



การวัดประสิทธิภาพการพยากรณ์ของแบบจำลองเครือข่ายประสาทเทียม: กรณีศึกษาดัชนีราคาตลาดหลักทรัพย์แห่งประเทศไทย

สุรัชย์ จันทรจรัส^{1*} ระวี มุสิกโปดก² และ จีรนันท์ เข็มจันทร์²

บทคัดย่อ

งานวิจัยนี้ ศึกษาเกี่ยวกับประสิทธิภาพในการพยากรณ์ของแบบจำลองเครือข่ายประสาทเทียม โดยใช้ข้อมูลราคาปิดของดัชนีราคาหลักทรัพย์รายวันของตลาดหลักทรัพย์แห่งประเทศไทย ระหว่างวันที่ 4 มกราคม 2548 ถึง 7 พฤศจิกายน 2554 รวมจำนวนข้อมูลทั้งสิ้น 1,672 วัน โดยแบ่งข้อมูล 32 วันสุดท้ายออกเพื่อใช้ทดสอบประสิทธิภาพการพยากรณ์ของแต่ละแบบจำลอง ผลการวิจัยจากการสร้างแบบจำลองเครือข่ายประสาทเทียมจำนวน 5 แบบจำลอง ประกอบไปด้วย

เครือข่าย 27-50-1, 45-60-1, 48-42-1, 47-49-1 และ 45-47-1 ซึ่งให้ค่าเฉลี่ยเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) 2.2926, 2.3003, 2.7125, 2.7666 และ 2.7786 ตามลำดับ พบว่าแบบจำลองเครือข่ายประสาทเทียมเครือข่าย 27-50-1 ให้ค่า MAPE ในการพยากรณ์ข้อมูล 32 วัน ได้ใกล้เคียงค่าจริงมากที่สุด

คำสำคัญ: เครือข่ายประสาทเทียม ตลาดหลักทรัพย์ การพยากรณ์

¹ ผู้ช่วยศาสตราจารย์ คณะวิทยาการจัดการ มหาวิทยาลัยขอนแก่น

² นักศึกษา คณะวิทยาการจัดการ มหาวิทยาลัยขอนแก่น

* ผู้นิพนธ์ประสานงาน โทรศัพท์ 0-4320-2401 ต่อ 201 อีเมล: csurac@kku.ac.th



Prediction Efficiency with Artificial Neural Network: Case Study of the SET Index

Surachai Chancharat^{1*} Rawee Musikapodoke² and Jeeranun Khermkhan²

Abstract

This study aimed to forecast the time series of an Artificial Neural Network (ANN). The time series data were comprised of the closing prices of the Stock Exchange of Thailand (SET) index from 4 January 2005 to 7 November 2011. One thousand six hundred and seventy-two daily samples were employed. The data for the last 32 days were used to calculate the forecasting performance of the ANNs. The results of

the established models consisted of 5 structures of the artificial neural networks: 27-50-1, 45-60-1, 48-42-1, 47-49-1 and 45-47-1 with Mean Absolute Percentage Error (MAPE) values of 2.2926, 2.3003, 2.7125, 2.7666 and 2.7786. The 27-50-1 network was the most accurate network in the 32-days' forecast.

Keywords: Artificial Neural Network, Stock Exchange, Prediction

¹ Assistant Professor, Faculty of Management Science, Khon Kaen University.

² Student, Faculty of Management Science, Khon Kaen University.

* Corresponding Author, Tel. 0-4320-2401 Ext. 201, E-mail: csurac@kku.ac.th

1. บทนำ

ในปัจจุบันการลงทุนในตลาดหลักทรัพย์ของประเทศไทยได้รับความสนใจอย่างมาก เนื่องมาจากการลงทุนในตลาดหลักทรัพย์นั้น มีโอกาสที่จะได้รับอัตราผลตอบแทนสูงกว่าการออมเงินในรูปเงินฝากกับธนาคารพาณิชย์สภาพการณ์ตลาดทุนและตลาดเงินในปัจจุบันถือได้ว่าการเปลี่ยนแปลงจากอดีตที่ผ่านมาทำให้ผู้ลงทุนจะต้องเผชิญกับปัญหาที่มีความซับซ้อนมาก เนื่องจากตลาดทุนมีการพัฒนาอย่างต่อเนื่อง เช่นมีผลิตภัณฑ์ใหม่ๆ เพื่อตอบสนองความต้องการของนักลงทุน มีจำนวนนักลงทุนรายย่อยเพิ่มขึ้นและตลาดทุนมีการขยายตัวอย่างกว้าง รวมถึงข้อมูลราคาหลักทรัพย์มีลักษณะที่ขึ้นลงอยู่ตลอดเวลา กล่าวคือโดยทั่วไปแล้วลักษณะของข้อมูลอนุกรมเวลา (Time Series) จะมีการเปลี่ยนแปลงเสมอเมื่อเวลาเปลี่ยนแปลงไป ซึ่งสิ่งเหล่านี้เป็นปัญหาที่มีความซับซ้อนและยากแก่การคาดการณ์ถึงแนวโน้มของตลาดหุ้นได้ [1] ดังนั้นการพยากรณ์แนวโน้มราคาหลักทรัพย์ในอนาคตถือเป็นสิ่งสำคัญที่จะช่วยลดปัญหาให้กับนักลงทุนได้

การพยากรณ์ข้อมูลอนุกรมเวลามีความสำคัญในสาขาวิชาต่างๆ รวมถึงสาขาวิชาเศรษฐศาสตร์ การพยากรณ์ทำให้สามารถคาดการณ์ถึงสิ่งใดสิ่งหนึ่งที่จะเกิดขึ้นในอนาคต และนำค่าพยากรณ์นั้นมาใช้ประโยชน์ ไม่ว่าจะเป็นการวางแผน การตัดสินใจ การเตรียมตัวป้องกันหรือสร้างผลกำไรจากการคาดการณ์ในอนาคต ทั้งนี้ค่าการพยากรณ์ที่ได้จะต้องมีความแม่นยำและคลาดเคลื่อนในระดับที่ยอมรับได้ การพยากรณ์การข้อมูลอนุกรมเวลา เช่น การพยากรณ์ข้อมูลทางการเงิน ข้อมูลเหล่านี้จะมีความยากในการสร้างค่าพยากรณ์ให้แม่นยำ [2] เนื่องจากปัจจัยบางประการ ประกอบไปด้วย ข้อจำกัดของจำนวนข้อมูลกลุ่มตัวอย่างเช่น ข้อมูลกลุ่มตัวอย่างไม่เป็นระบบเชิงเส้น (Non-Linear) ข้อมูลไม่มีความนิ่ง (Non-Stationary) ข้อมูลมีคลื่นรบกวน (Noise) รวมถึงข้อจำกัดในความสามารถของแบบจำลอง (Model) ที่ใช้พยากรณ์ [3]

ข้อมูลทางการเงินโดยส่วนใหญ่จะเป็นระบบที่ไม่เชิงเส้นและข้อมูลมักจะไม่มีความนิ่ง ซึ่งทำให้ยากต่อการสร้างตัวแบบพยากรณ์ที่ให้ค่าการพยากรณ์ที่แม่นยำ ยกตัวอย่างเช่น ราคาหลักทรัพย์ที่ซื้อขายกันในตลาดหลักทรัพย์ประเทศต่างๆ ราคาหลักทรัพย์เหล่านี้มีความผันผวนสูง การลงทุนในตลาดหลักทรัพย์ทำให้นักลงทุนต้องเผชิญกับความเสี่ยงจากราคาหลักทรัพย์ที่มีความผันผวนอยู่เสมอ และยากต่อการคาดคะเนได้ ซึ่งมีสมมติฐานเกี่ยวกับประสิทธิภาพของตลาด (Efficient Market Hypothesis) ได้อธิบายพฤติกรรมของราคาหลักทรัพย์ไว้ว่าเป็นตลาดที่มีประสิทธิภาพในระดับอ่อน (Weak Form Efficient) [4]-[6] ราคาหลักทรัพย์จะเคลื่อนที่แบบสุ่ม (Random Walk) [7] คือไม่สามารถคาดเดาสว่างหน้าได้ เป็นความยากที่เกิดจากพฤติกรรมของข้อมูล ดังนั้นจึงต้องมีการพยากรณ์ดัชนีราคาหลักทรัพย์ในตลาดหลักทรัพย์แห่งประเทศไทย (Stock Exchange of Thailand) ที่มีลักษณะความผันผวนสูงเพื่อลดความเสี่ยงให้กับนักลงทุน [8]

ผลงานวิจัยที่ผ่านมาพบว่า เครื่องมือที่ใช้ในการวิเคราะห์หลักทรัพย์ทางเทคนิคที่นิยมใช้อยู่ในปัจจุบันยังไม่มีข้อสรุปที่ชัดเจนว่าแบบจำลองใดให้ความแม่นยำในการพยากรณ์ดีที่สุด โดยเครื่องมือที่ถูกนำมาใช้ในการวิเคราะห์ทางเทคนิคนี้ส่วนใหญ่อาศัยการวิเคราะห์ทางสถิติ เช่น การวิเคราะห์เชิงเส้น การถดถอย และการวิเคราะห์อนุกรมเวลา เครื่องมือเหล่านี้ทำนายได้เฉพาะการหาความสัมพันธ์เชิงเส้น ซึ่งข้อมูลราคาหลักทรัพย์เป็นข้อมูลที่ไม่ใช่ข้อมูลเชิงเส้น [9] รวมถึงมีข้อบกพร่องของแบบจำลองที่ทำการทดสอบความแม่นยำนั้นเกิดข้อผิดพลาด จึงมีความจำเป็นที่จะต้องหาเครื่องมือทางเทคนิคอื่นๆ เพื่อทดสอบหาประสิทธิภาพของตลาดหลักทรัพย์ เพื่อเป็นการยืนยันถึงความมีประสิทธิภาพของตลาดหลักทรัพย์ [6] ในการวิจัยครั้งนี้ใช้เครื่องมือเครือข่ายประสาทเทียม เพราะเครือข่ายประสาทเทียมถูกนำมาใช้ในการพยากรณ์ข้อมูลอนุกรมเวลาที่ไม่เป็นเชิงเส้น เนื่องจากแบบจำลองจะไม่สนใจเงื่อนไขความสัมพันธ์ของตัวแปรที่เป็นปัญหาดังที่กล่าวไป สิ่งที่

เครือข่ายประสาทเทียมทำก็คือ ให้ข้อมูลนำเข้าเป็นตัวกำหนดค่าน้ำหนักในระบบและผลลัพธ์ที่จะแสดงออกเอง โดยผ่านกระบวนการเรียนรู้ของระบบ [1] ผู้ที่นำไปใช้เพียงแค่หารูปแบบเครือข่ายที่เหมาะสมที่สุดผ่านการทดลองกับข้อมูลชุดฝึกหัด (Training Data Set) ที่ทำให้ได้ประสิทธิภาพในการพยากรณ์ที่พึงพอใจ เครือข่ายประสาทเทียมเป็นเครื่องมือที่มีประสิทธิภาพในการพยากรณ์ที่มากกว่าตัวแบบทางสถิติอื่นๆ และมีความเหมาะสมที่จะนำมาใช้กับข้อมูลอนุกรมเวลา [2] ซึ่งมีการวิจัยหลายฉบับได้ใช้เครือข่ายประสาทเทียมในการพยากรณ์ในหลายๆ บริบท และมีผลการศึกษาระบุว่า เครือข่ายประสาทเทียมมีความแม่นยำในการพยากรณ์ เช่น ศึกษาเกี่ยวกับตลาดหุ้นไทย [10] พยากรณ์ราคาตลาดหุ้นในประเทศอื่นๆ [11], [12] และศึกษาการพยากรณ์ราคาน้ำมันดิบ [13] นอกจากนี้มีการศึกษาถึงประสิทธิภาพของเครือข่ายประสาทเทียม (Artificial Neural Network, ANNs) เทียบกับแบบจำลองทางสถิติ เช่น GARCH และ ARIMA [14]-[20] ได้ผลสรุปจากงานวิจัยสรุปเหมือนกันว่า เครือข่ายประสาทเทียมมีประสิทธิภาพ ในการพยากรณ์ที่มากกว่าแบบจำลอง GARCH และ ARIMA ดังนั้นผู้วิจัยจึงเลือกเครือข่ายประสาทเทียม โดยจะประยุกต์ใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer Perceptrons, MLP) เนื่องจากเป็นโครงสร้างที่ง่าย มีความยืดหยุ่นสูง และใช้สำหรับงานที่มีความซับซ้อน ได้ผลเป็นอย่างดี สามารถที่จะเรียนรู้และให้ผลตอบสนองที่รวดเร็ว โดยมีกระบวนการฝึกฝนเป็นแบบการเรียนรู้แบบมีการควบคุม (Supervised Learning) และใช้ขั้นตอนการส่งย้อนกลับ (Backpropagation) และมีหลายงานวิจัยที่ใช้ MLP ในบริบทของราคาตลาดหุ้นและทำให้ผลพยากรณ์อยู่ในเกณฑ์ที่ดี [3], [19], [21] เนื่องจากเป็นวิธีที่ง่ายและสามารถประยุกต์ใช้ได้หลากหลาย และมีหลายงานวิจัยที่ใช้วิธี MLP แล้วให้ผลพยากรณ์อยู่ในเกณฑ์ที่ดี ดังนั้นจึงเลือกใช้รูปแบบ MLP ในการพยากรณ์ครั้งนี้

ในการวิจัยนี้มีวัตถุประสงค์เพื่อการวัดประสิทธิภาพ

การพยากรณ์ของแบบจำลองเครือข่ายประสาทเทียม ในตลาดหลักทรัพย์แห่งประเทศไทย โดยใช้ดัชนีราคาหลักทรัพย์แห่งประเทศไทย และเพื่อสร้างตัวแบบเครือข่ายประสาทเทียมที่ดีที่สุดในการพยากรณ์ข้อมูลดัชนีราคาหลักทรัพย์ของตลาดหลักทรัพย์แห่งประเทศไทย โดยจะทำการทดสอบประสิทธิภาพการพยากรณ์ข้อมูลอนุกรมเวลาที่มีความผันผวนสูงโดยใช้เครือข่ายประสาทเทียม ซึ่งเป็นเครื่องมือที่สามารถพยากรณ์ข้อมูลอนุกรมเวลาได้อย่างแม่นยำ

2. วิธีการวิจัย

การศึกษาค้นคว้าเพื่อพยากรณ์ข้อมูลอนุกรมเวลาของแบบจำลองเครือข่ายประสาทเทียม โดยใช้ข้อมูลราคาปิดของ ดัชนีราคาหลักทรัพย์แห่งประเทศไทย (SET Index) แบบรายวัน ในช่วงเดือนมกราคม ปี 2548 ถึงเดือนพฤศจิกายน ปี 2554 รวมทั้งสิ้น 1,672 ข้อมูล โดยแบ่งเป็นสองกลุ่ม ข้อมูลชุดแรก 1 ถึง 1,640 ใช้ในการสร้างแบบจำลองเครือข่ายประสาทเทียม และชุดที่สอง 1,641 ถึง 1,672 ใช้ในการเปรียบเทียบผลพยากรณ์แบบ Out of Sample ใช้โปรแกรม Matlab r2008b ใช้กับ Nnet Tool เพื่อทำ Neural Nets โดยทำการทดสอบลักษณะการเคลื่อนที่แบบสุ่มในข้อมูลกลุ่มตัวอย่าง ทำการแปลงข้อมูลให้อยู่ในรูปของผลตอบแทน และใช้ Variance Ratio Test [7], [22] เพื่อทำการทดสอบ โดยกำหนดให้

$$VR(q) = \frac{Var[r_t(q)]}{q \times Var[r_t(1)]}$$

โดยที่

$VR(q)$ คืออัตราส่วนความแปรปรวน ณ คาบเวลา $t = q$

$Var[r_t(q)]$ คือค่าความแปรปรวน ณ คาบเวลา $t = q$

$Var[r_t(1)]$ คือค่าความแปรปรวน ณ คาบเวลา ที่ $t = 1$

Q คือเลขจำนวนเต็มบวก

กำหนดค่า q ที่ใช้ทดสอบเท่ากับ 2, 4, 8 และ 16 และทดสอบบนพื้นฐานที่ค่าความคลาดเคลื่อนมีความแปรปรวนคงที่ (Homoscedasticity) และแบบความแปรปรวนแต่ละช่วงไม่เป็นค่าคงที่ (Heteroscedasticity) พิจารณาว่า $VR(q)$ ณ แต่ละช่วงเวลาที่ใช้ทดสอบ ถ้าค่า $VR(q)$ มีค่าเท่ากับ 1 จะสรุปได้ว่า ณ ช่วงเวลาที่ทดสอบข้อมูลกลุ่มตัวอย่างมีลักษณะการเคลื่อนที่แบบสุ่มในการฝึกเครือข่ายได้กำหนดตัวแปรของเครือข่ายดังตารางที่ 1 ดังนี้

ตารางที่ 1 แสดงค่าของตัวแปรต่างๆ ที่เลือกใช้ในการฝึกระบบเครือข่ายประสาทเทียม

ตัวแปร	ค่าที่ใช้
Transfer Function ของ Input Layer	Hyperbolic Tangent
Transfer Function ของ Hidden Layer	Hyperbolic Tangent
Transfer Function ของ Output Layer	Pure Linear
Training Algorithm	Back Propagation
Training Function	Gradient Descent with Momentum
Max Validate Fail	6
Epochs	3000
Learning rate	0.01
Initial weight	Initnw
Goal	0.00
Performance	Mean Square Error

ตัวแปรที่ใช้ในการศึกษา 10 ตัวแปรดังตารางที่ 1 เป็นตัวแปรที่ใช้กันเป็นส่วนใหญ่ในบริบทของตลาดหลักทรัพย์ [5], [11], [24] จากตัวแปรดังกล่าวสามารถนำมาใช้ในการพิจารณาและออกแบบเครือข่ายประสาทเทียม โดยจะได้ผลลัพธ์จากการทดลอง และการฝึกระบบ การศึกษาคำนี้สร้างค่าพยากรณ์โดยใช้เครือข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer Perceptions, MLP) แบบ Feed Forward 3 ชั้น ประกอบไปด้วยชั้นนำข้อมูลเข้า ชั้นซ่อนเร้น และชั้นผลลัพธ์ ซึ่งรูปแบบนี้เพียงพอต่อการฝึกให้แก้ปัญหาต่างๆ ได้ [12] และใช้การเรียนรู้แบบแพร่กลับ (Back Propagation) ซึ่งการพิจารณาเลือกฟังก์ชันถ่าย

โอนในชั้นนำข้อมูลเข้าและชั้นซ่อนเร้นพิจารณาจากภาพรวมการฝึกระบบ หากฟังก์ชันที่เลือกใช้ให้ประสิทธิภาพการเรียนรู้ของระบบ (เส้น Train) ที่ดีขึ้นเรื่อยๆ หลังจากผ่านไปหลายรอบการเรียนรู้ (Epochs) โดยมีขั้นตอนดังนี้

1. แบ่งข้อมูลออกเป็น 3 กลุ่มดังตารางที่ 2 ดังนี้

ตารางที่ 2 แสดงจำนวนข้อมูลและสัดส่วนของข้อมูล

ข้อมูล	จำนวนข้อมูล	สัดส่วน (ร้อยละ)
1. Training set	1,312	80
2. Test set	164	10
3. Validation set	164	10

จากตารางที่ 2 แสดงถึงจำนวนข้อมูลในการออกแบบจำลองเครือข่ายประสาทเทียมโดยแบ่งข้อมูลเป็น 3 กลุ่มคือ 1) Training Set จำนวน 1,312 ข้อมูล คิดเป็นร้อยละ 80 ของข้อมูลทั้งหมด 2) Test Set จำนวน 164 ข้อมูล คิดเป็นร้อยละ 10 ของข้อมูลทั้งหมด และ 3) Validation Set จำนวน 164 ข้อมูล คิดเป็นร้อยละ 10 ของข้อมูลทั้งหมด

2. สร้างเครือข่าย จำนวนทั้งสิ้น $n \times h$ เครือข่าย โดยกำหนดให้ จำนวน Input Node เท่ากับ 1, 2, 3, ..., n และในแต่ละชุดของ Input Node มี Hidden Node เท่ากับ 1, 2, 3, ..., h ดังนี้

2.1 พิจารณาจำนวนวันที่จะกำหนดใช้เป็นค่าเพดานของจำนวนนิเวรอนในชั้นนำข้อมูลเข้า (Input Layer) โดยผู้วิจัยกำหนดเพดานของจำนวนนิเวรอนในชั้นนำข้อมูลเข้าให้เป็น 50 เนื่องจากข้อมูลดัชนีราคาหลักทรัพย์จำนวน 1,640 วัน มีความผันผวน รวมถึงข้อจำกัดในการประมวลผล (จำนวนนิเวรอนยิ่งมาก ยิ่งใช้เวลาฝึกนานมากขึ้น) [8]

2.2 กำหนดจำนวนนิเวรอนในชั้นซ่อนเร้น (Hidden Layer) จาก Rule of Thumbs สามารถกำหนดช่วงของจำนวนนิเวรอนได้ดังนี้ กำหนดให้ Input Neural (n) = 50 เพดานของ Hidden Layer = $2 \times n + 1$ [23] มีค่าเท่ากับ 101 นิเวรอน การเลือกแบบจำลองเครือข่ายประสาทเทียมทำโดย เลือกจำนวนนิเวรอนในชั้นนำข้อมูลเข้า (Input Node)

มีค่าเท่ากับ 50 และ จำนวนนิวรอนในชั้นซ่อนเร้น (Hidden Node) มีค่าเท่ากับ 101 รวมจำนวนเครือข่ายที่จะใช้ทดสอบทั้งสิ้น 50×101 เท่ากับ 5,050 เครือข่าย

2.3 กำหนดจำนวนนิวรอนในชั้นข้อมูลผลลัพธ์ (Output Layer) กำหนดตามรูปแบบผลลัพธ์ที่ต้องการ การวิจัยนี้ใช้ผลลัพธ์คือค่าพยากรณ์ 1 วันถัดไป และทำซ้ำจนได้ 32 วัน เพราะฉะนั้นจำนวนนิวรอนในชั้นนี้มีค่าเท่ากับ 1 นิวรอน

3. ฝึกเครือข่ายทั้ง $n \times h$ เครือข่ายด้วยชุด Training Set ในขั้นตอนที่ 1 และทำการคำนวณหา Root Mean Square Error (RMSE) จากการเรียนรู้ โดยใช้ Test Set โดยแต่ละเครือข่ายจะสร้างและฝึกซ้ำ จำนวน 10 ครั้ง เพื่อหาค่า RMSE ที่ต่ำที่สุด

4. เลือกเครือข่ายที่ค่า RMSE ต่ำที่สุด 5 อันดับ จากการคำนวณในขั้นตอนที่ 3


5. นำเครือข่ายจากขั้นที่ 4 มาทำการฝึกใหม่โดยกำหนดค่าตั้งต้นให้กับเครือข่ายทั้ง 5 และฝึกระบบใหม่อีกครั้งพร้อมทั้งให้เครือข่ายทั้ง 5 พยากรณ์ข้อมูลกลุ่มนอกเหนือจากกลุ่มตัวอย่าง (Out of Sample) จำนวน 32 วัน โดยนำค่าที่พยากรณ์ได้แล้วนำกลับมาใช้พยากรณ์วันถัดไป ทำซ้ำจนครบ 32 วัน

6. ทำการพยากรณ์ข้อมูลจำนวน 32 วัน ของแต่ละเครือข่าย

7. เปรียบเทียบค่า MAPE ของทั้ง 5 เครือข่าย เพื่อหาเครือข่ายที่ให้ค่า MAPE ต่ำที่สุด

3. ผลการวิจัย

จากการฝึกระบบเครือข่ายประสาทเทียม โดยพิจารณาฟังก์ชันอัลกอริทึมในการปรับค่าน้ำหนักจากรูปที่ 1 พบว่า Gradient Descent with Momentum ให้ผลการฝึกระบบที่ดีกว่าอัลกอริทึม Gradient Descent with Adaptive Learning Rate (Traingda), Levenberg-Marquardt (Trainlm) เพราะเส้น Train จะมีแนวโน้มที่ลดลงช้ากว่า รวมทั้งจะพบการสิ้นสุดการเรียนรู้แบบ Maximum Validation Fail Reach ซึ่งเป็นผลมาจาก



รูปที่ 1 กราฟแสดงค่า Gradient ที่ถูกปรับ และ Validation Fail Count ในการเรียนรู้ของระบบ

ระบบไม่ได้เรียนรู้อะไรเพิ่มเติมขึ้นเลยหลังจากฝึกระบบไปแล้วหลายรอบ และสำหรับค่า Epochs และ Learning Rate ก็พิจารณาเช่นเดียวกัน หลังจาก Epochs ที่ 3,000 ขึ้นไป ระบบจะเรียนรู้ได้น้อยมาก เพราะเส้น Train ความชันที่ลดลงอย่างมาก ทำให้ตัดการเรียนรู้ในรอบหลังจาก 3,000 ออกได้ รวมถึงงานวิจัยนี้ใช้ฟังก์ชันถ่ายโอนแบบ Hyperbolic Tangent Sigmoid Function ซึ่งให้ผลลัพธ์ที่ดีกว่าแบบ Logarimric Sigmoid Function

เมื่อทำการฝึกเครือข่ายเสร็จสิ้นทั้ง 5,050 เครือข่าย ระบบจะให้ค่า Mean Square Error ที่ได้จากการนำข้อมูลกลุ่ม Test มาทำการพยากรณ์ (In Sample) ซึ่งผู้วิจัยทำการแปลงให้เป็น Root Mean Square Error (RMSE) จากนั้นเลือกเครือข่าย 5 ตัวที่ให้ค่า RMSE ต่ำที่สุดแล้วทำการฝึกระบบใหม่อีกครั้งพร้อมทั้งให้เครือข่ายทั้ง 5 พยากรณ์ข้อมูลกลุ่มนอกเหนือจากกลุ่มตัวอย่าง (Out of Sample) จำนวน 32 วัน โดยนำค่าที่พยากรณ์ได้แล้วนำกลับมาใช้พยากรณ์วันถัดไป ทำซ้ำจนครบ 32 วัน และเปรียบเทียบค่า MAPE ของทั้ง 5 เครือข่ายดังตารางที่ 3

โดยมีรูปแบบสมการ MAPE และสมการ RMSE ดังนี้

$$MAPE = \sum_{i=1}^n \left| \left(\frac{a_i - p_i}{a_i} \right) * 100 \right| / n$$

โดยที่

n คือจำนวนค่าพยากรณ์ที่ทำการเปรียบเทียบ
ในที่นี้คือ 32

a_i คือค่าจริง ณ เวลาที่ i

p_i คือค่าที่แบบจำลองพยากรณ์ได้ ณ เวลาที่ i

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2}$$

โดยที่

Y_t^s คือค่าประมาณจากแบบจำลอง

Y_t^a คือค่าที่แท้จริง

T คือจำนวนเวลาที่ใช้ในการประมาณแบบจำลอง

ตารางที่ 3 แสดงค่า RMSE และ MAPE ของ 5 เครือข่าย
ที่ให้ผลทดสอบที่ดีที่สุด

เครือข่าย	RMSE	MAPE
27-50-1	0.1157	2.2926
45-60-1	0.1247	2.3003
48-42-1	0.0834	2.7125
47-49-1	0.1151	2.7666
45-47-1	0.0771	2.7786

จากผลการศึกษาพบว่าแบบจำลองเครือข่ายประสาทเทียมสามารถพยากรณ์ได้มีประสิทธิภาพสูงเนื่องจากเป็นแบบจำลองแบบไม่ใช้พารามิเตอร์ (Non-Parametric) โดยใช้หลักการเรียนรู้ของแบบจำลองในการสร้างความสัมพันธ์ของค่าน้ำหนักและโครงสร้างภายในเครือข่าย ซึ่งมีความยืดหยุ่นและมีประสิทธิภาพในการสร้างความสัมพันธ์ของข้อมูลที่มีความผันผวนมากซึ่งยากต่อการหาความสัมพันธ์ทางสถิติ แต่จากการศึกษาครั้งนี้ยังพบว่าในการสร้างแบบจำลองเครือข่ายประสาทเทียม มีเงื่อนไขหลายประการที่มาจากทดลองเช่นจำนวนชั้นในเครือข่ายควรเริ่มเครือข่ายลักษณะ 1 ชั้นนำเข้า 1 ชั้นซ่อนเร้น และ 1 ชั้นนำข้อมูลออก เพราะสามารถเรียนรู้ปัญหาต่างๆ ได้มากมาย จึงควรเริ่มที่เครือข่ายแบบนี้ก่อน แต่เมื่อต้องการเพิ่มจำนวนนิวรอนในชั้น

ซ่อนเร้นให้มากขึ้น เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ก็ควรที่จะเพิ่มจำนวนชั้นในชั้นซ่อนเร้นแทน เพื่อลดปัญหา Overfitting ที่เกิดได้ง่ายขึ้น และลดเวลาประมวลผลลงได้มาก เนื่องจากการที่มีจำนวนนิวรอนในชั้นซ่อนเร้นมากแต่มีเพียงชั้นซ่อนเร้นเดียว จะใช้เวลาประมวลผลที่มากกว่ารวมถึงจำนวนนิวรอนในชั้นนำข้อมูลเข้า นอกจากนี้จากการศึกษาของ [24] ระบุว่าใช้จำนวนข้อมูลนำเข้า (200-500) และจำนวนชั้นซ่อนเร้นที่มากเกินไป (ใช้ 84-1,500) แต่มีจำนวนรอบการศึกษาเพียง 500 รอบซึ่งไม่เพียงพอต่อการเรียนรู้ของโครงข่ายประสาทเทียมทำให้เกิดปัญหารบกวน (Noise) ของข้อมูลในอดีตซึ่งรบกวนการพยากรณ์ข้อมูลในอนาคตทำให้ได้ความแม่นยำต่ำลง ขณะที่ [13] ใช้จำนวนข้อมูลนำเข้าเพียง 10 ค่า จำนวนชั้นซ่อนเร้น 200 ชั้นจะให้ผลการพยากรณ์ โดยเฉลี่ยที่แม่นยำกว่า [21], [24] ซึ่งงานวิจัยนี้ จึงมีการกำหนด Input 50 และชั้นซ่อนเร้นเพียง 101 ซึ่งทำให้ค่า MAPE มีในระดับที่ต่ำ ดังนั้นไม่ควรกำหนดชั้นซ่อนเร้นที่มากเกินไป รวมถึงควรพิจารณาจากลักษณะข้อมูลที่จะใช้ เนื่องจากจำนวนนิวรอนที่น้อยเกินไปจะไม่สามารถหาความสัมพันธ์ที่ซ่อนอยู่ในข้อมูลได้ แต่ถ้ามากเกินไปจะทำให้นิวรอนที่เกิดขึ้นจะรบกวนการเรียนรู้ของระบบในรูปแบบของคลื่นรบกวน (Noise) นอกจากนี้การแปลงข้อมูลก่อนนำเข้าก็เป็นสิ่งสำคัญ ควรให้เลือกแปลงให้สอดคล้องกับฟังก์ชันเคลื่อนย้าย (Transfer Function) ในชั้นนำข้อมูลเข้า เช่นงานวิจัยนี้ใช้ Hyperbolic Tangent ซึ่งมีค่าเป็น [-1, 1] ผู้วิจัยจึงแปลงข้อมูลดัชนีราคาให้อยู่ในรูป [-1, 1] ก่อน

4. สรุป

งานวิจัยนี้เป็นพยากรณ์ข้อมูลอนุกรมเวลา โดยใช้เครือข่ายประสาทเทียมในการพยากรณ์ กลุ่มตัวอย่างที่ใช้คือ ดัชนีราคาหลักทรัพย์รายวันของตลาดหลักทรัพย์แห่งประเทศไทย ตั้งแต่วันที่ 4 มกราคม 2548 ถึง 7 พฤศจิกายน 2554 รวมจำนวนทั้งสิ้น 1,672 วัน ซึ่งผู้วิจัยได้ทำการแบ่งข้อมูลออกเป็น 2 กลุ่ม คือ 1,640 วันแรก ใช้สำหรับสร้างแบบจำลองและ 32 วันที่เหลือ ใช้สำหรับให้แบบ

จำลองสร้างค่าพยากรณ์ขึ้นมาเปรียบเทียบความแม่นยำ โดยการพยากรณ์ข้อมูลทั้ง 32 วันนี้เป็นกรพยากรณ์แบบ Out of Sample และผลการพยากรณ์ของวันที่ y_t จะถูกนำไปพยากรณ์ข้อมูลของวันที่ y_{t+1} ทำซ้ำไปเรื่อยๆ จนครบ 32 วัน จากนั้นหาค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) ของแต่ละแบบจำลองเพื่อใช้วัดประสิทธิภาพของแบบจำลองนั้นๆ โดยแต่ละส่วนของการวิจัยสามารถสรุปได้ดังนี้

เครือข่ายประสาทเทียม ผู้วิจัยได้ทำการทดลองเลือกเครือข่ายในลักษณะจำกัดขนาดของเครือข่าย เนื่องด้วยระยะเวลาในการประมวลผล โดยเลือกจากแบบจำลองที่ให้ค่า MAPE ต่ำที่สุด ทำให้ได้แบบจำลองที่เหมาะสมที่สุดภายใต้ข้อจำกัด คือ 27-50-1, 45-60-1, 48-42-1, 47-49-1 และ 45-47-1 ซึ่งให้ค่า MAPE เท่ากับ 2.2926, 2.3003, 2.7125, 2.7666 และ 2.7786 ตามลำดับ ซึ่งบางงานวิจัยพบว่า เครือข่ายประสาทเทียมจะมีประสิทธิภาพในการพยากรณ์ข้อมูลแบบ Out of Sample ในระยะยาว [16], [18] ซึ่งสอดคล้องกับผลของงานวิจัยในครั้งนี้ แต่เมื่อพิจารณา งานวิจัยที่ผ่านมา มีบางงานวิจัยให้ผลการพยากรณ์จากแบบจำลองเครือข่ายประสาทเทียมไม่แม่นยำ [8] เนื่องมาจากการออกแบบจำลองที่ใช้ตัวข้อมูลซ้อนแน่นมากเกินไป จึงทำให้เกิดปัญหา Overfitting แต่ในการศึกษาครั้งนี้มีการทดสอบใช้ข้อมูลซ้อนแน่น 1 ชั้น ซึ่งทำให้ผู้วิจัยสามารถทราบปัญหาที่เกิดขึ้นได้ง่ายกว่าการใช้ตัวซ้อนแน่นหลายชั้น

เอกสารอ้างอิง

- [1] B. Lebaron and A.S. Weigend, "A Bootstrap Evaluation of The Effect of Data Splitting on Financial Time Series," *IEEE Transactions on Neural Networks*, vol. 2, pp. 213-220, 1998.
- [2] R. Frank, N. Davey, and S. Hunt, "Time series prediction and neural networks," *Journal of Intelligent and Robotic Systems*, vol. 31, no. 1, pp. 91-103, 1999.
- [3] D. Goutam et al., "Artificial neural network models for forecasting stock price index in the Bombay stock exchange," *Journal of Emerging Market Finance December*, vol. 1, no. 5, pp. 207-215, 2006.
- [4] S. Basu, "Investment performance of common stocks in relation to their price-earnings ratios: a test of the efficient market hypothesis," *The Journal of Finance*, vol. 32, no. 3, pp. 663-682, 1977.
- [5] J. J. Laffont and E.S Maskin, "The efficient market hypothesis and insider trading on the stock market," *Journal of Political Economy*, vol. 98, no. 1, pp. 70-93, 1990.
- [6] A. Timmermann and C.W.J. Granger, "Efficient Market Hypothesis and Forecasting," *International Journal of Forecasting*, vol. 20, pp. 15-27, 2004.
- [7] M. B. Righi and P.S. Ceretta, "Random walk and variance ratio tests for efficiency in the sub-prime crisis: evidence for the U.S. and Latin markets," *International Research Journal of Finance and Economics*, no. 72, pp. 25-32, 2011.
- [8] S. Chancharat, A.R. Kamalian, and A. Valadkhani, "Random walk and multiple structural breaks in Thai stock market," *Empirical Economics Letters*, vol. 8, no. 5, pp. 501-506, 2009.
- [9] Y. Jingtao and H.L. Poh, "Forecasting the klse index using neural networks," *IEEE International Conference*, vol. 2, pp. 1012-1017, 1995.
- [10] N. Chancharat, K. Sektrakul, and S. Chancharat, "Examining the market efficiency of the Thai stock market: SUE, P/E and B/M anomalies models," *Journal of Accountancy and Management*, vol. 1, no.1, pp. 1-21, 2009 (in Thai).
- [11] R.K. Dase and D.D. Pawar, "Application of artificial neural network for stock market



- predictions: a review of literature,” *International Journal of Machine Intelligence*, vol. 2, no. 2, pp. 14-17, 2010.
- [12] S. Soni, “Applications of anns in stock market prediction: a survey,” *International Journal of Computer Science and Engineering Technology*, vol. 2, no. 3, pp. 71-83, 2011.
- [13] K. Suriya, *Forecasting Crude Oil Price using Neural Networks*, Chiang Mai: Chiang Mai University, 2003 (in Thai).
- [14] C. Brook and S. Tsolacos, “International evidence on the predictability of prices of securitised real estate assets: econometric models versus neural networks,” *Journal of Property Research*, vol. 20, no. 2, pp. 133-156, 2003.
- [15] P. Siripanich, “Time series forecasting using a combined ARIMA and artificial neural network model,” M.Sc. Thesis, Silpakorn University, 2007 (in Thai).
- [16] A. Carvalhal and T. Ribeiro, “Do artificial neural networks provide better forecasts? evidence from latin American stock indexes,” *Latin American Business Review*, vol. 8, no. 3, pp. 92-100, 2007.
- [17] A.F. Darrat and M. Zhong, “On Testing The Random Walk Hypothesis: A Model-Comparison Approach,” *Financial Review*, vol. 35, no. 3, pp.105-124, 2000.
- [18] G.P. Zhang and B. Patuwo, “A cross validation analysis of neural network out-of-sample performance in exchange rate forecasting,” *Decision Science*, vol. 30, no. 1, pp. 197-216, 1998.
- [19] R.G. Donaldson and M. Kamstra, “An artificial neural network-GARCH model for international stock return volatility,” *Journal of Empirical Finance*, vol. 4, no. 1, pp 17-46, 1997.
- [20] M. Bildirici and O.O. Ersin, “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*, vol. 36, no. 4, pp 7355-7362, 2009.
- [21] E. Hadavandi, H. Shavandi and A. Ghanbari, “Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting,” *Knowledge-Based Systems*, vol. 23, no. 8, pp. 800-808, 2010.
- [22] A.W. Lo and A.C. Mackinlay, “Stock Market Prices do not Follow Random Walks: Evidence from A Simple Specification Test,” *Review of Financial Studies*, vol. 1, no. 1, pp. 41-66, 1988.
- [23] R.N. Hecht, “Counterpropagation networks,” *Applied Optics*, vol. 26, no. 23, pp. 4979-4984, 1987.
- [24] J. Tunsenee, “Accuracy comparison in securities price forecasting between neural networks model and EGARCH-M ARIMA model,” M.Econ. Thesis, Chiang Mai University, 2006 (in Thai).