



การทำนายราคาหลักทรัพย์โดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

โดยใช้ตัวแบบอนุกรมเวลาฟังก์ชันแบบไม่เชิงเส้น

FORECASTING STOCK PRICE USING BACKPROPAGATION ALGORITHM

AND NONLINEAR AUTOREGRESSIVE EXOGENOUS MODEL (NARX)

วสันต์ ศิลปะ¹ สมพร ปันโกษา² และ บำรุง พ่วงเกิด³

¹ สาขาวิศวกรรมการเงิน คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยหอการค้าไทย

126 / 1 ถ.วิภาวดีรังสิต ดินแดง กรุงเทพมหานคร 10400 E-mail: mark_AI01@hotmail.com

² สาขาวิศวกรรมการเงิน คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยหอการค้าไทย

126 / 1 ถ.วิภาวดีรังสิต ดินแดง กรุงเทพมหานคร 10400 E-mail: somporn_pun@utcc.ac.th

³ ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

1 ซอยฉลองกรุง 1 เขตลาดกระบัง กรุงเทพมหานคร 10520 E-mail: bumroong.pu@kmitl.ac.th

บทคัดย่อ

การวิเคราะห์หลักทรัพย์โดยใช้ปัจจัยพื้นฐานเป็นวิธีการหนึ่งที่น่าสนใจในปัจจุบัน แต่การวิเคราะห์ดังกล่าวขึ้นอยู่กับประสิทธิภาพของผู้วิเคราะห์ อาจมีความไม่แน่นอนและความลำเอียง และเนื่องจากในปัจจุบันมีความนิยมนำโครงข่ายประสาทเทียมมาประยุกต์ใช้ในหลากหลายสาขาวิชาชีพมากขึ้น ฉะนั้นจึงเป็นที่น่าสนใจในการประยุกต์ใช้โครงข่ายประสาทเทียม ในการทำนายราคาหุ้นโดยใช้ปัจจัยพื้นฐาน

จุดประสงค์ของการศึกษาอิสระครั้งนี้คือการใช้โครงข่ายประสาทเทียมในการทำนายราคาหุ้น โดยใช้ปัจจัยพื้นฐาน ของบริษัท ปูนซิเมนต์ไทย จำกัด(มหาชน) (SCC) เนื่องจากเป็นบริษัทที่อยู่ในตลาดหุ้นมาอย่างยาวนาน มีข้อมูลเพียงพอสำหรับการฝึกและทดสอบในโครงข่ายประสาทเทียม โดยใช้อัตราส่วนทางการเงิน และตัวเลขทางสถิติในงบการเงิน โดยแบ่งข้อมูลเป็นสองชุดคือ ชุดข้อมูลฝึก 80% และชุดข้อมูลทดสอบ 20% และนำมาฝึกโดยใช้ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้นและใช้ Levenberg-Marquardt Algorithm สำหรับปรับค่าความคลาดเคลื่อนในโครงข่าย

จากการศึกษาพบว่าตัวแบบอนุกรมเวลาฟังก์ชันแบบไม่เชิงเส้นดังกล่าวมีความสามารถในการทำนายราคาหุ้นโดยโครงข่ายที่เหมาะสมมีสองชั้นซ่อน ชั้นซ่อนที่ 1 มี 22 โหนด ชั้นซ่อนที่ 2 มี 1 โหนด โดยมีความคลาดเคลื่อนกำลังสองเฉลี่ย ในชุดข้อมูลฝึกโครงข่ายประสาทเทียมอยู่ที่ 0.0195 และชุดข้อมูลทดสอบโครงข่ายประสาทเทียมอยู่ที่ 0.0087 สามารถใช้ประยุกต์โดยใช้ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้นในการทำนายราคาหุ้นโดยใช้ปัจจัยพื้นฐานได้ในสถานการณ์จริง

คำสำคัญ: การแพร่ย้อนกลับ, การวิเคราะห์หลักทรัพย์โดยใช้ปัจจัยพื้นฐาน, โครงข่ายประสาทเทียม



ABSTRACT

Nowadays, fundamental analysis is one of the most popular methods. This is depending on the analyst's experience which can make the biased analysis. Artificial neural networks are the most widely used in various careers. Therefore, it is interesting to use Artificial neural networks for stock price prediction.

The aim of this study is to use artificial neural networks for prediction of The Siam Cement PCL. (SCC) stock price by using fundamental analysis. This is because this company stays in the stock market for long periods. Moreover, the company has enough data to test in artificial neural networks using financial ratio and financial statement. In this study, data were separated into two groups; 80% training data and 20% testing data. These data were tested by using non-linear time series analysis and Levenberg-marquardt algorithm for error adjustment of the network.

The results show that non-linear time series analysis can be employing for predicting the stock price by the best network which had two hidden layers. The first hidden layer has 22 nodes and the second one has 1 node. Mean squared error (MSE) of training data and testing data were 0.0195 and 0.0087, respectively. Therefore, non-linear time series analysis can be used to predict stock price in real situation by using fundamental analysis.

Keywords: Backpropagation, Fundamental analysis, Artificial Neural Network


1. บทนำ

ตลาดหลักทรัพย์เป็นสถานที่แห่งโอกาสที่ได้รับประโยชน์จากการลงทุน โดยผ่านบริษัทต่างๆ แต่ในการลงทุนนั้นเป็นเรื่องยากในการคาดการณ์ว่าสินทรัพย์ที่เลือกลงทุน มีราคาเหมาะสมที่ลงทุนหรือไม่ เนื่องจากไม่มีกฎหรือวิธีการที่แน่นอนในการทำนายราคาหุ้น จึงมีหลายๆวิธีที่ถูกนำมาใช้ในการทำนายราคาหุ้น การวิเคราะห์หลักทรัพย์โดยใช้ปัจจัยพื้นฐาน (Fundamental Analysis) เป็นหนึ่งในวิธีที่นิยมใช้ในการวิเคราะห์มูลค่าของบริษัทต่างๆในตลาดหลักทรัพย์ ซึ่งเป็นการวิเคราะห์หาราคาหุ้นจากสถานะเศรษฐกิจ อุตสาหกรรม และสถานะทางการเงินของบริษัท เพื่อหามูลค่าที่แท้จริงของหลักทรัพย์ (Intrinsic Value) ซึ่งเป็นวิธีการหนึ่งที่นิยมใช้ในปัจจุบัน แต่การวิเคราะห์ด้วยวิธีนี้ ต้องอาศัยประสบการณ์ของผู้วิเคราะห์เอง ซึ่งอาจมีความไม่แน่นอน และอาจมีความลำเอียงจากผู้วิเคราะห์เอง นอกจากนี้ผู้วิเคราะห์แต่ละคนมีมุมมองต่อบริษัท ความเข้าใจต่อธุรกิจแต่ละประเภท และข้อมูลที่แตกต่างกัน จึงเป็นผลให้การวิเคราะห์ของนักวิเคราะห์แต่ละคนแตกต่างกัน แม้วิเคราะห์บริษัทเดียวกัน และมีข้อมูลที่เท่ากันก็ตาม

เนื่องจากปัจจุบัน การเรียนรู้ของเครื่อง (Machine Learning) กำลังเป็นที่นิยมอย่างมาก อันเนื่องมาจากเทคโนโลยีในปัจจุบันที่ก้าวหน้าขึ้นมาก คอมพิวเตอร์สามารถประมวลผลได้รวดเร็วมากขึ้น การเรียนรู้ของเครื่องจึงเริ่มมีบทบาทต่อมนุษย์มากขึ้น เนื่องจากความสามารถในหาความสัมพันธ์ในข้อมูลที่ซับซ้อน และมีความสามารถตัดสินใจภายใต้ข้อมูลปริมาณมหาศาลได้ ปัจจุบันได้มีการนำไปประยุกต์ใช้ในหลากหลายสาขาอาชีพไม่ว่าเป็นการแพทย์ วิศวกรรม วิทยาศาสตร์ ประกันภัย การตลาด การเงินการธนาคาร เป็นต้น ฉะนั้นจึงมีความน่าสนใจในการประยุกต์ใช้โครงข่ายประสาทเทียม ในการทำนายราคาหุ้นจากตัวแปรที่ใช้ในการวิเคราะห์หลักทรัพย์โดยใช้ปัจจัยพื้นฐาน โดยหาความสัมพันธ์ระหว่างตัวแปร ทางเศรษฐกิจ อุตสาหกรรม และสถานะทางการเงินของบริษัท

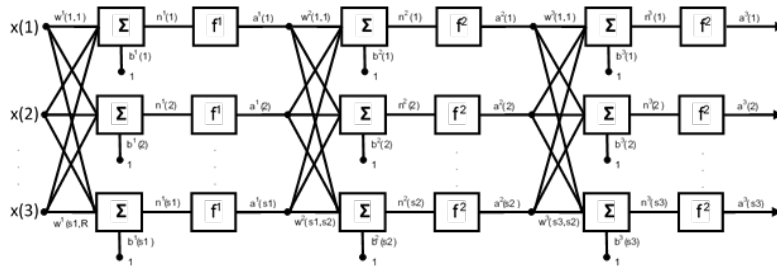


โครงข่ายประสาทเทียม (Artificial Neural Network : ANN) เป็นหนึ่งวิธีในศาสตร์การเรียนรู้ของเครื่อง ซึ่งเป็นการจำลองการทำงานของเซลล์ประสาท (Neural) ของสิ่งมีชีวิตสามารถนำไปประยุกต์ใช้ได้อย่างหลากหลาย เช่น ใช้หาความสัมพันธ์ที่ซ่อนอยู่ในข้อมูลที่ซับซ้อนในการทำเหมืองข้อมูล (Data mining) ตลอดจนการประยุกต์ใช้ในงานด้านการจดจำรูปแบบ (Pattern recognition) ซึ่งแนวคิดดังกล่าวเริ่มจากการพัฒนาเพอร์เซปตรอน (Perceptron) (ภาพที่ 1) ซึ่งเป็นโครงข่ายประสาทเทียมชนิดหนึ่งในปี ค.ศ. 1957 โดย แฟรงค์ โรเซนบลัทท์ แต่ไม่ค่อยได้รับความนิยมมากในขณะนั้น เพราะสามารถเรียนรู้ได้แค่ปัญหาเชิงเส้นเท่านั้น จากนั้นจึงมีการพัฒนาเรื่อยมาจนได้ Feedforward neural network หรือเรียกกันว่า Multilayer perceptron ซึ่งมีประสิทธิภาพมากกว่าเพอร์เซปตรอนชั้นเดียว และปัจจุบันที่เทคโนโลยีก้าวหน้าขึ้นมากเมื่อเทียบกับในอดีต จึงทำให้โครงข่ายประสาทเทียม เริ่มได้รับการยอมรับมากขึ้น



ภาพที่ 1 แผนภาพแสดงการทำงานของเพอร์เซปตรอนอย่างง่าย

โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation) คือ โครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Feedforward network) (ภาพที่ 2) ที่นิยมใช้กันอย่างกว้างขวางในปัจจุบัน ใช้ประมาณความสัมพันธ์แบบไม่เชิงเส้น (non-linear relationship) ระหว่าง input และ output โดยการปรับน้ำหนักของชั้นนำเข้า ประกอบด้วย ชั้นตอนหลัก สองชั้นตอนคือ feedforward และ Backpropagation กระบวนการ feedforward เริ่มจากการ นำข้อมูลนำเข้ากระจายไปตามชั้นต่างๆ ทุกๆ โหนดทั่วโครงข่าย จนได้ข้อมูลนำออก และนำข้อมูลดังกล่าวมาเปรียบเทียบกับค่าจริง ได้ค่าความคลาดเคลื่อนที่คำนวณในแต่ละโหนดของข้อมูลนำออก จากนั้น ค่าความคลาดเคลื่อนจะย้อนกลับไปปรับน้ำหนักของแต่ละโหนด ในแต่ละชั้นจนจนได้ค่าความคลาดเคลื่อน ของชั้นนำออกเมื่อเทียบกับค่าจริงค่าที่สูงสุดด้วยวิธีการที่เรารู้จักว่า delta rule หรือ gradient descent (Papagelis & Kim, 2017)



ภาพที่ 2 โครงข่ายประสาทเทียมแบบหลายชั้น (Hagan and Menhaj, 1994)

ในการศึกษาค้นคว้าครั้งนี้ทำการศึกษาโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation) โดยใช้ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้น (Nonlinear Autoregressive Exogenous Model : NARX) เนื่องจากเป็นโครงข่ายพื้นฐานที่ง่ายต่อความเข้าใจ ไม่ซับซ้อน เป็นการเรียนรู้แบบต้องมีผู้สอน (Supervised Learning) ซึ่งในการทำนายต้องอาศัยข้อมูลในการฝึก และสามารถใช้สำหรับงานที่มีความซับซ้อน ได้ผลเป็นอย่างดี โดยใช้ข้อมูลราคาของหุ้นบริษัทปูนซิเมนต์ไทย จำกัด(มหาชน) (SCC) เนื่องจากเป็นหุ้นที่อยู่ในตลาดมาอย่างยาวนาน มีข้อมูลมากพอที่ใช้ศึกษา และเป็นหุ้นพื้นฐานดี และเนื่องจากการใช้อัตราส่วนทางการเงินมีความจำเพาะในแต่ละอุตสาหกรรม นอกจากนี้โครงสร้างภายในบริษัทที่มีความจำเพาะ ฉะนั้นจะส่งผลให้น้ำหนักของโครงข่ายในหุ้นแต่ละตัว และจำนวนโหนดในแต่ละชั้นซ่อนที่ให้การทำนายที่เหมาะสมจะไม่เหมือนกัน จากนั้นนำไปเปรียบเทียบกับค่าทำนายกับค่าจริงเพื่อหาความแม่นยำของแบบจำลองต่อไป

2. วัตถุประสงค์การวิจัย

1. เพื่อศึกษาการทำงานของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับในอนุกรมเวลา ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้น
2. เพื่อเปรียบเทียบชั้นของโครงข่ายโครงข่ายประสาทเทียมที่เหมาะสม และมีประสิทธิภาพในการทำนายราคาหุ้น โดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้น และนำไปเปรียบเทียบกับค่าทำนายกับค่าจริงเพื่อหาความแม่นยำของแบบจำลอง

3. การดำเนินการวิจัย

การทำการศึกษาค้นคว้าด้วยตนเองครั้งนี้ ในการคัดเลือกข้อมูลที่น่าสนใจในการศึกษา ใช้ข้อมูลทุติยภูมิรายไตรมาสของราคาหุ้น ตัวเลขทางการเงิน อัตราส่วนทางการเงิน ในงบแสดงสถานะทางการเงิน โดยมีตัวแปรอิสระที่ใช้สำหรับการศึกษาดังนี้ (ตาราง 1)

ตาราง 1 ค่าทางสถิติและอัตราส่วนทางการเงิน

Financial Ratio		
Liquidity Ratio	Leverage Ratio	Profitability Ratio
Current Ratio	D/E Ratio	Gross Profit Margin
Quick Ratio	Interest Coverage ratio	Net Profit Margin
		Return on Asset
		Return on Equity



ตาราง 1 ค่าทางสถิติและอัตราส่วนทางการเงิน (ต่อ)

Financial Ratio	Financial Data	Economic
Activity Ratio		
Accounts Receivable Turnover	Cash	Gross Domestic Product
Average Collection Period	Total Assets	
Fixed Asset Turnover	Current Liabilities	
Inventory Turnover	Total Liabilities	
Average Sale Period	Equities	
Total Asset Turnover	Sales	
	Revenue	
	Cost of Sales	
	EBIT	
	Interest Expenses	
	Net Profit	
	EPS	

1) นำข้อมูลของตัวเลขทางการเงิน อัตราส่วนทางการเงิน ในงบแสดงสถานะทางการเงิน และตัวแปรทางเศรษฐกิจศาสตร์แต่ละตัวแปลใน (ตาราง 1) ที่ได้จากฐานข้อมูล

2) ทำอัตราการเปลี่ยนแปลงและทำให้อยู่ในรูปทศนิยม

3) แบ่งข้อมูลออกเป็น ข้อมูลใช้สำหรับการฝึก 80% และข้อมูลใช้ในการทดสอบ 20%

4) ทำข้อมูลให้อยู่ในรูปเมทริกซ์ จึงได้เมทริกซ์สำหรับการฝึกและทดสอบในโครงข่ายประสาทเทียมดังนี้

เมทริกซ์ข้อมูลตัวแปลนำเข้าสำหรับการฝึกขนาด $31 \times n$ เมื่อ n คือจำนวนของข้อมูล 80% ที่ใช้ในการฝึก

เมทริกซ์ข้อมูลตัวแปลนำเข้าสำหรับชุดตัวอย่างทดสอบ $31 \times m$ เมื่อ m คือจำนวนของข้อมูล 20% ที่ใช้ในการทดสอบ

เมทริกซ์ข้อมูลตัวแปลนำออกสำหรับการฝึกขนาด $1 \times n$ เมื่อ n คือจำนวนของข้อมูล 80% ที่ใช้ในการฝึก

เมทริกซ์ข้อมูลตัวแปลนำออกสำหรับชุดตัวอย่างทดสอบ $1 \times m$ เมื่อ m คือจำนวนของข้อมูล 20% ที่ใช้ในการทดสอบ

โดยข้อมูลนำเข้าและนำออก 80% ที่ใช้สำหรับการฝึกอยู่ในช่วง ไตรมาสที่ 1 ในปี 1998 จนถึง ไตรมาสที่ 4 ในปี 2012 และข้อมูลนำเข้าและนำออก 20% ที่ใช้สำหรับการทดสอบ อยู่ในช่วง ไตรมาสที่ 1 ในปี 2013 จนถึง ไตรมาสที่ 4 ในปี 2016



การสร้างแบบจำลองโครงข่ายประสาทเทียม ใช้ข้อมูลที่แบ่งสำหรับการฝึก นำไปฝึกในโครงข่ายประสาทเทียมโดยใช้ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้น (Nonlinear Autoregressive Exogenous Model : NARX) โดยกำหนดพารามิเตอร์ (Parameter) สำหรับอัลกอริทึม (Algorithm) สำหรับการสร้างแบบจำลองโครงข่ายประสาทเทียมดังนี้

- 1.) ใช้โครงข่าย series-parallel architecture โดยใช้ค่าจริงแทนการใช้ feedback loop ในการประมาณค่า output
- 2.) ฟังก์ชันกระตุ้นในโครงข่ายประสาทเทียมใช้ (activation function) เป็น Hyperbolic tangent sigmoid transfer function
- 3.) ในการคำนวณค่าความผิดพลาดใช้วิธี Levenberg-Marquardt backpropagation

Levenberg-Marquardt algorithm สมการคล้ายคลึงกับ วิธี Newton methods ในขณะที่ backpropagation เป็นกระบวนการหาค่าความลาดชันต่ำสุด Marquardt-Levenberg algorithm คือกระบวนการที่ใช้ประมาณการวิธีของ Newton's method สมมุติว่ามีฟังก์ชัน $V(\bar{x})$ ต้องการหาค่าต่ำที่สุดของพารามิเตอร์ของเวกเตอร์ \bar{x} ฉะนั้น ได้รูปแบบสมการ Newton's method ดังนี้

$$\square \bar{x} = -[\nabla^2 V(\bar{x})]^{-1} \nabla V(\bar{x})$$

โดย $\nabla^2 V(\bar{x})$ เป็น Hessian matrix และ $\nabla V(\bar{x})$ คือ Gradient ถ้าให้ $V(\bar{x})$ คือ ค่าความผิดพลาดกำลังสอง (Mean squared error : MSE)

$$V(\bar{x}) = \sum_{i=1}^N e_i^2(\bar{x})$$

ฉะนั้น สามารถเขียนเป็นสมการ Hessian Gradient ได้ดังนี้

$$\nabla V(\bar{x}) = J^T(\bar{x}) \bar{e}(\bar{x})$$

$$\nabla^2 V(\bar{x}) = J^T(\bar{x}) J(\bar{x})$$

เมื่อ $J^T(\bar{x})$ คือ Jacobian matrix

$$J(\bar{x}) = \begin{bmatrix} \frac{\partial e_1(\bar{x})}{\partial x_1} & \frac{\partial e_1(\bar{x})}{\partial x_2} & \dots & \frac{\partial e_1(\bar{x})}{\partial x_n} \\ \frac{\partial e_2(\bar{x})}{\partial x_1} & \frac{\partial e_2(\bar{x})}{\partial x_2} & \dots & \frac{\partial e_2(\bar{x})}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(\bar{x})}{\partial x_1} & \frac{\partial e_N(\bar{x})}{\partial x_2} & \dots & \frac{\partial e_N(\bar{x})}{\partial x_n} \end{bmatrix}$$

และ

$$S(\bar{x}) = \sum_{i=1}^N e_i(\bar{x}) \nabla^2 e_i(\bar{x})$$



จากสมการ Gauss-Newton เมื่อให้ $S(\bar{x}) \approx 0$ ได้สมการดังนี้

$$\square \bar{x} = [J^T(\bar{x})J(\bar{x})]^{-1} J^T(\bar{x})\bar{e}(\bar{x})$$

Marquardt-Levenberg เมื่อตัดแปลงกับวิธี Gauss-Newton ได้สมการดังนี้

$$\square \bar{x} = [J^T(\bar{x})J(\bar{x}) + \mu I]^{-1} J^T(\bar{x})\bar{e}(\bar{x})$$

เมื่อ μ เท่ากับศูนย์หรือมีขนาดเล็กมากๆ สมการดังกล่าวเป็น Newton's method เมื่อ μ มีขนาดใหญ่ สมการเป็น gradient descent สิ่งสำคัญของอัลกอริทึมนี้คือการคำนวณ Jacobian matrix ในการคำนวณของโครงข่ายประสาทเทียมโดยใช้ Jacobian matrix สามารถคำนวณได้จาก การตัดแปลง backpropagation algorithm ปกติ จาก performance index

$$\bar{x} = [w^1(1,1) w^1(1,2) \dots w^1(S1, R) b^1(S1) \dots b^1(S1) w^2(1,1) \dots b^M(SM)]^T$$

$$\text{และ } N = Q \times SM$$

สามารถคำนวณ backpropagation ได้ดังนี้

$$\frac{\partial \hat{V}}{\partial w^k(i, j)} = \frac{\partial \sum_{m=1}^{sm} e_q^2(m)}{\partial w^k(i, j)}$$

ในองค์ประกอบของ Jacobian matrix ที่ใช้ Marquardt algorithm คำนวณดังนี้

$$\frac{\partial e_q(m)}{\partial w^k(i, j)}$$

เทอมนี้สามารถคำนวณได้โดยใช้ backpropagation algorithm ปกติที่มีการปรับแต่งในขั้นสุดท้าย

$$\square M = \dot{F}^k(\bar{n}^k)$$

$\dot{F}^k(\bar{n}^k)$ คือ performance index เป็นความสัมพันธ์เวียนเกิด (recurrence relation)

โดย

$$\dot{F}^k(\bar{n}^k) = \begin{bmatrix} \dot{f}^k(n^k(1)) & 0 & \dots & 0 \\ 0 & \dot{f}^k(n^k(2)) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \dot{f}^k(n^k(sk)) \end{bmatrix}$$

หาได้จากสมการ

$$\bar{\delta}^k = \dot{F}^k(\bar{n}^k)W^{k+1T} \bar{\delta}^{k+1}$$

โดยเมื่อ Mean squared error (MSE)ของโครงข่ายประสาทเทียมสามารถหาได้จากสมการ ดังนี้

$$V = \frac{1}{q} \sum_{j=1}^q (\bar{t}_q - \bar{a}_q^M)^T (\bar{t}_q - \bar{a}_q^M)$$

$$V \approx \frac{1}{2} \sum_{j=1}^q (\bar{t}_q - \bar{a}_q^M)^T (\bar{t}_q - \bar{a}_q^M) = \frac{1}{2} \sum_{j=1}^q \bar{e}_q^T \bar{e}_q$$



โดย \bar{a}_q^M คือค่าจากชั้นนำออกของโครงข่ายประสาทเทียม q นำเข้าจาก p_q $\bar{e}_q = (\bar{t}_q - \bar{a}_q^M)$ คือค่าความผิดพลาด นำเข้าจาก q สำหรับ backpropagation algorithm แบบปกติ ในการประมาณโดยใช้ steepest descent ประมาณ performance index ได้ดังนี้

$$\hat{V} = \frac{1}{2} \bar{e}_q^T \bar{e}_q$$

W^{k+1} คือน้ำหนัก และ $\bar{\delta}^{k+1}$ คืออัตราการเปลี่ยนแปลงของ Mean squared error (MSE) เทียบกับน้ำหนัก และ $\alpha^{k-1}(i)$ คืออัตราการเรียนรู้ (Learning rate)


$$\frac{\partial \hat{V}}{\partial w^k(i, j)} = \frac{\partial \hat{V}}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial w^k(i, j)} = \delta^k(i) \alpha^{k-1}(i)$$

$$\frac{\partial \hat{V}}{\partial b^k(i, j)} = \frac{\partial \hat{V}}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial b^k(i, j)} = \delta^k(i)$$

นำข้อมูลของราคาหุ้นหาความล่าช้า (Dela) โดยการแบ่งช่วงหา autocorrelation แบบระบบที่ไม่มีสมบัติภาวะเชิงเส้น โดยใช้ algorithm ของ backpropagation neural network ธรรมดา เมื่อทำการฝึกโครงข่าย โดยใช้ความล่าช้าจากการใช้ algorithm ของ backpropagation neural network ธรรมดาขั้นต้น โดยใช้อัตราการเปลี่ยนแปลงของ ตัวเลขทางการเงิน อัตราส่วนทางการเงิน ในงบแสดงสถานะทางการเงิน และใช้ข้อมูลตัวแปรทางเศรษฐศาสตร์ของไตรมาสปัจจุบันในการทำนายราคาหุ้นในไตรมาสถัดไป เพื่อให้ได้น้ำหนักในแต่ละ layer เมื่อได้น้ำหนักในแต่ละ layer จากการฝึกแล้ว จึงนำไปใช้กับข้อมูลทดสอบ ผลที่ได้จากข้อมูลทดสอบมาเปรียบเทียบกับ ค่าจริงเพื่อหาความผิดพลาดกำลังสอง (Hagan and Menhaj, 1994)

4. ผลการวิจัย

การหาความล่าช้าสำหรับโครงข่ายประสาทเทียมอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้น โดยการแบ่งช่วงหาความล่าช้าที่จะนำไปใช้ในอัลกอริทึม อนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้น โดยใช้อัลกอริทึมของ Backpropagation neural network พบว่าการใช้ความล่าช้าออกไป 4 ช่วงเวลาในตัวแบบที่ได้จาก อัลกอริทึมของ Backpropagation neural network ซึ่งเป็นอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้น พบว่าได้ค่าความคลาดเคลื่อนเฉลี่ย กำลังสองต่ำสุดจึงเลือกความล่าช้าดังกล่าวเพื่อจะใช้ในอนุกรมเวลาอัลกอริทึมฟังก์ชันเป็นแบบไม่เชิงเส้นต่อไป (ภาพที่ 3)



ภาพที่ 3 ค่าความคลาดเคลื่อนเฉลี่ยกำลังสองของความล่าช้า (delay)

ในขั้นตอนการฝึกโครงข่าย และเปรียบเทียบแต่ละโครงข่าย โดยเลือกจากโครงข่ายที่ให้ค่าความคลาดเคลื่อนเฉลี่ยกำลังสองต่ำที่สุด โดยเริ่มฝึกโครงข่ายจากโครงข่าย 1 ชั้นซ่อน 1 โหนด ไล่จนถึง โครงข่าย ที่มี 2 ชั้นซ่อน คือ ชั้นซ่อนที่ 1 จำนวน 31 และชั้นซ่อนที่ 2 จำนวน 31 โหนด รวมทั้งสิ้นจำนวน 992 โครงข่าย

จากนั้นหาค่าเฉลี่ยของ ค่าความคลาดเคลื่อนเฉลี่ยกำลังสองผลการประมวลผลโดยใช้ประสาทเทียมแบบแพร่ย้อนกลับ โดยใช้ Levenberg-Marquardt algorithm โดยจัดเรียงตามค่าความคลาดเคลื่อนเฉลี่ยกำลังสองน้อยที่สุด 10 อันดับแรก ซึ่งได้ผลดังนี้ (ตาราง 2)


ตาราง 2 แสดงข้อมูลบางส่วนของผลการฝึกโครงข่าย โดยจัดเรียงตามค่าเฉลี่ยน้อยที่สุด 10 อันดับแรก

Layer	ค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง
[22,1]	0.0195
[19,1]	0.0210
[8,1]	0.0232
[16,1]	0.0238
[11,1]	0.0244
[12,1]	0.0266
[18,2]	0.0269
[24,2]	0.0269
[30,2]	0.0278
[20,1]	0.0280



จากตาราง 2 พบว่า โครงข่ายที่มีชั้นซ้อนสองชั้น โดยในชั้นซ้อนแรกมี 22 โหนด และในชั้นซ้อนที่สองมี 1 โหนด มีความสามารถในการทำนายราคาหุ้น บริษัทปูนซิเมนต์ไทย จำกัด(มหาชน) (SCC) ด้วยตัวเลขทางการเงิน อัตราส่วนทางการเงิน และตัวแปรทางเศรษฐศาสตร์ ได้ดีที่สุด

เมื่อใช้อัลกอริทึม ของโครงข่ายประสาทเทียมโดยใช้ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้นในการทำนายอัตราการเปลี่ยนแปลงของราคาหุ้นในชุดข้อมูลที่ทำการทดสอบโดยโครงข่ายประสาท เมื่อแปลงเป็นราคาหุ้นแล้วนำมาเทียบกับราคาหุ้นที่เกิดขึ้นจริง (ภาพที่ 4) โดยมีความคลาดเคลื่อนกำลังสองเฉลี่ย ในชุดข้อมูลทดสอบโครงข่ายประสาทเทียมอยู่ที่ 0.0087 ความสามารถในการทำนายราคาหุ้นในชุดข้อมูลทดสอบโดยมีค่าความคลาดเคลื่อนเฉลี่ยอยู่ที่ 8.49% หรือ ± 39.95 บาท



ภาพที่ 4 แสดงราคาหุ้น บริษัทปูนซิเมนต์ไทย จำกัด(มหาชน) ค่าจริงและค่าทำนายระหว่าง
ในชุดข้อมูลที่ทำการทดสอบ

5. บทสรุปและข้อเสนอแนะ

การวิจัยนี้ทำการศึกษาการทำงานและประสิทธิภาพของโครงข่ายประสาทเทียม ในการทำนายราคาหุ้นโดยใช้ตัวเลขทางการเงิน อัตราส่วนทางการเงิน และตัวแปรทางเศรษฐศาสตร์ ในการสร้างแบบจำลองโครงข่ายประสาทเทียม และหาค่าความคลาดเคลื่อนเฉลี่ยกำลังสองต่ำที่สุด ตัวแบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้นดังกล่าวมีความสามารถในการทำนายราคาหุ้นโดยโครงข่ายที่เหมาะสมคือ ชั้นซ้อนที่ 1 มี 22 โหนด ชั้นซ้อนที่ 2 มี 1 โหนด โดยมีความคลาดเคลื่อนเฉลี่ยกำลังสองอยู่ที่ 0.0087 ซึ่งมีค่าน้อยที่สุดโดยเทียบกับโครงข่ายอื่นๆ มีความคลาดเคลื่อนเฉลี่ยอยู่ที่ 8.49% เมื่อเปรียบเทียบกับการศึกษาของ วิชชุพันธ์ อ่าวชันนาการ (2005) ในการทำนายราคาหลักทรัพย์ซึ่งมีความคลาดเคลื่อนเฉลี่ยอยู่ที่ 9.92% จากทุกกลุ่มอุตสาหกรรม ซึ่งมีค่าที่ใกล้เคียงกันแต่การศึกษาของ วิชชุพันธ์ อ่าวชันนาการ มีความคลาดเคลื่อนเฉลี่ยมากกว่าอาจเป็นเพราะข้อมูลที่ใช้มีความจำเพาะน้อยกว่าจึงส่งผลทำให้มีความแม่นยำน้อยกว่า หรืออาจเป็นที่ความแตกต่างของโครงข่าย ฉะนั้นอาจสรุปได้ว่าสามารถประยุกต์ใช้ตัว



แบบอนุกรมเวลาฟังก์ชันเป็นแบบไม่เชิงเส้นดังกล่าว ในการทำนายราคาหุ้นในอนาคตได้ และสามารถใช้ในสถานการณ์จริงได้อย่างมีประสิทธิภาพ

มีตัวแปรที่น่าสนใจอีกมากมายที่สามารถนำมาช่วยในการทำนายได้ ยกตัวอย่างเช่น อัตราดอกเบี้ย การบริโภค ดัชนีอุตสาหกรรม ดัชนีตลาดหลักทรัพย์แห่งประเทศไทย (SET index) เป็นต้น อาจลองใช้วิธีในการประเมินมูลค่าหุ้น หรือการวิเคราะห์แบบอื่น เช่น Technical analysis สามารถนำมาประยุกต์ใช้กับโครงข่ายประสาทเทียมเพื่อเพิ่มประสิทธิภาพของการทำนาย ในการเปรียบเทียบความแม่นยำลักษณะของการศึกษายังคงมีความแตกต่างกันมาก ดังนั้นอาจต้องรอให้มีการศึกษาในเรื่องเดียวกันหรือคล้ายกันอีกในอนาคตเพื่อเปรียบเทียบความแม่นยำและประสิทธิภาพของโครงข่ายประสาทเทียมดังกล่าว การเปลี่ยนแปลง transfer function ตลอดจนการเปลี่ยนอัลกอริทึมสำหรับการ optimization ที่เหมาะสมอาจทำให้โครงข่ายมีประสิทธิภาพดีขึ้น

สถาปัตยกรรมโครงข่ายประสาทเทียมในการศึกษาคั้งนี้เป็นแบบ Multilayer Perceptron ซึ่งในปัจจุบันมีสถาปัตยกรรมโครงข่ายประสาทเทียมหลากหลายรูปแบบ เช่น Deep Neural Network (DNN), Recurrent Neural Network (RNN), Convolutional Neural Network (CNN) เป็นต้น ฉะนั้นอาจลองประยุกต์สถาปัตยกรรมโครงข่ายประสาทเทียมหลายๆแบบในการทำนาย อาจทำให้มีความแม่นยำมากกว่า Multilayer Perceptron

การปรับเปลี่ยนธุรกิจเป็นสิ่งสำคัญที่ต้องพิจารณาเพราะจะทำให้พื้นฐานบริษัทเปลี่ยนไป ส่งผลต่อการใช้อัตราส่วนทางการเงิน อาจทำให้อัตราส่วนทางการเงินบางตัวมีความสำคัญมากขึ้นและบางตัวลดความสำคัญลง

เอกสารอ้างอิง

วิชชุพันธ์ อาวัจนการ. (2005). การทำนายราคาหลักทรัพย์ประเภทหุ้นสามัญในตลาดหลักทรัพย์แห่งประเทศไทย โดยใช้ข่ายงานประสาทเทียม. (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ, จุฬาลงกรณ์มหาวิทยาลัย).

Hagan, M. T., Menhaj M. B. (1994). Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions On Neural Networks*, 5(6), 989-993.

Papagelis, A. J., & Kim, D. S. (2017, June). Backpropagation. *UNSW Sydney*. Retrieved from <https://www.cse.unsw.edu.au/~cs9417ml/MLP2/BackPropagation.html>.