

การพยากรณ์ความผันผวนราคาทองคำด้วยโครงข่ายประสาทเทียม

Forecasting Volatility of Gold Price with Artificial Neural Networks

วิจิตร คลังภูเขียว^{*}, ปิยภัทร บุษบาบดินทร์ และบังอร กุมพล

Wichit Khangphukhieo^{*}, Piyapatr Busababadhin and Bung-on Kumphon

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยมหาสารคาม

Mathematics Department, Faculty of Science, Mahasarakham University

Received : 7 September 2016

Accepted : 27 December 2016

Published online : 31 January 2017

บทคัดย่อ

ในการศึกษานี้มีวัตถุประสงค์เพื่อสร้างตัวแบบพยากรณ์ความผันผวนของราคาทองคำ ด้วยโครงข่ายประสาทเทียม โดยใช้ข้อมูลราคาทองคำแท่งสูงสุดรายวันในประเทศไทย ตั้งแต่วันที่ 2 พฤษภาคม 2549 ถึง 30 กันยายน 2558 รวมจำนวน 2,788 วัน ข้อมูลแบ่งออกเป็น 2 ส่วน คือ ส่วนแรกใช้ข้อมูล 90% จำนวน 2509 วัน ตั้งแต่วันที่ 2 พฤษภาคม 2549 ถึงวันที่ 24 ตุลาคม 2557 สำหรับฝึกการเรียนรู้ให้กับโครงข่าย และข้อมูลอีก 10% จำนวน 279 วัน เพื่อทดสอบประสิทธิภาพและความแม่นยำของโครงข่าย ในการวัดความแม่นยำของการพยากรณ์ เกณฑ์ที่ใช้ คือ ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) ค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และค่าคลาดเคลื่อนเปอร์เซ็นต์สัมบูรณ์เฉลี่ย (MAPE) ผลการศึกษาพบว่าโครงข่ายประสาทเทียมที่มีการเรียนรู้แบบแพร่กลับ (Backpropagation Learning) ซึ่งมีชั้นซ่อน 1 ชั้น นีวรอนในชั้นซ่อนจำนวน 20 นีวรอน ให้ค่า MAE RMSE และค่า MAPE ต่ำที่สุด

คำสำคัญ : ความผันผวนของราคาทองคำ, โครงข่ายประสาทเทียม

Abstract

This study aimed to develop a gold price volatility forecasting model by artificial neuron networks with Thailand daily maximum gold bar price data from May 2, 2006 to September 30, 2015 (2,788 days). Data were divided into two groups, 90% of data (2,509 days) from May 2, 2006 until October 24, 2014 were used as a training the network and another 10% of data (279 days) were used to test the model's effectiveness and accuracy. The criterions as mean absolute error (MAE), root mean square error (RMSE) and mean absolute percentage error (MAPE) were also calculated for the accuracy. The artificial neuron networks via Backpropagation learning with one hidden layer and 20 nodes performed the lowest MAE, RMSE, and MAPE.

Keywords: Volatility of Gold Price, Artificial Neural Networks

*Corresponding author. E-mail : wichitchob24041990@gmail.com

บทนำ

การลงทุนในภาวะเศรษฐกิจถดถอยหรือวิกฤติเศรษฐกิจ วิกฤติการณ์ทางการเมือง และความผันผวนของราคาน้ำมันในตลาดโลก ทำให้นักลงทุนส่วนใหญ่หันมาลงทุนหรือถือครองทองคำมากขึ้น เนื่องจากราคาทองคำปรับตัวสูงขึ้น และด้วยคุณลักษณะสินทรัพย์ที่มีความมั่นคงและปลอดภัยสูง ซึ่งในการลงทุนและการซื้อขายทองคำที่ได้รับความนิยมมากที่สุดในประเทศไทย คือทองคำแท่งความบริสุทธิ์ที่ 96.5% เนื่องด้วยค่าธรรมเนียมในการซื้อขายที่ต่ำกว่าทองคำรูปพรรณ ได้รับการยกเว้นภาษี และมีส่วนต่างในการซื้อขายน้อยกว่าทองคำรูปพรรณ โดยในทุกภาคส่วนมีการซื้อขายทองคำกันเองตลอดเวลา และการซื้อขายของร้านทองด้วยกันเอง จะมีปริมาณที่มากกว่าการซื้อขายกับผู้ลงทุนทั่วไปหลายสิบเท่า ดังนั้น เมื่อสมาคมค้าทองคำประกาศราคาทองคำสูงหรือต่ำกว่าความเป็นจริง จากตลาดต่างประเทศมากไปจะทำให้ร้านทองเทขายทองคำกันเอง ส่งผลให้สมาคมค้าทองคำต้องปรับราคาที่เหมาะสมที่สุด เพื่อสะท้อนถึงความต้องการซื้อขายที่แท้จริงของตลาด (Gold Traders Association, 2015)

ความสามารถและประสิทธิภาพของวิธีการ ที่ใช้ในคาดการณ์ราคาทองคำ จึงเป็นสิ่งสำคัญอย่างมากในตลาดการเงิน เศรษฐกิจ และการลงทุนในทองคำ จากการศึกษาของ Keerativibool & Na-laed (2013) ได้ศึกษาตัวแบบในการพยากรณ์ราคาทองคำรูปพรรณรายเดือน พบว่าวิธีการทำให้เรียบแบบเลขชี้กำลัง (Exponential Smoothing) ด้วยวิธีของโฮลต์ (Holt) มีความเหมาะสมมากที่สุด แต่เนื่องจากการคาดการณ์ข้อมูลสถานการณ์ทางเศรษฐกิจ ข้อมูลทางการเงิน มักเจอปัญหาความแปรปรวนของค่าคลาดเคลื่อนไม่คงตัว (Heteroskedasticity) โดยการใช้งานด้วยตัวแบบที่มีข้อบกพร่อง จะทำให้เกิดความสูญเสียทางเศรษฐกิจ และยังส่งผลต่อการตัดสินใจผิดพลาดในการลงทุน และด้วยตัวแบบที่ใช้ในการพยากรณ์ความผันผวนราคาทองคำในประเทศไทย ไม่สะท้อนความเป็นจริงในราคาการซื้อขายและราคาที่เกิดขึ้นในอนาคต ดังนั้น จึงมีนักวิจัยหลายคนได้นำเสนอวิธีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) มาใช้ในการพยากรณ์ข้อมูลทางเศรษฐกิจ ข้อมูลทางการเงิน เช่น Liao & Wang (2008) ได้นำเสนอโครงข่ายประสาทเทียม โดยใช้ฟังก์ชันอิทธิพลเวลา สโตแคสติก (Stochastic time effective function) ในการพยากรณ์ดัชนีตลาดหุ้นในประเทศจีน Kaewmart & Chancharat (2013) ได้ศึกษาการใช้โครงข่ายประสาทเทียมเพื่อหาตัวแบบในการพยากรณ์ดัชนีราคาหลักทรัพย์ของ 9 ประเทศหลัก ได้แก่ ไทย สิงคโปร์ มาเลเซีย อินโดนีเซีย ฟิลิปปินส์ สหรัฐอเมริกา อังกฤษ ญี่ปุ่น และฮ่องกง และจากการศึกษาของ Lin (2015) ได้นำเสนอโครงข่ายประสาทเทียมที่มีการเรียนรู้แบบแพร่ย้อนกลับ (Backpropagation Learning) ในการพยากรณ์ราคาทองคำในได้หวัน จากผลการศึกษาพบว่าวิธีการโครงข่ายประสาทเทียมเป็นวิธีที่มีประสิทธิภาพและความแม่นยำ

จากการศึกษาและพัฒนาตัวแบบเพื่อลดค่าคลาดเคลื่อน ที่สามารถอธิบายความผันผวนที่เกิดขึ้น โดยการนำเสนอวิธีการโครงข่ายประสาทเทียม ซึ่งเป็นวิธีการที่ให้ประสิทธิภาพและความแม่นยำ เมื่อใช้กับข้อมูลที่มีขนาดใหญ่ ข้อจำกัดในการใช้งานน้อยความยืดหยุ่นสูง ความทนทานต่อข้อบกพร่อง (Fault Tolerance) เมื่อเกิดความเสียหายขึ้นในโครงข่ายและมีความสามารถในการปรับตัว (Adaptive) ได้ในกรณีข้อมูลไม่เป็นเชิงเส้น (Nonlinear) ในฐานะที่ทองคำเป็นสินทรัพย์ที่ปลอดภัย และเป็นสินทรัพย์ที่นักลงทุนในปัจจุบันให้ความสนใจ Zhang *et al.* (1998) ดังนั้น ผู้วิจัยจึงสนใจศึกษาวิธีโครงข่ายประสาทเทียมที่มีการเรียนรู้แบบแพร่ย้อนกลับ ในการสร้างตัวแบบการพยากรณ์ความผันผวนราคาทองคำในประเทศไทย โดยรวมปัจจัยที่มีอิทธิพลต่อความผันผวนของราคาทองคำเข้าไปในตัวแบบ นอกจากนี้ผลลัพธ์ที่ได้เป็นการนำเสนอตัวแบบการพยากรณ์ที่ให้ประสิทธิภาพความแม่นยำในการพยากรณ์ที่ดี

วิธีดำเนินการวิจัย

1. ข้อมูลที่ศึกษา

ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลทุติยภูมิราคาทองคำแห่งประเทศไทย (หน่วย: บาท) เป็นข้อมูลอนุกรมเวลา รายวัน (Times Series Data) จากเว็บไซต์สมาคมค้าทองคำ (Gold Traders Association, 2015) และทำการพิจารณาเลือก ข้อมูลราคาทองคำสูงสุดรายวัน ตั้งแต่วันที่ 2 พฤษภาคม 2549 ถึง 30 กันยายน 2558 จำนวน 2,788 วัน เนื่องด้วยข้อมูลราคา ทองคำที่ถูกประกาศออกมา โดยสมาคมค้าทองคำในแต่ละวันมีมากกว่าหนึ่งค่า จากนั้นแปลงข้อมูล (Data Transformation) อยู่ในรูปผลตอบแทนของราคาทองคำแบบลอการิทึม โดยใช้ Logarithm Return ซึ่งมีสมการคำนวณ ดังสมการ (1) โดยที่ กำหนดให้ r_t คือ ผลตอบแทนของราคาทองคำแบบลอการิทึม P_t คือ ราคาของทองคำในคาบเวลาปัจจุบัน P_{t-1} คือ ราคาของ ทองคำในคาบเวลาที่ผ่านมา

$$r_t = \log P_t - \log P_{t-1} \quad (1)$$

$$r'_t = \frac{r_t - r_{\min}}{r_{\max} - r_{\min}} (new\ r_{\max} - new\ r_{\min}) + new\ r_{\min} \quad (2)$$

เนื่องจากเพื่อเป็นการป้องกันการเกิดข้อมูลรบกวน (Noisy Data) หรือค่านอกเกณฑ์ (Outliers) จึงทำการปรับข้อมูลผลตอบแทนของราคาทองคำ ให้ข้อมูลมีค่าอยู่ในช่วง -1 ถึง 1 ดังสมการที่ (2) เพื่อช่วยให้อัลกอริทึม ใช้หน่วยความจำและระยะเวลาในการประมวลผลสั้นลง ในขั้นตอนการเรียนรู้ของโครงข่ายประสาทเทียม กำหนดให้ r'_t คือผลตอบแทนราคาทองคำ โดยกำหนดให้ r_{\max} คือ ผลตอบแทนราคาทองคำสูงสุด r_{\min} คือ ผลตอบแทนราคาทองคำต่ำสุด $new\ r_{\max}$ คือ ช่วงของค่ามาตรฐานสูงสุดมีค่าเท่ากับ 1 และ $new\ r_{\min}$ คือ ช่วงของค่ามาตรฐานต่ำสุด มีค่าเท่ากับ -1 (Dahlan *et al.*, 2010) โดยที่ r'_t ถูกใช้เป็นข้อมูลเป้าหมาย (Target) และตัวแปรที่ใช้เป็นข้อมูลนำเข้า (Input Data) ให้กับโครงข่าย คือ ราคาทองคำตลาดโลก (Gold Traders Association, 2015) อัตราแลกเปลี่ยนสกุลเงินดอลลาร์สหรัฐ อัตราแลกเปลี่ยน สกุลเงินเยน (Bank of Thailand, 2015) ดัชนีราคาน้ำมันตลาดหลักทรัพย์แห่งประเทศไทย (The Stock Exchange of Thailand, 2015) และข้อมูลราคาน้ำมันดิบโลก (U.S. Energy Information Administration, 2015) โดยทำการแบ่งข้อมูลออกเป็น 2 ชุด โดยที่ข้อมูลชุดแรกจำนวน 90% จำนวน 2509 วัน ตั้งแต่วันที่ 2 พฤษภาคม 2549 ถึงวันที่ 24 ตุลาคม 2557 ใช้สำหรับเป็น ข้อมูลฝึกการเรียนรู้ให้กับโครงข่าย (Data Training Set) และข้อมูลชุดที่ 2 อีก 10% ตั้งแต่วันที่ 25 ตุลาคม 2557 ถึงวันที่ 30 กันยายน 2558 จำนวน 279 วัน เป็นชุดของข้อมูลที่ใช้เพื่อทดสอบประสิทธิภาพของโครงข่าย (Data Testing Set) (Nam & Schaefer, 1995) โดยทำการทดสอบสมบัติหนึ่งของข้อมูล ด้วยสถิติทดสอบ ADF (Augmented Dickey Fuller) (Busababodhin *et al.*, 2015)

2. วิธีการวิจัย

โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) เป็นวิธีที่ถูกพัฒนามาจากการทำงานของเซลล์ ประสาททางชีววิทยา (Biological Neuron) ซึ่งมีความสามารถในการปรับตัวเมื่อข้อมูลไม่เป็นเชิงเส้น มีความสามารถในการ


เรียนรู้จากตัวอย่างและการทำให้เป็นทั่วไป (Generalize) โครงข่ายจะถูกฝึกการเรียนรู้โดยการแสดงรูปแบบ (Pattern) ต่างๆ ที่ต้องการให้โครงข่ายเรียนรู้ด้วยกฎการเรียนรู้ (Learning Rule) การที่โครงข่ายถูกทำให้เป็นกรณีทั่วไป จะทำให้ตัวโครงข่ายสามารถที่จะจำแนกรูปแบบของข้อมูลนำเข้าแบบใหม่ๆ ที่ตัวโครงข่ายไม่รู้จักมาก่อนในระดับที่เป็นที่ยอมรับได้ ตัวโครงข่ายจะทำการเก็บข้อมูลความรู้ (Knowledge) ในระหว่างขั้นตอนของการเรียนรู้ โดยเก็บไว้ที่น้ำหนักประสาท (Synaptic Weights) ในการประยุกต์ใช้โครงข่ายประสาทเทียมในการทำนาย โดยการกำหนดเซตของค่าเป้าหมาย (Target) N ค่า คือ $\{y(t_1), y(t_2), \dots, y(t_N)\}$ ณ เวลา t_1, t_2, \dots, t_N ตามลำดับ ในการพยากรณ์ผลล่วงหน้า คือ $y(t_{N+1})$ ซึ่งเป็นค่า ณ เวลา t_{N+1} ในอนาคต การใช้ฟังก์ชันประมาณค่าจึงจำเป็นต้องทำการกำหนด ชนิดของฟังก์ชันถ่ายโอน (Activation Function) โดยปกติแล้วโครงข่ายจะประกอบไปด้วยนิเวรอนหลายๆ ตัว และเชื่อมต่อแบบขนานกันหลายๆ ชั้นเรียกว่า Layer แต่ละชั้นมีน้ำหนักประสาท (Weight) ค่าเอนเอียง (Biased) ของชั้นนั้นๆ ซึ่งชั้นแรกเรียกว่าชั้นนำเข้ามี R อินพุต ชั้นที่หนึ่งมี S^1 นิเวรอนไปเรื่อยๆ จนถึงชั้นสุดท้ายคือชั้นผลลัพธ์ซึ่งมี S^N นิเวรอน โครงข่ายที่ไม่ใช่ชั้นนำเข้าและชั้นผลลัพธ์ เรียกว่าชั้นซ่อน (Hidden Layer) ซึ่งในชั้นซ่อนนั้น ช่วยแปลงข้อมูลจากไม่เชิงเส้นให้กลายเป็นเชิงเส้น (Srikaew, 2009) ค่าผลลัพธ์ในรูปแบบทั่วไปในชั้นซ่อนของโครงข่าย แสดงดังสมการ (3)

$$a_j = f \sum_{i=0}^d w_{ji} x_i - b_i \quad (3)$$

เมื่อพิจารณาจากผลลัพธ์ (Output) ของโครงข่ายประสาทเทียมในรูปแบบทั่วไป แสดงในสมการ (4)

$$o_i = f \sum_{j=0}^m w_{kj} g \left(\sum_{i=0}^d w_{ji} x_i - b_i \right) - b_j \quad (4)$$

โดยกำหนดให้ i แทน จำนวนนิเวรอนในชั้นนำเข้า ที่ $i = 1, 2, \dots, d$ โดยที่ j แทน จำนวนนิเวรอนในชั้นซ่อน ที่ $j = 1, 2, \dots, m$ w_{ji} แทน ค่าน้ำหนัก ของเส้นเชื่อมจากชั้นนำเข้า ของนิเวรอนที่ i w_{kj} แทน ค่าน้ำหนักของเส้นเชื่อมจากชั้นซ่อนของนิเวรอนที่ j โดย b_i แทน ค่าเอนเอียงของเส้นเชื่อมจากชั้นนำเข้าของนิเวรอนที่ i และ b_j แทน ค่าเอนเอียงของเส้นเชื่อมจากชั้นซ่อนของนิเวรอนที่ j โดย g แทน ฟังก์ชันถ่ายโอนในชั้นซ่อน f แทน ฟังก์ชันถ่ายโอนในชั้นผลลัพธ์ a_j แทน ผลลัพธ์ในชั้นซ่อนที่ j และ o_i แทน ผลลัพธ์ที่ i



ภาพที่ 1 สถาปัตยกรรมโครงข่ายประสาทเทียมแบบชั้นเดียวหลายนิวรอน

ในการพิจารณาเลือกสถาปัตยกรรมของโครงข่าย (Network Architecture) ในการศึกษาครั้งนี้ ซึ่งมีสถาปัตยกรรมของโครงข่าย ดังภาพที่ 1 ที่มีรูปแบบของการไหลของโครงข่ายแบบไปข้างหน้า (Feedforward Network) โดยมีชั้นซ่อนจำนวน 1 ชั้นซ่อน อย่างไรก็ตามในการพยากรณ์บางปัญหาที่ใช้จำนวนชั้นซ่อนเพียง 1 ชั้น อาจทำให้โครงข่ายที่ได้มีจำนวนนิวรอนในชั้นซ่อนมีจำนวนมากเกินไป และการเพิ่มจำนวนนิวรอนในชั้นซ่อนที่มากเกินไป อาจส่งผลกระทบต่อระยะเวลาในการเรียนรู้ที่เพิ่มขึ้น ควรเพิ่มจำนวนชั้นซ่อนแทนการเพิ่มจำนวนนิวรอนที่มากขึ้น และทำให้ระยะเวลาในการฝึกการเรียนรู้ของโครงข่ายมากตามไปด้วย แต่ในการเพิ่มจำนวนชั้นซ่อนที่มากขึ้น ก็ไม่สามารถยืนยันได้ว่าจะให้ผลการพยากรณ์ที่มีความแม่นยำมากขึ้น ตาม ซึ่งโครงข่ายที่มีจำนวนชั้นซ่อนน้อยจะมีความซับซ้อนที่น้อยกว่าโครงข่ายที่มีจำนวนชั้นซ่อนมาก (Zhang *et al.*, 1998) จากตารางที่ 1 ทำการกำหนดค่าพารามิเตอร์ของโครงข่ายที่ใช้ในการฝึกการเรียนรู้ ที่มีการเรียนรู้แบบแพร่กลับ (Backpropagation Learning) และทำการปรับปรุงอัลกอริทึมด้วยฟังก์ชัน Levenberg-Marquardt เพื่อให้การปรับค่าน้ำหนักและค่าเอนเอียง ในเส้นเชื่อมแต่ละชั้นของโครงข่ายให้มีความรวดเร็วและได้ค่าที่เหมาะสม จากนั้นทำการปรับค่าผลรวมของนิวรอน ในชั้นซ่อนด้วยฟังก์ชันถ่ายโอน คือ ฟังก์ชันซิกมอยด์แบบเส้นสัมผัสไฮเพอร์โบลาร์ (Hyperbolic Tangent Sigmoid) ซึ่งมีผลลัพธ์อยู่ในช่วง $[-1, 1]$ มีอัตราการเรียนรู้เท่ากับ (Learning Rate) 0.0001 จำนวนรอบในการฝึกการเรียนรู้ (Epoch) สูงสุด 1,000 รอบ โดยใช้ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean squared error: MSE) ดังสมการที่ (5) เป็นเกณฑ์ในการเลือกนิวรอนในชั้นซ่อนที่เหมาะสมให้กับโครงข่าย

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{r}_i - r_i')^2 \quad (5)$$

ตารางที่ 1 พารามิเตอร์สำหรับการพยากรณ์ความผันผวนราคาทองคำ

Parameters	Value
Activation Function	Hyperbolic Tangent Sigmoid
Learning Algorithm	Backpropagation
Training Function	Levenberg-Marquardt Backpropagation
Leaning Rate	0.0001
Epoch	1,000
Number of Hidden Neurons	1-50

3. เกณฑ์ในการวัดประสิทธิภาพและความแม่นยำของโครงข่ายประสาทเทียม

ในการทดสอบประสิทธิภาพและความแม่นยำ โดยใช้เกณฑ์ในการวัดด้วยค่าสถิติ 3 ค่า ได้แก่ ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ดังสมการ (6) ค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ดังสมการ (7) และค่าเปอร์เซ็นต์ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ดังสมการ (8) เมื่อค่าสถิติตัวใดในการวัดมีค่าน้อย แสดงให้เห็นว่าค่าสถิติตัวนั้นมีความแม่นยำในการพยากรณ์ตามเกณฑ์ของ (Lewis, 1982) โดยที่กำหนดให้ r'_t และ \hat{r}_t เป็นค่าจริงของข้อมูลและค่าที่ได้จากการพยากรณ์ตามลำดับ โดยที่ n เป็นจำนวนของข้อมูลอนุกรมเวลาทั้งหมด (Manmin, 2006)


$$MAE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{r}_t - r'_t}{r'_t} \right| \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{r}_t - r'_t)^2} \quad (7)$$


$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{r}_t - r'_t}{r'_t} \right| \times 100 \quad (8)$$

ผลการวิจัยและวิจารณ์ผล

จากการพิจารณาข้อมูลราคาทองคำแห่งประเทศไทย ที่ใช้เป็นข้อมูลชั้นผลลัพธ์ของโครงข่าย ดังภาพที่ 3 แสดงให้เห็นว่าราคาทองคำ มีแนวโน้ม และมีลักษณะการเคลื่อนไหวไม่นิ่ง (Non-Stationary) จึงทำการทดสอบด้วยสถิติทดสอบ ADF จากผลการทดสอบพบว่า ลักษณะการเคลื่อนไหวของข้อมูลราคาทองคำแห่งประเทศไทยไม่นิ่ง ที่ระดับนัยสำคัญ 0.05




ภาพที่ 3 ราคาทองคำแท่งในประเทศไทย (P_t)




ภาพที่ 4 ผลตอบแทนราคาทองคำ (r_t')

เมื่อทำการแปลงข้อมูล ให้อยู่ในรูปของผลตอบแทนราคาทองคำ ดังภาพที่ 4 พบว่าลักษณะการเคลื่อนไหวของผลตอบแทนราคาทองคำมีความนิ่ง (Stationary) ที่ระดับนัยสำคัญ 0.05 จากการพิจารณาตัวแปรนำเข้า ด้วยค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson Correlation Coefficient) พบว่าตัวแปรที่มีความสัมพันธ์ในทิศทางเดียวกับผลตอบแทนราคาทองคำ ได้แก่ ราคาทองคำตลาดโลก อัตราแลกเปลี่ยนสกุลเงินเยน ดัชนีราคาหุ้นตลาดหลักทรัพย์แห่งประเทศไทย และราคาน้ำมันดิบโลก (ค่าสหสัมพันธ์อยู่ระหว่าง 0.41 ถึง 0.70) และตัวแปรที่มีความสัมพันธ์ในทิศทางตรงข้าม ได้แก่ อัตราแลกเปลี่ยนสกุลเงินดอลลาร์สหรัฐ (ค่าสหสัมพันธ์เท่ากับ -0.85)




ภาพที่ 5 แสดงค่า MSE เมื่อจำนวนนิวรอนในชั้นซ่อนแตกต่างกัน

จากการใช้ข้อมูลชุด 90% ในการฝึกการเรียนรู้ให้กับโครงข่ายและทำการปรับจำนวนนิวรอนในชั้นซ่อน จาก 1 ถึง 50 นิวรอน เพื่อหาจำนวนนิวรอนในชั้นซ่อนที่เหมาะสม จากภาพที่ 5 พบว่าโครงข่ายที่เหมาะสม คือ โครงข่ายที่มีจำนวนนิวรอนในชั้นซ่อน 20 นิวรอน (ANN-20) เนื่องจากมีค่าคลาดเคลื่อนกำลังสองเฉลี่ยต่ำที่สุด (0.00019)

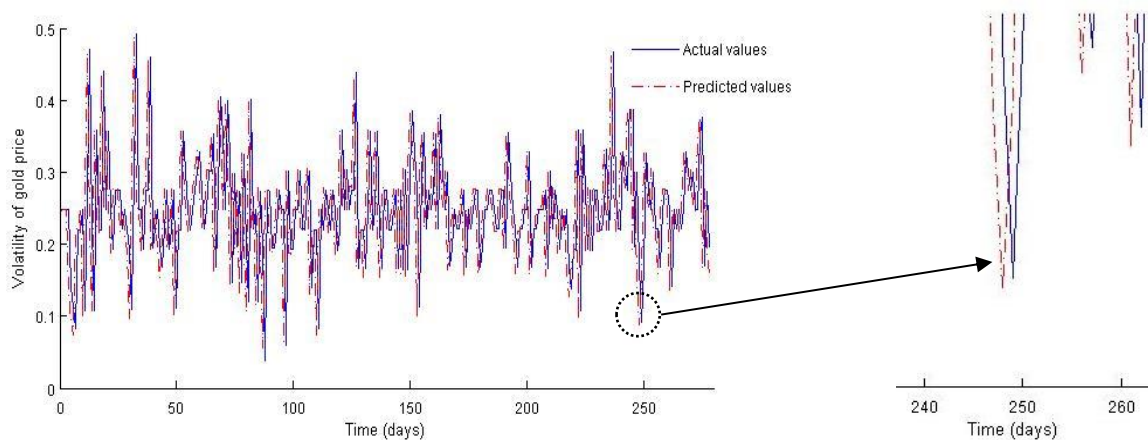


ภาพที่ 6 ค่าคลาดเคลื่อนกำลังสองเฉลี่ยในขั้นตอนการเรียนรู้



ภาพที่ 7 การกระจายข้อมูลผลลัพธ์และข้อมูลที่คาดหวัง

จากภาพที่ 6 แสดงให้เห็นว่าโครงข่าย ANN-20 ในการกระบวนการฝึกการเรียนรู้ของโครงข่าย มีค่าคลาดเคลื่อนกำลังสองเฉลี่ยน้อยลง เมื่อจำนวนรอบในการเรียนรู้ เพิ่มขึ้น และมีค่าต่ำสุดที่จำนวนรอบในการเรียนรู้ เท่ากับ 142 รอบ ในการกระจายของข้อมูลเป้าหมาย (Target) หรือข้อมูลผลลัพธ์ที่คาดหวัง มีค่าใกล้เคียงกับข้อมูลผลลัพธ์จากโครงข่าย ANN-20 แสดงให้เห็นว่าค่าคลาดเคลื่อนของค่าพยากรณ์ในการเรียนรู้ ของโครงข่าย ANN-20 มีค่าน้อย แสดงดังภาพที่ 7



ภาพที่ 8 ค่าพยากรณ์จากตัวแบบ ANN-20 และผลตอบแทนราคาทองคำ

เมื่อทำการทดสอบประสิทธิภาพและความแม่นยำของโครงข่ายประสาทเทียม ที่ใช้การพยากรณ์ความผันผวนราคาทองคำ โดยใช้ข้อมูล 10% จำนวน 279 วัน เปรียบเทียบกับค่าพยากรณ์จากโครงข่ายประสาทเทียม ANN-20 ที่ได้จากการเลือกโครงข่ายที่มีความเหมาะสมและความแม่นยำ ในขั้นตอนการฝึกการเรียนรู้ของโครงข่ายที่ผ่านมา จากภาพที่ 8 แสดง

ให้เห็นว่าเส้นกราฟระหว่างค่าพยากรณ์ ที่ได้จากตัวแบบโครงข่ายประสาทเทียม ANN-20 มีค่าใกล้เคียงกับผลตอบแทนราคาของค่า (Actual value) นั่นคือค่าคลาดเคลื่อนในการพยากรณ์มีค่าน้อยเช่นเดียวกัน ถึงแม้ว่าค่าข้อมูลผลตอบแทนราคาของค่ากับค่าพยากรณ์ที่ได้จากตัวแบบ ANN-20 จะมีค่าใกล้เคียงกัน เมื่อทำการวัดประสิทธิภาพและความแม่นยำในการพยากรณ์ด้วยค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย ค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย และเปอร์เซ็นต์ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย พบว่าค่าคลาดเคลื่อนทั้งสามค่า คือ MAE มีค่าเท่ากับ 0.0120 RMSE มีค่าเท่ากับ 0.0368 และ MAPE มีค่าเท่ากับ 1.2229 แสดงให้เห็นว่าตัวแบบโครงข่ายประสาทเทียม ANN-20 มีความแม่นยำในการพยากรณ์ความผันผวนราคาทองคำสูง เมื่อทำการพยากรณ์ล่วงหน้าไป 279 วัน

สรุปผลการวิจัย

ผลจากการพยากรณ์ความผันผวนราคาทองคำด้วยวิธีโครงข่ายประสาทเทียม แสดงให้เห็นว่าเป็นอีกหนึ่งวิธีการในการสร้างตัวแบบที่ให้ความแม่นยำในการพยากรณ์สูง เนื่องจากโครงข่ายประสาทเทียมมีความสามารถในการปรับตัวในกรณีข้อมูลไม่เป็นเชิงเส้นได้ดี สอดคล้องกับงานวิจัยของ Lin (2015) ได้นำเสนอโครงข่ายประสาทเทียมที่มีการเรียนรู้แบบแพร่ย้อนกลับ ที่ให้ความแม่นยำในการพยากรณ์ราคาทองคำในได้วัน และผลในการสร้างตัวแบบด้วยวิธีโครงข่ายประสาทเทียมที่มีจำนวนชั้นซ่อนเพียง 1 ชั้น สามารถให้ผลในการพยากรณ์ที่มีความแม่นยำสูง ซึ่งสอดคล้องกับงานวิจัยของ Kara *et al.* (2011) โดยใช้โครงข่ายประสาทเทียมที่มีรูปแบบของการไหลแบบไปข้างหน้า มีการเรียนรู้แบบแพร่ย้อนกลับ และมีจำนวนชั้นซ่อน 1 ชั้นซ่อน พบว่ามีประสิทธิภาพและความแม่นยำในการพยากรณ์ดัชนีราคาหุ้นตลาดหลักทรัพย์ในอิสตันบูล ในการพิจารณาข้อมูลนำเข้า จำเป็นต้องทำการตรวจสอบข้อมูลเป็นอย่างดี เพื่อหลีกเลี่ยงการเกิดปัญหาข้อมูลรบกวนหรือมีค่านอกเกณฑ์ และทำให้ได้ข้อมูลที่มีความสมบูรณ์เป็นข้อมูลนำเข้า ในการฝึกการเรียนรู้ให้กับโครงข่าย ถึงแม้การใช้วิธีโครงข่ายประสาทเทียม ไม่ได้มีข้อจำกัดในการเลือกตัวแปรหรือข้อมูลนำเข้า แต่การตรวจสอบข้อมูลและมีสมบัติหนึ่ง ช่วยลดระยะเวลาในการค้นหาโครงข่ายที่มีความเหมาะสม และเพื่อหลีกเลี่ยงปัญหาการเกิดเหตุการณ์ Overfitting คือ ตัวแบบที่ได้มีประสิทธิภาพและความแม่นยำกับข้อมูลชุดฝึกการเรียนรู้ แต่เมื่อทำการเปรียบเทียบกับข้อมูลชุดทดสอบตัวแบบไม่มีประสิทธิภาพและความแม่นยำ

ข้อเสนอแนะจากการศึกษาครั้งนี้ เมื่อทำการพยากรณ์ในระยะเวลามากขึ้น ควรนำข้อมูลใหม่เพิ่มเข้าไปเป็นข้อมูลนำเข้า ในขั้นตอนการฝึกการเรียนรู้ให้กับโครงข่าย เนื่องจากราคาทองคำเปลี่ยนแปลงตลอดเวลา และมีความผันผวนซึ่งเกิดขึ้นได้จากปัจจัยหลายปัจจัย

กิตติกรรมประกาศ

โครงการวิจัยนี้ได้รับทุนอุดหนุนการวิจัยสำหรับนิสิตระดับบัณฑิตศึกษา มหาวิทยาลัยมหาสารคาม งบประมาณเงินรายได้ประจำปีงบประมาณ 2560

เอกสารอ้างอิง

Bank of Thailand. (2015). *Financial Markets Statistics*. Retrieved August 15, 2015, from <https://www.bot.or.th/Thai/Statistics/FinancialMarkets/Pages/default.aspx>

- Busababodin, P., Siriboon, M. & Kaewmun, A. (2015). Modeling of Extreme Precipitation in Upper Northeast of Thailand. *Burapha Science Journal*, 20(1), 106-117. (in Thai)
- Dahlan, I., Ahmad, Z., Fadly, M., Lee, K.T., Kamaruddin, A.H. & Mohamed, A.R. (2010). Parameters optimization of rice husk ash (RHA)/CaO/CeO₂ sorbent for predicting SO₂/NO sorption capacity using response surface and neural network models. *J. Hazard. Mater*, 178, 249-257.
- Gold Traders Association. (2015). *Features and Benefits of Gold*. Retrieved October 20, 2015, from <http://www.goldtraders.or.th/PageView.aspx?page=5>
- Kaewmart, W. & Chancharat, S. (2013). Artificial Neural Network Forecasting for Stock Indices. *KKU Research Journal (Graduate Studies)*, 1(1), 108-118. (in Thai)
- Kara, Y., Boyacioglu, M.A. & Baykan, K.Ö. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, 38, 5311-5319.
- Keerativibool, W. & Na-laed, D. (2013). Forecasting Model of Monthly Gold Ornament Selling Prices. *NU Science Journal*, 9(2), 65-81. (in Thai)
- Lewis, C.D. (1982). *International and Business Forecasting Methods*. London: Butterworths.
- Liao Z. & Wang J. (2008). Forecasting Model of Chinese Stock Index by Stochastic Time Effective Neural Network. In *Internal Conference on Wireless Communication, Networking and Mobile Computing*. (pp. 1-4). China: IEEE.
- Lin, C. (2015). Build Prediction Models for Gold Prices Based on Back-Propagation Neural Network. In *Internal Conference on Modelling Simulation and Applied Mathematic*. (pp. 155-158). Thailand: Atlantis Press.
- Manmin, M. (2006). *Time Series and Forecasting*. Bangkok: Four Printing Co., Ltd. (in Thai)
- Nam, K. & Schaefer, T. (1995). Forecasting international airline passenger traffic using neural networks. *Logistics and Transportation*, 31(3), 239-251.
- Sonia, R.B. (2015). Forecasting volatility in gold returns under the GARCH, IGARCH and FIGARCH frameworks: New evidence. *Physica A: Statistical Mechanics and its Applications*, 438, 355-364.
- Srikaew, A. (2009). *Computational Intelligence*. Bangkok: Charansnitwong Co., Ltd. (in Thai)
- The Stock Exchange of Thailand. (2015). *SET Index Series*. Retrieved August 15, 2015, from http://www.set.or.th/th/products/index/setindex_p1.html
- U.S. Energy Information Administration. (2015). *PETROLEUM & OTHER LIQUIDS*. Retrieved August 15, 2015, from <http://tonto.eia.gov/dnav/pet/hist/LeafHandler.ashx?n=PET&s=RWTC&f=D>
- Zhang, G., Eddy, P.B. & Michael, Y.H. (1998). Forecasting with artificail neural networks: The state of the art. *International Journal of Forecasting*, 14, 35-62.