

ตัวแบบโครงข่ายประสาทเทียมสำหรับการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย

ธรณินทร์ สัจจวิริยทรัพย์*

บทคัดย่อ

งานวิจัยนี้ ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าถูกพัฒนาขึ้นเพื่อพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย โดยใช้ข้อมูลอนุกรมเวลาของราคาข้าวโพดเลี้ยงสัตว์ตั้งแต่เดือนมกราคม 2540 ถึงเดือนพฤศจิกายน 2558 ซึ่งตัวแบบที่ถูกพัฒนาขึ้นถูกเปรียบเทียบประสิทธิภาพความแม่นยำกับตัวแบบอาร์มาแบบมีฤดูกาลและตัวแบบการพยากรณ์แบบรวมที่ถูกรวบรวมไว้ในงานวิจัยว่าประสิทธิภาพดีในการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย โดยใช้เกณฑ์การประเมินประสิทธิภาพของตัวแบบต่างๆ 3 เกณฑ์คือ ค่าเฉลี่ยของความคลาดเคลื่อนสัมบูรณ์ ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง ค่าเฉลี่ยของเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ จากผลการวิจัยพบว่า ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมอาศัยข้อมูลในอดีตย้อนหลัง 2 ค่า เพื่อให้ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าเรียนรู้และสร้างฟังก์ชันการทำนายที่มีประสิทธิภาพดีกว่าตัวแบบอาร์มาแบบมีฤดูกาลและตัวแบบการพยากรณ์รวม ดังนั้น ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า จึงมีความเหมาะสมที่จะเป็นตัวแทนในการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย เพื่อให้ได้สารสนเทศที่เป็นประโยชน์และสนับสนุนการตัดสินใจในการวางแผนการผลิตอาหารสัตว์ได้อย่างมีประสิทธิภาพ

คำสำคัญ: ตัวแบบโครงข่ายประสาทเทียม ตัวแบบอาร์มาแบบมีฤดูกาล ข้าวโพดเลี้ยงสัตว์ ตัวแบบความสำคัญรวม

Artificial Neural Network Model for Forecasting Monthly Price of Maize in Thailand

Thorarin Sujjaviriyasup^{*}

ABSTRACT

In this research, a feed-forward neural network model is developed in order to forecast a future price of maize in Thailand. The time series data of Thailand's maize price is a monthly time series dataset from January 1997 to November 2015. Subsequently, the developed model is compared to both seasonal ARIMA model and combined forecasting model that is proposed in a research paper with the superior performance in forecasting the future price of maize in Thailand based on three accuracy measures. The accuracy measures are mean absolute error, root mean squared error, and mean absolute percentage error. The empirical results revealed that the feed-forward neural network model is formulated from two previous observations, which outperforms both seasonal ARIMA model and the combined forecasting model based on three measures of forecast accuracy. Consequently, the feed-forward neural network model is able to be a useful model to forecast Thailand's monthly price of maize and to provide meaningful information to support critical decision making in effective production planning of animal feed.

Keywords: Artificial neural network, seasonal ARIMA, Maize, Combined forecasting model

บทนำ

ภาคการเกษตรของประเทศไทยเป็นส่วนหนึ่งที่มีบทบาทสำคัญต่อเศรษฐกิจของประเทศตั้งแต่อดีตจนถึงปัจจุบัน ซึ่งสามารถสร้างรายได้เข้าสู่ประเทศหลายล้านล้านบาทต่อปีหรือมีมูลค่าคิดเป็นร้อยละ 8.337 ของผลิตภัณฑ์มวลรวมในประเทศ [1] ในปี 2559 นอกจากนี้ ภาคการเกษตรยังมีความผูกพันกับวิถีชีวิตของเกษตรกรไทยมาอย่างยาวนาน ส่งผลให้ประเทศไทยสามารถผลิตและส่งออกสินค้าทางการเกษตรในฐานะผู้ส่งออกรายใหญ่ของตลาดการค้าสินค้าทางการเกษตรระหว่างประเทศในปัจจุบัน ผลิตภัณฑ์จากไก่เป็นหนึ่งในสินค้าทางการเกษตรที่ประเทศไทยสามารถผลิตและส่งออกได้ในปริมาณมาก ซึ่งสามารถส่งออกในปี 2558 ได้มากถึงร้อยละ 44 ของปริมาณการส่งออกของทวีปเอเชีย [2] ส่งผลให้เกิดความต้องการวัตถุดิบสำหรับผลิตอาหารสัตว์เพื่อป้อนเข้าสู่อุตสาหกรรมเลี้ยงไก่จำนวนมาก

ข้าวโพดเลี้ยงสัตว์เป็นหนึ่งในวัตถุดิบที่สำคัญของกระบวนการผลิตอาหารไก่ [3] เนื่องจากเป็นแหล่งพลังงานที่สำคัญและยังมีแคโรทีน ซึ่งเป็นสารที่ช่วยให้สีเนื้อไก่และไข่แดงเข้มขึ้นตามความนิยมของผู้บริโภค แต่ราคาข้าวโพดเลี้ยงสัตว์ในแต่ละเดือนมีลักษณะที่ไม่แน่นอน [4] และยากที่จะทำนายด้วยวิธีการอย่างง่าย ส่งผลให้เกษตรกรผู้ผลิตอาหารไก่ประสบปัญหาการวางแผนการผลิตเพื่อให้สามารถลดต้นทุนการผลิตที่ต่ำที่สุด สำหรับการบริหารจัดการและวางแผนการผลิตให้เกิดประสิทธิภาพ การคาดการณ์ราคาข้าวโพดเลี้ยงสัตว์ที่จะมีการเปลี่ยนแปลงในอนาคต จึงเป็นสารสนเทศที่สำคัญสำหรับการวางแผนการผลิตที่มีประสิทธิภาพ

จากลักษณะการเปลี่ยนแปลงของราคาข้าวโพดเลี้ยงสัตว์รายเดือนที่ไม่แน่นอน ตัวแบบอนุกรมเวลาเป็นหนึ่งในเครื่องมือที่ได้รับการยอมรับว่าเป็นเครื่องมือที่มีประสิทธิภาพในการพยากรณ์ค่าที่ต้องการในอนาคต [5-7] ถึงแม้ว่าจะมีข้อถกเถียงเกี่ยวกับประสิทธิภาพของตัวแบบพยากรณ์สำหรับการวางแผนต่างๆ แต่อย่างไรก็ตาม นักวิทยาศาสตร์ต่างๆ ยังคงสนับสนุนการใช้งานตัวแบบพยากรณ์สำหรับการวางแผนต่างๆ โดยอาศัยข้อมูลและประสบการณ์ในอดีตรวมถึงข้อมูลในปัจจุบันเพื่อทำนายค่าที่จะเกิดขึ้นในอนาคต ตัวแบบการพยากรณ์ต่างๆ จึงเข้ามามีบทบาทสำคัญเพื่อประมาณราคาที่จะเกิดการเปลี่ยนแปลงในอนาคต ซึ่งสารสนเทศที่ได้สามารถสนับสนุนการตัดสินใจในการบริหารจัดการและวางแผนการผลิตให้เกิดประสิทธิภาพได้ แต่อย่างไรก็ตาม วิธีการทดสอบลักษณะความสัมพันธ์ของข้อมูลที่ต้องการทำนายยังไม่สามารถระบุคุณลักษณะของความสัมพันธ์ที่ชัดเจนและไม่มีตัวแบบพยากรณ์ใดที่มีประสิทธิภาพในการทำนายในทุกสถานการณ์ [8] ส่งผลให้จำเป็นต้องใช้ตัวแบบพยากรณ์ต่างๆ เพื่อสร้างความสัมพันธ์จากข้อมูลในอดีตรวมถึงข้อมูลในปัจจุบันเพื่อทำนายค่าในอนาคตที่ต้องการและเลือกใช้ตัวแบบที่ให้ค่าความแม่นยำมากที่สุดสำหรับการใช้ประโยชน์ในการพยากรณ์ต่อไป

ตัวแบบอาร์มา (ARIMA) เป็นหนึ่งในตัวแบบทางสถิติที่ได้รับความนิยมและมีความโดดเด่นในการพยากรณ์ค่าความสัมพันธ์ที่เป็นเชิงเส้นตรง [9-12] จึงถูกใช้ในการพยากรณ์ราคาสินค้าต่างๆ ถึงแม้ว่า ตัวแบบอาร์มาจะมีประสิทธิภาพดีในการพยากรณ์ราคาสินค้าต่างๆ แต่ยังคงมีข้อจำกัดอยู่บางประการ [13] เช่น ตัวแบบอาร์มาถูกสร้างจากสมมติฐานของความสัมพันธ์แบบเชิงเส้นตรง จึงไม่ยืดหยุ่นในการใช้งานและไม่เหมาะสมกับข้อมูลที่มีความสัมพันธ์ไม่เป็นเชิงเส้นตรง เป็นต้น เพื่อให้เกิดความยืดหยุ่นในการใช้งานและมีความถูกต้องในการพยากรณ์มากขึ้น จึงมีความสนใจพัฒนาตัวแบบการเรียนรู้ของเครื่อง (Machine learning) อย่างกว้างขวาง เพื่อให้การใช้งานมีความยืดหยุ่นและมีความถูกต้องมากยิ่งขึ้น โดยจุดเด่นของตัวแบบการเรียนรู้ของเครื่องมีดังต่อไปนี้ 1) ตัวแบบการเรียนรู้ของเครื่องถูกสร้างจากการใช้คุณลักษณะของข้อมูลในการสร้างตัวแบบ จึงไม่จำเป็นต้องใช้สมมติฐานมากเมื่อเทียบกับตัวแบบอาร์มา 2) ตัวแบบการเรียนรู้ของเครื่องมีความยืดหยุ่นในการพยากรณ์ข้อมูลที่ไม่เป็นเชิงเส้นตรง โดยใช้ความสามารถในการแปลงข้อมูลจากข้อมูลไม่เป็นเชิงเส้นตรงไปสู่ข้อมูลที่เป็นเชิงเส้นตรงในปริภูมิ (Space) ใหม่ ซึ่งมีคุณลักษณะที่สอดคล้องกับลักษณะข้อมูลไม่เป็นเชิงเส้นตรง 3) ตัวแบบการเรียนรู้ของเครื่องสามารถปรับเปลี่ยนตัวแบบในการใช้งานและระดับความถูกต้องตามที่ต้องการ จากจุดเด่นที่กล่าวมาข้างต้นของตัว

แบบการเรียนรู้ของเครื่อง ส่งผลให้ตัวแบบการเรียนรู้ของเครื่องได้รับความสนใจและถูกนำมาใช้ในการพยากรณ์ในงานวิจัยต่างๆ

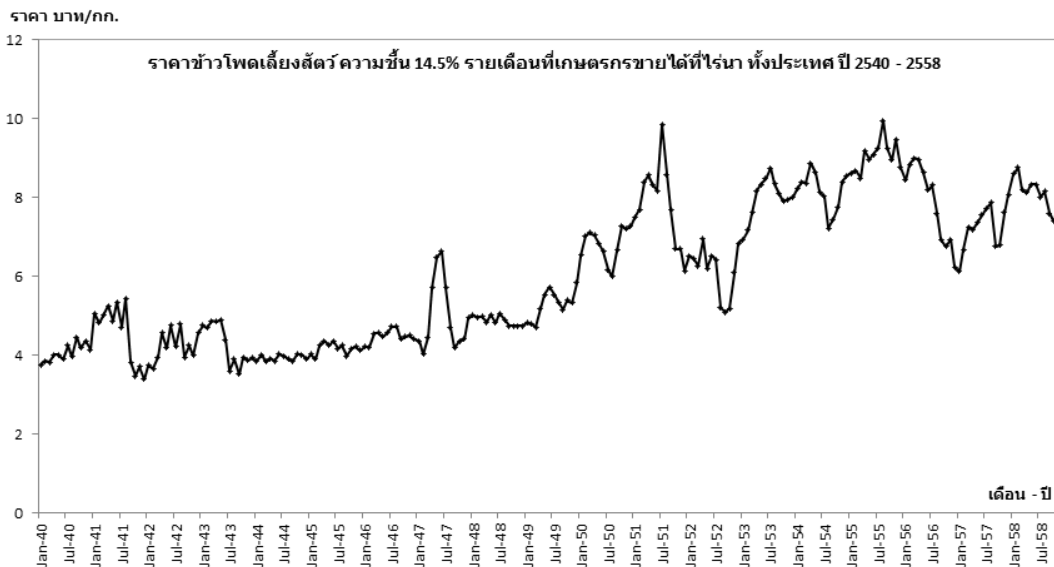
ตัวแบบโครงข่ายประสาทเทียม (Artificial Neural Network) เป็นหนึ่งในตัวแบบการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised learning) ที่ถูกพัฒนาจากการลอกเลียนแบบโครงข่ายประสาทของสิ่งมีชีวิตเพื่อการจำแนกและทำนาย ซึ่งได้รับความนิยมอย่างกว้างขวางและถูกประยุกต์ใช้ในงานวิจัยต่างๆ [14-16] ในช่วงหลายสิบปีที่ผ่านมา

งานวิจัยนี้ ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feed-Forward Neural Network) ซึ่งมีโครงสร้างของชั้นซ่อนตัว (hidden layer) แบบชั้นเดียวและใช้วิธีการหาค่าที่เหมาะสมที่สุดของค่าพารามิเตอร์ต่างๆ ด้วยวิธี Broyden-Fletcher-Goldfarb-Shanno (BFGS) เพื่อให้ค่ากำลังสองน้อยที่สุด (Least squares) ในการหาตัวแบบที่เหมาะสมที่สุด ถูกประยุกต์เพื่อพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์ตั้งแต่เดือนมกราคม 2540 ถึงเดือนพฤศจิกายน 2558 นอกจากนี้ ตัวแบบโครงข่ายประสาทเทียมที่ถูกพัฒนายังถูกเปรียบเทียบประสิทธิภาพการพยากรณ์กับตัวแบบอาร์มา และตัวแบบการพยากรณ์รวมระหว่างวิธีบ็อกซ์-เจนกินส์และวิธีการปรับให้เรียบด้วยเส้นโค้งเลขชี้กำลังที่มีแนวโน้มแบบแฉก [17] ซึ่งถูกแทนด้วย “Combined model” เพื่อความกระชับในการอ้างอิง โดยอาศัยเกณฑ์การวัดความแม่นยำของ ตัวแบบพยากรณ์ 3 เกณฑ์ ได้แก่ ค่าเฉลี่ยของความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error) ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Squared Error) และค่าเฉลี่ยของเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error) เพื่อพิจารณาตัวแบบพยากรณ์ที่เหมาะสมสำหรับคาดการณ์ราคาข้าวโพดเลี้ยงสัตว์ในอนาคต ซึ่งเป็นสารสนเทศที่สำคัญสนับสนุนการตัดสินใจและบริหารจัดการการผลิตอาหารสัตว์ได้ ตัวแบบพยากรณ์ต่างๆ ในงานวิจัยนี้ ถูกพัฒนาจากการเขียนชุดคำสั่งของโปรแกรมภาษา R ซึ่งมีไลบรารีต่างๆ ที่ได้ถูกพัฒนามาบางส่วนเพื่อช่วยให้การประยุกต์ใช้งานได้สะดวกและรวดเร็วมากยิ่งขึ้น

อุปกรณ์และวิธีทดลอง

1. ข้อมูลอนุกรมเวลาของราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย

ข้อมูลราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย [4] ตั้งแต่เดือนมกราคม 2540 ถึงเดือนพฤศจิกายน 2558 จากข้อมูลเว็บไซต์ของสำนักงานเศรษฐกิจการเกษตร จำนวน 227 คำสั่งเกิด โดยข้อมูลทั้งหมดถูกนำเสนอในรูปแบบที่ 1



รูปที่ 1 ราคาข้าวโพดเลี้ยงสัตว์รายเดือน ตั้งแต่เดือนมกราคม 2540 ถึงเดือนพฤศจิกายน 2558

โดยข้อมูลทั้ง 227 ค่าสังเกต จะถูกแบ่งออกเป็นสองส่วน คือ ชุดข้อมูลสำหรับการสร้างตัวแบบซึ่งประกอบไปด้วยข้อมูลลำดับที่ 1 ถึง 216 และชุดข้อมูลสำหรับการทดสอบตัวแบบซึ่งเป็นข้อมูลที่เหลืออยู่ในลำดับที่ 217 ถึง 227 โดยชุดข้อมูลทดสอบจะถูกปิดไว้และไม่เกี่ยวข้องกับการสร้างตัวแบบจนกระทั่งค่าชุดข้อมูลนั้นถูกเฉลย เพื่อทดสอบประสิทธิภาพการพยากรณ์ เริ่มต้น ข้อมูลสำหรับการสร้างตัวแบบที่ประกอบไปด้วยค่าในลำดับที่ 1 ถึง 216 จะถูกใช้เพื่อสร้างตัวแบบพยากรณ์ในการทำนายค่าที่ 217 ซึ่งถูกปิดไว้ในชุดข้อมูลทดสอบ เมื่อค่าที่ 217 ถูกเฉลยและมีการคำนวณค่าความคลาดเคลื่อนต่างๆ ของการพยากรณ์ของแต่ละตัวแบบแล้ว ค่าดังกล่าวจะถูกนำมารวมเข้ากับข้อมูลสำหรับการสร้างตัวแบบเดิมเพื่อเป็นชุดข้อมูลสำหรับการสร้างตัวแบบใหม่และพยากรณ์ค่าในอนาคตถัดไป 1 ลำดับ โดยทุกตัวแบบพยากรณ์จะดำเนินการพยากรณ์แบบวนซ้ำไปเรื่อยๆ จนกระทั่งถึงการพยากรณ์ค่าสุดท้ายของชุดข้อมูลสำหรับการทดสอบประสิทธิภาพการพยากรณ์

2. ตัวแบบการพยากรณ์แบบอาร์มี

ตัวแบบอาร์มีเป็นตัวแบบอนุกรมเวลาที่มีความโดดเด่นในการพยากรณ์ข้อมูลที่มีลักษณะเชิงเส้นตรง โดยมีสมการทางคณิตศาสตร์ของตัวแบบอาร์มีแบบมีฤดูกาล ดังที่แสดงในสมการที่ 1

$$\Phi_p(B^s) \theta_p(B) \nabla_S^D \nabla^d Y_t = \mu + \theta_q(B) \Theta_Q(B^s) \varepsilon_t \quad (1)$$

เมื่อ y_t และ ε_t คือ ค่าจริงและค่าความคลาดเคลื่อน ณ เวลาที่ t ตามลำดับ

B และ μ คือ ตัวแปลงค่าอนุกรมเวลาย้อนกลับ (backward shift operator) และค่าเฉลี่ย ตามลำดับ

d และ D คือ ลำดับของผลต่างและผลต่างฤดูกาล ตามลำดับ

p และ q คือ ลำดับของอาร์มี

S คือ จำนวนฤดูกาล

โดยรูปแบบอาร์มีมาแบบมีฤดูกาลทั่วไป คือ SARIMA(p, d, q)(P,D,Q)_S ซึ่งมีขั้นตอนในการสร้างตัวแบบ SARIMA ดังนี้

1. ขั้นตอนการระบุตัวแบบอาร์มีมาแบบมีฤดูกาล ซึ่งในขั้นตอนนี้ชุดข้อมูลอนุกรมเวลาจะถูกพิจารณาสถานะคงที่ หากชุดข้อมูลไม่อยู่ในสถานะคงที่ จะใช้การแปลงค่าอนุกรมเวลาย้อนกลับที่ระดับผลต่างค่าใดค่าหนึ่งของชุดข้อมูลอนุกรมเวลาหรือที่ระดับผลต่างค่าใดค่าหนึ่งของฤดูกาล เพื่อปรับชุดข้อมูลอนุกรมเวลามีสถานะคงที่ ซึ่งสถานะคงที่ที่มีความสำคัญต่อการสร้างตัวแบบอาร์มีมา โดยค่าลำดับของอาร์มีมาสามารถพิจารณาจากค่าฟังก์ชันสหสัมพันธ์ในตัวเอง (autocorrelation function, ACF) และค่าฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (partial autocorrelation function, PACF) เพื่อเป็นจุดเริ่มต้นในการกำหนดลำดับของตัวแบบอาร์มีมา แต่ถ้าลักษณะของค่าฟังก์ชันสหสัมพันธ์ในตัวเองและค่าฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วนเข้าใกล้ค่าศูนย์อย่างรวดเร็วทั้งสองค่า การระบุลำดับจะมีความซับซ้อน จึงต้องอาศัยเกณฑ์การพิจารณาอื่น เช่น เกณฑ์อะไคอินฟอร์เมชันไครทีเรีย (Akaike Information Criterion, AIC) เป็นต้น เพื่อกำหนดลำดับของตัวแบบอาร์มีมา

2. ขั้นตอนการประมาณค่าพารามิเตอร์ของตัวแบบอาร์มีมา ซึ่งขั้นตอนนี้จะทำการประมาณค่าพารามิเตอร์จากหลักการเลือกค่าพารามิเตอร์ที่ให้ค่าความคลาดเคลื่อนน้อยที่สุด

3. ขั้นตอนการทดสอบตัวแบบ ซึ่งในขั้นตอนนี้ ตัวแบบอาร์มีมาที่ได้จะถูกทดสอบตามข้อกำหนดต่างๆ หากตัวแบบที่ได้ยังไม่เหมาะสมจะต้องดำเนินการข้อ 2 ถึง 3 ใหม่

ในการพิจารณาตัวแบบที่เหมาะสมของงานวิจัยนี้ใช้เกณฑ์อะไคอินฟอร์เมชันไครทีเรียแบบมีขนาดตัวอย่างแบบจำกัด (AICc) ซึ่งตัวแบบที่ให้ค่าเกณฑ์อะไคอินฟอร์เมชันไครทีเรียแบบมีขนาดตัวอย่างแบบจำกัดที่ต่ำที่สุด คือ ตัวแบบที่เหมาะสมที่สุดในการพยากรณ์ โดยในการวิจัยนี้ตัวแบบอาร์มีมาแบบมีฤดูกาลได้ถูกเขียนขึ้นจากโปรแกรมภาษา R (R programming) ซึ่งไลบรารี “forecast” ของโปรแกรม R [18] ได้ถูกพัฒนาเพื่อช่วยในการพยากรณ์ด้วยการหาตัวแบบที่เหมาะสมแบบอัตโนมัติ ซึ่งได้ถูกอ้างอิงและประยุกต์ใช้งานในงานวิจัยที่ได้ถูกเผยแพร่ในวารสารที่เป็นที่ยอมรับต่างๆ [19-21] โดยโปรแกรม R จะทำการหาตัวแบบที่เป็นไปได้ทั้งหมดภายใต้ขอบเขตลำดับของค่า p และ q ที่ถูกกำหนดไว้ในโปรแกรม แต่ผู้วิจัยสามารถปรับแก้ไขค่าดังกล่าวได้ และทำการเลือกตัวแบบอาร์มีมาที่เหมาะสมที่สุดด้วยการใช้เกณฑ์อะไคอินฟอร์เมชันไครทีเรียแบบมีขนาดตัวอย่างแบบจำกัดที่น้อยที่สุดเป็นเกณฑ์ในการเลือกตัวแบบอาร์มีมาที่เหมาะสมดังรูปที่ 2

ARIMA(0,1,0)	: 256.1032	ARIMA(3,1,0) (1,0,0) [12] with drift	: 264.2491
ARIMA(0,1,0) with drift	: 257.6844	ARIMA(3,1,0) (1,0,1) [12]	: 263.8296
ARIMA(0,1,0) (0,0,1) [12]	: 255.7764	ARIMA(3,1,0) (1,0,1) [12] with drift	: 265.8532
ARIMA(0,1,0) (0,0,1) [12] with drift	: 257.6488	ARIMA(3,1,0) (2,0,0) [12]	: 232.63
ARIMA(0,1,0) (0,0,2) [12]	: 248.7807	ARIMA(3,1,0) (2,0,0) [12] with drift	: 234.5602
ARIMA(0,1,0) (0,0,2) [12] with drift	: 250.5663	ARIMA(3,1,1)	: 257.3079
ARIMA(0,1,0) (1,0,0) [12]	: 258.8283	ARIMA(3,1,1) with drift	: 257.6429
ARIMA(0,1,0) (1,0,0) [12] with drift	: 260.7152	ARIMA(3,1,1) (0,0,1) [12]	: 256.4739
ARIMA(0,1,0) (1,0,1) [12]	: 260.8731	ARIMA(3,1,1) (0,0,1) [12] with drift	: 256.6315
ARIMA(0,1,0) (1,0,1) [12] with drift	: 262.8407	ARIMA(3,1,1) (1,0,0) [12]	: 262.448
ARIMA(0,1,0) (1,0,2) [12]	: 250.658	ARIMA(3,1,1) (1,0,0) [12] with drift	: 264.3218
ARIMA(0,1,0) (1,0,2) [12] with drift	: 252.6582	ARIMA(3,1,2)	: 259.0841
ARIMA(0,1,0) (2,0,0) [12]	: 234.7953	ARIMA(3,1,2) with drift	: 259.1042
ARIMA(0,1,0) (2,0,0) [12] with drift	: 236.5345	ARIMA(4,1,0)	: 262.3484
ARIMA(0,1,0) (2,0,1) [12]	: 229.6362	ARIMA(4,1,0) with drift	: 263.9193
ARIMA(0,1,0) (2,0,1) [12] with drift	: 231.3351	ARIMA(4,1,0) (0,0,1) [12]	: 261.5669
ARIMA(0,1,0) (2,0,2) [12]	: 230.8133	ARIMA(4,1,0) (0,0,1) [12] with drift	: 263.1981
ARIMA(0,1,0) (2,0,2) [12] with drift	: 232.5556	ARIMA(4,1,0) (1,0,0) [12]	: 263.1336
ARIMA(0,1,1)	: 258.137	ARIMA(4,1,0) (1,0,0) [12] with drift	: 264.9945
ARIMA(0,1,1) with drift	: 259.8762	ARIMA(4,1,1)	: 260.1806
ARIMA(0,1,1) (0,0,1) [12]	: 257.808	ARIMA(4,1,1) with drift	: 1e+20
ARIMA(0,1,1) (0,0,1) [12] with drift	: 259.4491	ARIMA(5,1,0)	: 264.9366
ARIMA(0,1,1) (0,0,2) [12]	: 250.8342	ARIMA(5,1,0) with drift	: 266.4372
ARIMA(0,1,1) (0,0,2) [12] with drift	: 252.6336		
ARIMA(0,1,1) (1,0,0) [12]	: 260.5274		
ARIMA(0,1,1) (1,0,0) [12] with drift	: 262.4228		
ARIMA(0,1,1) (1,0,1) [12]	: 262.6024	Series: data	
ARIMA(0,1,1) (1,0,1) [12] with drift	: 264.5745	ARIMA(0,1,1) (2,0,2) [12]	
ARIMA(0,1,1) (1,0,2) [12]	: 252.6204		
ARIMA(0,1,1) (1,0,2) [12] with drift	: 254.6117	Coefficients:	
ARIMA(0,1,1) (2,0,0) [12]	: 235.4626	ma1 sar1 sar2 sma1 sma2	
ARIMA(0,1,1) (2,0,0) [12] with drift	: 237.2567	-0.0493 0.3135 0.5228 -0.2763 -0.3414	
ARIMA(0,1,1) (2,0,1) [12]	: 229.3731	s.e. 0.0705 0.2738 0.2641 0.2938 0.2667	
ARIMA(0,1,1) (2,0,1) [12] with drift	: 231.1183		
ARIMA(0,1,1) (2,0,2) [12]	: 229.223	sigma^2 estimated as 0.1727: log likelihood=-117.83	

รูปที่ 2 การหาตัวแบบอาร์มีนาที่เหมาะสมที่สุดโดยการใช้เกณฑ์อะไคอินฟอร์เมชันไครที่เรียแบบมีขนาดตัวอย่างแบบจำกัดที่น้อยที่สุด

จากรูปที่ 2 ตัวแบบอาร์มีนาในรูปแบบต่างๆ ถูกคำนวณค่าอะไคอินฟอร์เมชันไครที่เรียแบบมีขนาดตัวอย่างแบบจำกัด ซึ่งจะพบว่าตัวแบบอาร์มีนาแบบมีฤดูกาล SARIMA(0,1,1)(2,0,2)₁₂ มีค่าอะไคอินฟอร์เมชันไครที่เรียแบบมีขนาดตัวอย่างแบบจำกัดที่น้อยที่สุด จึงเป็นตัวแบบที่มีความเหมาะสมที่สุดในการใช้พยากรณ์ เมื่อได้ตัวแบบที่เหมาะสมที่สุดสำหรับชุดข้อมูลลำดับที่ 1 ถึง 216 สำหรับการสร้างตัวแบบอาร์มีนาแบบมีฤดูกาลแล้ว ตัวแบบที่ได้จะถูกใช้ในการพยากรณ์ไปข้างหน้า 1 ค่า ดังรูปที่ 3

```

R Console
> predict_ARIMA
Jan
2558 8.044766
> Output
predict_ARIMA Real_data
1          8.044766      8.59
> |
    
```

รูปที่ 3 ผลการพยากรณ์ค่าที่ 217 ของราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย

จากรูปที่ 3 ค่าของการพยากรณ์ของราคาข้าวโพดเลี้ยงสัตว์ ซึ่งได้จากตัวแบบอาร์มาแบบมีฤดูกาล SARIMA(0,1,1)(2,0,2)₁₂ คือ 8.045 บาท/กิโลกรัม โดยผลพยากรณ์ค่าที่ 217 หรือค่าพยากรณ์ของราคาข้าวโพดเลี้ยงสัตว์ของเดือนมกราคม พ.ศ. 2558

3. ตัวแบบโครงข่ายประสาทเทียม

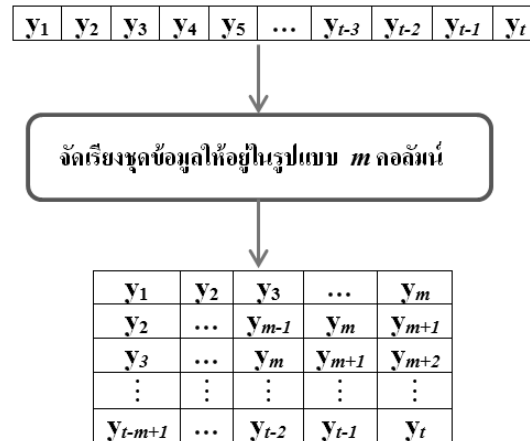
ตัวแบบโครงข่ายประสาทเทียมเป็นแบบการเรียนรู้ของเครื่องประเภทหนึ่ง ซึ่งเป็นแบบการเรียนรู้แบบมีผู้สอน (supervised learning) ที่ได้ถูกพัฒนาจากการลอกเลียนโครงข่ายประสาทของสิ่งมีชีวิตด้วยตัวแบบทางคณิตศาสตร์ เพื่อเรียนรู้และจดจำข้อมูลสำหรับการสอนต่างๆ ในการสร้างความสัมพันธ์สำหรับการจำแนกกลุ่มหรือการทำนาย จึงมีการประยุกต์ตัวแบบโครงข่ายประสาทเทียมในงานวิจัยหลายลักษณะ เช่น การจำแนกกลุ่มหรือการพยากรณ์ เป็นต้น สมการทางคณิตศาสตร์ของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าสามารถอธิบายได้ ดังสมการที่ 2

$$x_{t+1} = h \left(\beta_0 + \sum_{j=1}^D \beta_j g \left(w_{0j} + \sum_{i=1}^m w_{ij} x_{t-(i-1)} \right) \right) \quad (2)$$

เมื่อ m และ D คือ จำนวนของข้อมูลป้อนเข้า (Input data) และจำนวนโหนด (node) ในชั้นซ่อนตัว และ w_{0j} , w_{ij} และ x_t คือ ค่าเอนเอียง (bias) ของโหนดที่ j ในชั้นของชั้นซ่อนตัว, ค่าถ่วงน้ำหนัก (weight) ของข้อมูลป้อนเข้าที่ i ไปยังโหนดที่ j และค่าข้อมูลป้อนเข้าที่ลำดับ t ตามลำดับ นอกจากนี้ β_0 และ β_j คือ ค่าเอนเอียง (bias) ของค่าเป้าหมาย ในชั้นของชั้นคำตอบ (Output layer), ค่าถ่วงน้ำหนัก (weight) ของข้อมูลป้อนเข้าในชั้นซ่อนตัวของโหนดที่ j ตามลำดับ นอกจากนี้ $g(\bullet)$ และ $h(\bullet)$ คือ ฟังก์ชันไม่เป็นเชิงเส้นตรงของแต่ละโหนดในชั้นซ่อนตัวด้วยฟังก์ชันซิกมอยด์ (Sigmoid function) และฟังก์ชันเชิงเส้นตรงของความสัมพันธ์ระหว่างแต่ละโหนดและค่าเป้าหมาย (Target data) ตามลำดับ โดยขั้นตอนการดำเนินงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าสามารถอธิบายได้ดังนี้

1. ค่าถ่วงน้ำหนักต่างๆ ของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าถูกกำหนดขึ้นด้วยวิธีการสุ่ม
2. ป้อนค่าของข้อมูลป้อนเข้าขนาด m ค่า เข้าสู่โครงข่ายประสาทเทียมในขั้นตอนของกระบวนการเรียนรู้ตามสมการที่ (2) ด้วยการคูณกับค่าถ่วงน้ำหนัก w_{ij} และบวกกับค่าเอนเอียง w_{0j} เพื่อคำนวณค่าแต่ละโหนดในชั้นซ่อนตัว
3. คำนวณค่าเป้าหมาย x_{t+1} จากสมการที่ (2) โดยใช้แต่ละโหนดในชั้นซ่อนตัวคูณค่าถ่วงน้ำหนัก β_j และบวกกับค่าเอนเอียง β_0
4. คำนวณค่าผลรวมกำลังสองของค่าความคลาดเคลื่อน จากค่าจริงเทียบกับค่าเป้าหมาย
5. ปรับค่าถ่วงน้ำหนักด้วยวิธี Broyden-Fletcher-Goldfarb-Shanno (BFGS) เพื่อหาค่าถ่วงน้ำหนักที่ทำให้ค่าผลรวมกำลังสองของค่าความคลาดเคลื่อนที่ลดน้อยลง
6. ดำเนินการในขั้นตอนที่ 2 ถึง 5 จนกระทั่งถึงเกณฑ์ที่กำหนดให้หยุด

ในการจัดเตรียมข้อมูลอนุกรมเวลาเพื่อใช้สำหรับการสร้างตัวแบบพยากรณ์ของโครงข่ายประสาทเทียม นั้น ข้อมูลจะถูกจัดเรียงใหม่ m คอลัมน์ โดยใช้ข้อมูลย้อนหลังตั้งแต่คอลัมน์ที่ 1 ถึงคอลัมน์ที่ $m - 1$ เป็นข้อมูล ป้อนเข้าและคอลัมน์ที่ m ซึ่งเป็นคอลัมน์สุดท้ายเป็นข้อมูลเป้าหมาย เพื่อการเรียนรู้ของโครงข่ายประสาทเทียมใน การสร้างตัวแบบพยากรณ์ค่าที่ m ดังแสดงในรูปที่ 4



รูปที่ 4 การจัดรูปแบบข้อมูลสำหรับการพยากรณ์ด้วยโครงข่ายประสาทเทียม


โดยขั้นตอนการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทยด้วยตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า โดยใช้ไลบรารี “nnet” ของโปรแกรม R [22] ซึ่งมีการอ้างอิงและถูกใช้งานในงานวิจัยที่ได้ถูกเผยแพร่ในวารสารที่เป็นที่ยอมรับต่างๆ [23-25] มีขั้นตอนการดำเนินการ ดังนี้

1. นำข้อมูลอนุกรมเวลาของราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทยลำดับที่ 1 ถึง 216 มาจัดเรียงใหม่ให้อยู่ในรูปเมตริกซ์ที่มีจำนวนคอลัมน์ m คอลัมน์ ดังรูปที่ 4 ซึ่งมีค่า m ตั้งแต่ 2 ถึง 10 คอลัมน์ เช่น ตัวอย่างชุดข้อมูลอนุกรมเวลานี้ถูกจัดให้อยู่ในรูปแบบเมตริกซ์ขนาด 3 คอลัมน์ ดังรูปที่ 5

[1,]	[,1]	[,2]	[,3]	[36,]	4.56	4.76	4.69	[71,]	4.22	4.12	4.22	[181,]	8.61	8.67	8.48
[1,]	3.76	3.84	3.81	[37,]	4.76	4.69	4.87	[72,]	4.12	4.22	4.20	[182,]	8.67	8.48	9.18
[2,]	3.84	3.81	4.00	[38,]	4.69	4.87	4.84	[73,]	4.22	4.20	4.54	[183,]	8.48	9.18	8.96
[3,]	3.81	4.00	4.01	[39,]	4.87	4.84	4.89	[74,]	4.20	4.54	4.56	[184,]	9.18	8.96	9.09
[4,]	4.00	4.01	3.89	[40,]	4.84	4.89	4.39	[75,]	4.54	4.56	4.47	[185,]	8.96	9.09	9.24
[5,]	4.01	3.89	4.25	[41,]	4.89	4.39	3.59	[76,]	4.56	4.47	4.57	[186,]	9.09	9.24	9.95
[6,]	3.89	4.25	3.96	[42,]	4.39	3.59	3.89	[77,]	4.47	4.57	4.72	[187,]	9.24	9.95	9.25
[7,]	4.25	3.96	4.45	[43,]	3.59	3.89	3.52	[78,]	4.57	4.72	4.72	[188,]	9.95	9.25	8.94
[8,]	3.96	4.45	4.18	[44,]	3.89	3.52	3.94	[79,]	4.72	4.72	4.40	[189,]	9.25	8.94	9.46
[9,]	4.45	4.18	4.36	[45,]	3.52	3.94	3.86	[80,]	4.72	4.40	4.46	[190,]	8.94	9.46	8.75
[10,]	4.18	4.36	4.13	[46,]	3.94	3.86	3.92	[81,]	4.40	4.46	4.50	[191,]	9.46	8.75	8.44
[11,]	4.36	4.13	5.05	[47,]	3.86	3.92	3.85	[82,]	4.46	4.50	4.40	[192,]	8.75	8.44	8.84
[12,]	4.13	5.05	4.81	[48,]	3.92	3.85	4.01	[83,]	4.50	4.40	4.36	[193,]	8.44	8.84	8.99
[13,]	5.05	4.81	5.00	[49,]	3.85	4.01	3.83	[84,]	4.40	4.36	4.03	[194,]	8.84	8.99	8.96
[14,]	4.81	5.00	5.24	[50,]	4.01	3.83	3.91	[85,]	4.36	4.03	4.45	[195,]	8.99	8.96	8.62
[15,]	5.00	5.24	4.87	[51,]	3.83	3.91	3.84	[86,]	4.03	4.45	5.71	[196,]	8.96	8.62	8.18
[16,]	5.24	4.87	5.34	[52,]	3.91	3.84	4.03	[87,]	4.45	5.71	6.48	[197,]	8.62	8.18	8.31
[17,]	4.87	5.34	4.70	[53,]	3.84	4.03	3.98	[88,]	5.71	6.48	6.63	[198,]	8.18	8.31	7.59
[18,]	5.34	4.70	5.44	[54,]	4.03	3.98	3.89	[89,]	6.48	6.63	5.71	[199,]	8.31	7.59	6.92
[19,]	4.70	5.44	3.82	[55,]	3.98	3.89	3.85	[90,]	6.63	5.71	4.69	[200,]	7.59	6.92	6.76
[20,]	5.44	3.82	3.46	[56,]	3.89	3.85	4.02	[91,]	5.71	4.69	4.18	[201,]	6.92	6.76	6.92
[21,]	3.82	3.46	3.71	[57,]	3.85	4.02	4.01	[92,]	4.69	4.18	4.35	[202,]	6.76	6.92	6.23
[22,]	3.46	3.71	3.38	[58,]	4.02	4.01	3.90	[93,]	4.18	4.35	4.40	[203,]	6.92	6.23	6.11
[23,]	3.71	3.38	3.73	[59,]	4.01	3.90	4.02	[94,]	4.35	4.40	4.95	[204,]	6.23	6.11	6.68
[24,]	3.38	3.73	3.66	[60,]	3.90	4.02	3.89	[95,]	4.40	4.95	5.01	[205,]	6.11	6.68	7.24
[25,]	3.73	3.66	3.94	[61,]	4.02	3.89	4.24	[96,]	4.95	5.01	4.96	[206,]	6.68	7.24	7.18
[26,]	3.66	3.94	4.56	[62,]	3.89	4.24	4.36	[97,]	5.01	4.96	4.97	[207,]	7.24	7.18	7.36
[27,]	3.94	4.56	4.18	[63,]	4.24	4.36	4.24	[98,]	4.96	4.97	4.83	[208,]	7.18	7.36	7.54
[28,]	4.56	4.18	4.75	[64,]	4.36	4.24	4.35	[99,]	4.97	4.83	5.02	[209,]	7.36	7.54	7.70
[29,]	4.18	4.75	4.21	[65,]	4.24	4.35	4.16	[100,]	4.83	5.02	4.81	[210,]	7.54	7.70	7.87
[30,]	4.75	4.21	4.79	[66,]	4.35	4.16	4.25	[101,]	5.02	4.81	5.05	[211,]	7.70	7.87	6.75
[31,]	4.21	4.79	3.94	[67,]	4.16	4.25	3.98	[102,]	4.81	5.05	4.89	[212,]	7.87	6.75	7.68
[32,]	4.79	3.94	4.25	[68,]	4.25	3.98	4.17	[103,]	5.05	4.89	4.73	[213,]	6.75	7.68	7.61
[33,]	3.94	4.25	3.99	[69,]	3.98	4.17	4.22	[104,]	4.89	4.73	4.74	[214,]	6.78	7.61	8.07
[34,]	4.25	3.99	4.56	[70,]	4.17	4.22	4.12	[105,]	4.73	4.74	4.73				
[35,]	3.99	4.56	4.76												

รูปที่ 5 การจัดรูปแบบข้อมูลสำหรับการพยากรณ์ด้วยตัวแบบโครงข่ายประสาทเทียมของราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทยตั้งแต่ค่าที่ 1 ถึง 216

2. นำข้อมูลที่ได้จากข้อที่ 1 มาใช้สำหรับการสอนตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า โดยใช้ข้อมูลในคอลัมน์ที่ 1 ถึง 2 เป็นข้อมูลป้อนเข้าและค่าคอลัมน์ที่ 3 เป็นค่าเป้าหมาย ซึ่งค่าทั้งสองส่วนจะถูกป้อนเข้าสู่ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าผ่านความสัมพันธ์ของฟังก์ชันในชั้นซ่อนตัว เพื่อแปลงค่าข้อมูลที่ไม่เป็นเชิงเส้นตรงให้อยู่ในรูปแบบของข้อมูลเชิงเส้นตรง สำหรับการสร้างตัวแบบทำนายของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าจากความสัมพันธ์ระหว่างโหนดและค่าเป้าหมาย ซึ่งโปรแกรมจะทำการหาตัวแบบที่เหมาะสมที่สุดของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า โดยใช้วิธีการหาค่าที่เหมาะสมที่สุดของค่าพารามิเตอร์ต่างๆ ด้วยวิธี Broyden-Fletcher-Goldfarb-Shanno (BFGS) เพื่อให้ค่ากำลังสองน้อยที่สุด เพื่อใช้ตัวแบบดังกล่าวในการพยากรณ์ ดังรูปที่ 6 - 7



รูปที่ 6 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมสำหรับการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย

```

Read 227 items
# weights: 41
initial value 7320.092400
iter 10 value 359.415698
iter 20 value 40.368432
iter 30 value 36.022864
iter 40 value 34.758134
iter 50 value 34.230676
iter 60 value 33.038144
iter 70 value 32.729556
iter 80 value 32.609406
iter 90 value 32.575691
iter 100 value 32.556808
final value 32.556808
stopped after 100 iterations

```

รูปที่ 7 การหาตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมที่สุดสำหรับการพยากรณ์

ในรูปที่ 7 ตัวแบบโครงข่ายประสาทเทียมถูกกำหนดให้ทำการเรียนรู้จำนวน 100 รอบ ซึ่งแต่ละรอบจะให้เรียนรู้และปรับค่ากำลังสองน้อยที่สุดให้มีค่าน้อยลงเรื่อยๆ จนกระทั่งรอบการเรียนรู้รอบที่ 100 มีค่ากำลังสองน้อยที่สุดเท่ากับ 32.556808 โดยสามารถอธิบายการคำนวณค่ากำลังสองน้อยที่สุดจากผลรวมของค่าส่วนเหลือ (Residuals) ยกกำลังสอง ดังรูปที่ 8 นอกจากนี้ ค่าถ่วงน้ำหนักต่างๆ ของโครงข่ายประสาทเทียมสามารถอธิบายดังรูปที่ 9

```
> as.vector(model$residuals)
[1] -0.098878066 0.036686228 0.025699127 -0.232153424
[5] 0.152896804 -0.157392321 0.216139778 -0.077739374
[9] -0.048303472 -0.195881520 0.696490144 -0.189599779
[13] 0.049529619 0.317978960 -0.266061898 0.306795738
[17] -0.479608617 0.598985704 -1.538871722 -0.016114674
[21] -0.098920875 -0.227195314 0.028949222 0.121395258
[25] 0.100685571 0.704317503 -0.164556089 0.318587340
[29] -0.337365765 0.338328513 -0.648627709 0.119361455
[33] -0.155512637 0.311388359 0.409614799 0.004582717
[37] 0.100418442 0.038705922 0.002100198 -0.501746596
[41] -1.014633825 -0.028800151 -0.264960049 0.065070350
[45] 0.105704938 -0.125198834 -0.153380254 -0.019362801
[49] -0.185969885 -0.167175515 -0.138737893 0.009984682
[53] -0.033554123 -0.244458259 -0.228943492 0.011069501
[57] -0.008335176 -0.235430754 -0.080111709 -0.164446404
[61] 0.137093631 0.246842358 -0.123059350 -0.047954471
[65] -0.200316255 -0.112664839 -0.303684887 -0.073815219
[69] 0.074286282 -0.162621174 -0.065301418 -0.050463523
[73] 0.231586448 0.154878214 -0.132690789 -0.012055510
[77] 0.154881677 0.044785380 -0.360106784 -0.145104884
[81] 0.010679682 -0.137048408 -0.165743552 -0.429054138
[85] 0.148423948 1.426812986 0.180576767 -0.047499379
[89] -0.867098018 -0.964012343 -0.410821818 -0.081887965
[93] 0.077038620 0.508235936 0.251070793 -0.040887559
[97] -0.041389083 -0.159585490 0.088258621 -0.131557062
[101] 0.109372735 -0.056801760 -0.266211678 -0.107818651
[105] -0.043113960 -0.034811004 0.046886040 -0.028820835
[109] -0.137144990 0.396250976 0.522140752 0.322691225
[113] -0.108798355 -0.277937386 -0.286519997 0.135513593
[117] 0.042958529 0.458680236 0.808255870 0.345437763
[121] -0.016121371 -0.0399993613 -0.198120205 -0.161726674
[125] -0.463004012 -0.250414655 0.619452951 0.471082345
[129] -0.309941452 0.099437482 0.224633108 0.148200393
[133] 0.600308611 0.081119046 -0.365166480 -0.170027262
[137] 1.643172735 -0.069899281 0.093180556 -0.553988138
[141] 0.218861119 -0.522558064 0.305235757 -0.016717451
[145] -0.171802200 0.648439806 -0.954858683 0.300284632
[149] -0.032963861 -1.221189137 0.235404911 0.020518957
[153] 0.930451784 0.522960748 -0.155927934 0.273119481
[157] 0.421163162 0.393081902 -0.001381615 0.011303164
[161] 0.154872886 -0.460999585 -0.181601988 -0.193711776
[165] 0.056118920 -0.021494622 0.118614206 0.038025502
[169] -0.148052263 0.402003604 -0.175131628 -0.543946798
[173] 0.041023382 -0.844017650 0.447368069 0.278875607
[177] 0.497829532 0.051978431 -0.049815925 -0.059404103
[181] -0.305968680 0.632843435 0.127616268 0.049399974
[185] 0.129819907 0.751433923 0.248762165 -0.054052821
[189] 0.473493070 -0.284405495 0.009237640 0.397789905
[193] 0.165445310 -0.070667096 -0.434324437 -0.444187725
[197] 0.241727282 -0.846558606 -0.398045352 -0.057958422
[201] 0.179961348 -0.660455755 -0.145656584 0.546086914
[205] 0.482201095 -0.236022239 0.207156769 0.147869604
[209] 0.100453855 0.092478274 -1.222091808 0.371920345
[213] 0.869744293 0.110696633
> sum(as.vector(model$residuals)^2)
[1] 32.55681
```

รูปที่ 8 ค่าส่วนเหลือของตัวแบบและค่ากำลังสองน้อยที่สุดของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมที่สุดสำหรับการพยากรณ์

```
R Console
a 2-10-1 network with 41 weights
options were - linear output units
b->h1 i1->h1 i2->h1
-0.31 -1.34 -0.72
b->h2 i1->h2 i2->h2
8.54 1.80 -2.87
b->h3 i1->h3 i2->h3
-7.79 1.74 1.39
b->h4 i1->h4 i2->h4
-0.02 -2.36 2.34
b->h5 i1->h5 i2->h5
0.86 1.26 -1.75
b->h6 i1->h6 i2->h6
1.16 0.19 -1.49
b->h7 i1->h7 i2->h7
0.49 0.14 -0.02
b->h8 i1->h8 i2->h8
0.89 1.82 0.90
b->h9 i1->h9 i2->h9
1.93 -1.57 -1.19
b->h10 i1->h10 i2->h10
6.27 0.45 -1.69
b->o h1->o h2->o h3->o h4->o h5->o h6->o h7->o h8->o h9->o h10->o
4.10 -5.13 -3.67 7.33 -2.70 -3.53 3.69 0.26 -0.31 -7.67 -1.79
```

รูปที่ 9 ค่าถ่วงน้ำหนักของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมที่สุดสำหรับการพยากรณ์

3. เมื่อได้ตัวแบบที่เหมาะสมสำหรับการพยากรณ์ ซึ่งเกิดจากการสอนให้ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าเรียนรู้และสร้างฟังก์ชันการทำนายจากชุดข้อมูลที่ 1 ถึง 216 แล้วนั้น ข้อมูลลำดับที่ 215 และ 216 ซึ่งเป็นข้อมูลราคาข้าวโพดเลี้ยงสัตว์ในเดือนพฤศจิกายนและธันวาคม พ.ศ. 2557 โดยมีค่าเท่ากับ 7.61 และ 8.07 ตามลำดับ จะถูกป้อนเข้าสู่ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าดังกล่าว เพื่อพยากรณ์ค่าที่ 217 ซึ่งค่าพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์ของเดือนมกราคม พ.ศ. 2558 มีค่าเท่ากับ 8.23 ดังรูปที่ 10

```
> Input_data
  X1  X2
1 7.61 8.07
> predict(model, Input_data)
      [,1]
[1,] 8.233705
>
```

รูปที่ 10 การพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทยสำหรับค่าที่ 217

4. การประเมินประสิทธิภาพของตัวแบบพยากรณ์

เพื่อประเมินประสิทธิภาพการพยากรณ์ของตัวแบบต่างๆ เกณฑ์ประเมินความถูกต้องของการพยากรณ์ต่างๆ จึงถูกใช้เพื่อวัดประสิทธิภาพ โดยเกณฑ์ที่ใช้ในการประเมินประสิทธิภาพของตัวแบบพยากรณ์ในงานวิจัยนี้มี 3 เกณฑ์ ดังนี้

1. ค่าเฉลี่ยของความคลาดเคลื่อนสัมบูรณ์

$$MAE = \text{mean}(|e_t|) \quad (3)$$

2. ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง

$$RMSE = \sqrt{\text{mean}(e_t^2)} \quad (4)$$

3. ค่าเฉลี่ยของเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์

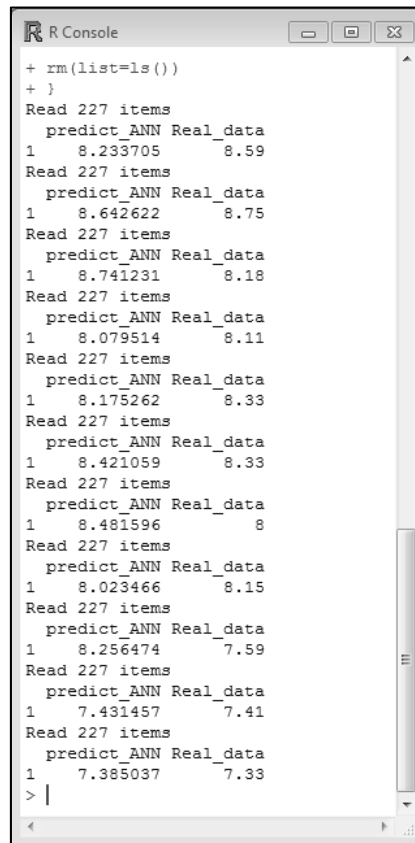
$$MAPE = \text{mean}(|p_t|) \quad (5)$$

เมื่อ e_t คือ ความคลาดเคลื่อนของการพยากรณ์ ณ เวลา t

p_t คือ ค่าร้อยละของความคลาดเคลื่อนของการพยากรณ์เทียบกับค่าจริง ณ เวลา t

ผลการทดลอง

จากผลการพัฒนาตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมที่สุด ตัวแบบที่เหมาะสมดังกล่าวใช้ข้อมูลในอดีต 2 ค่าย้อนหลัง เพื่อพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย ซึ่งผลการพยากรณ์ของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าถูกแสดงในรูปที่ 11 โดยการเขียนชุดคำสั่งเป็นการทำแบบวนซ้ำตามจำนวนชุดข้อมูลสำหรับทดสอบประสิทธิภาพการพยากรณ์ของตัวแบบพยากรณ์ซึ่งจะใช้คำสั่งในการล้างข้อมูลที่ได้ประมวลผลก่อนหน้า (rm(list=ls())) เพื่อไม่ให้มีค่าคงค้างใดที่อาจเป็นผลกระทบต่อการพยากรณ์ โดยผลของการพยากรณ์ของตัวแบบต่างๆ ถูกแสดงในตารางที่ 1



```
R Console
+ rm(list=ls())
+ }
Read 227 items
predict_ANN Real_data
1 8.233705 8.59
Read 227 items
predict_ANN Real_data
1 8.642622 8.75
Read 227 items
predict_ANN Real_data
1 8.741231 8.18
Read 227 items
predict_ANN Real_data
1 8.079514 8.11
Read 227 items
predict_ANN Real_data
1 8.175262 8.33
Read 227 items
predict_ANN Real_data
1 8.421059 8.33
Read 227 items
predict_ANN Real_data
1 8.481596 8
Read 227 items
predict_ANN Real_data
1 8.023466 8.15
Read 227 items
predict_ANN Real_data
1 8.256474 7.59
Read 227 items
predict_ANN Real_data
1 7.431457 7.41
Read 227 items
predict_ANN Real_data
1 7.385037 7.33
> |
```

รูปที่ 11 ผลการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทยสำหรับค่าที่ 217 ถึง 227

ตารางที่ 1 ผลการเปรียบเทียบประสิทธิภาพของการพยากรณ์ระหว่างตัวแบบ Combined model, ARIMA และ ANN

ช่วงเวลา	ราคาข้าวโพดเลี้ยงสัตว์	การพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์		
		Combined model*	ARIMA	ANN
ม.ค.-58	8.59	8.12	8.04	8.23
ก.พ.-58	8.75	8.26	8.70	8.64
มี.ค.-58	8.18	8.43	8.83	8.74
เม.ย.-58	8.11	8.37	8.37	8.08
พ.ค.-58	8.33	8.31	8.00	8.18
มิ.ย.-58	8.33	8.33	8.23	8.42
ก.ค.-58	8.00	8.35	8.39	8.48
ส.ค.-58	8.15	8.25	7.75	8.02
ก.ย.-58	7.59	8.23	7.90	8.26
ต.ค.-58	7.41	8.02	7.57	7.43
พ.ย.-58	7.33	7.81	7.60	7.39
	MAE	0.3336	0.3155	0.2418
	RMSE	0.3976	0.3594	0.3285
	MAPE	4.22%	3.91%	3.01%

หมายเหตุ ค่า Combined model* คือ ค่าที่ได้จากงานวิจัยการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย (วรารคณา เรียนสุทธิ, 2560)

สรุปและวิจารณ์ผลการทดลอง

จากการประเมินประสิทธิภาพของตัวแบบพยากรณ์ทั้งสามตัวแบบ โดยอาศัยเกณฑ์ประเมินประสิทธิภาพ 3 เกณฑ์ ดังที่แสดงในตารางที่ 1 พบว่าตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าให้ค่าความแม่นยำมากกว่าตัวแบบอาร์มาและตัวแบบการพยากรณ์รวมระหว่างวิธีบอซซ์-เจนกินส์และวิธีการปรับให้เรียบด้วยเส้นโค้งเลขชี้กำลังที่มีแนวโน้มแบบแฉก ซึ่งแสดงให้เห็นว่าตัวแบบอาร์มาที่สร้างตัวแบบโดยใช้สมมติฐานของความสัมพันธ์ของค่าในอดีตแบบเชิงเส้นตรงอาจไม่สามารถให้ค่าการพยากรณ์ที่เหมาะสมสำหรับข้อมูลราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย นอกจากนี้ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมสามารถสร้างตัวแบบพยากรณ์ที่ซับซ้อนในชั้นซ่อนตัว จากข้อมูลอดีตย้อนหลังเพียง 2 ค่า และใช้ข้อกำหนดไม่มากนักเมื่อเปรียบเทียบกับตัวแบบอาร์มาในการสร้างตัวแบบหรือตัวแบบการพยากรณ์รวมระหว่างวิธีบอซซ์-เจนกินส์และวิธีการปรับให้เรียบด้วยเส้นโค้งเลขชี้กำลังที่มีแนวโน้มแบบแฉกที่ถูกสร้างด้วยวิธีที่ซับซ้อนกว่าตัวแบบอาร์มา ดังนั้น ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมที่สุดจากการวิจัยสามารถถูกใช้เป็นเครื่องมือในการพยากรณ์ราคาข้าวโพดเลี้ยงสัตว์รายเดือนของประเทศไทย เพื่อสนับสนุนการตัดสินใจสำหรับการวางแผนการผลิตอาหารเลี้ยงสัตว์ให้เกิดประสิทธิภาพได้

เอกสารอ้างอิง

1. The World Bank Data. 2017. Agriculture, Value Added (% of GDP). Available from URL: <http://data.worldbank.org/indicator/NV.AGR.TOTL.ZS?locations=TH>. 15 May 2017.
2. Food and Agriculture Organization of the United Nations. 2017. Food Outlook Biannual Report on Global Food Markets. Available from URL: <http://www.fao.org/3/a-i6198e.pdf>. p.122. 15 May 2017.
3. Bureau of Animal Nutrition Development. 2017. Animal Feed. Available from URL: http://nutrition.dld.go.th/SERVICE/feed_calculate/calculate.htm. 15 May 2017.
4. Office of Agricultural Economic. 2017. Monthly Price of Maize. Available from URL: <http://www.oae.go.th/download/price/monthlyprice/maize.pdf>. 15 May 2017.
5. Krzemien, A., Fernández, P. R., Sánchez, A. S. and Lasheras, F. S. 2015. Forecasting European Thermal Coal Spot Prices. *Journal of Sustainable Mining*. 14(4): 203-210.
6. Livina, V. N., Lohmann, G., Mudelsee, M. and Lenton, T. M. 2013. Forecasting the Underlying Potential Governing the Time Series of a Dynamical System. *Physica A: Statistical Mechanics and its Applications* 392(18): 3891-3902.
7. Ansuji, A. P., Camargo, M. E., Radharamanan, R. and Petry, D.G. 1996. Sales Forecasting Using Time Series and Neural Networks. *Computers & Industrial Engineering* 31(1-2): 421-424.
8. Khashei, M., and Bijari, M. 2011. A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting. *Applied Soft Computing*. 11: 2664-2675.
9. Lasheras, F. S., de Cos Juez, F. J., Sánchez, A. S., Krzemien, A. and Fernández, P. R. 2015. Forecasting the COMEX Copper Spot Price by Means of Neural Networks And ARIMA Models. *Resources Policy*. 45: 37-43.
10. Weron, R., 2014. Electricity Price Forecasting: A Review of the State-Of-The-Art with a Look into the Future. *International journal of forecasting* 30(4): 1030-1081.
11. Koutroumanidis, T., Ioannou, K. and Arabatzis, G. 2009. Predicting Fuelwood Prices in Greece with the Use of ARIMA Models, Artificial Neural Networks and a Hybrid ARIMA-ANN Model. *Energy Policy* 37(9): 3627-3634.
12. Bowden, N. and Payne, J. E. 2008. Short Term Forecasting of Electricity Prices for MISO Hubs: Evidence from ARIMA-EGARCH Models. *Energy Economics*. 30(6): 3186-3197.

13. Sujjaviriyasup, T. 2017. Forecasting Thailand's Monthly Export Quantity of Rubber Compound using Support Vector Machine Model. *Srinakharinwirot Science Journal*. 33(1):205-220. (In Thai)
14. Li, G. Q., Xu, S. W. and Li, Z. M. 2010. Short-Term Price Forecasting for Agro-Products Using Artificial Neural Networks. *Agriculture and Agricultural Science Procedia*. 1: 278-287.
15. Moghaddam, A. H., Moghaddam, M. H. and Esfandyari, M. 2016. Stock Market Index Prediction Using Artificial Neural Network. *Journal of Economics, Finance and Administrative Science*. 21(41): 89-93.
16. Thakur, G. S. M., Bhattacharyya, R. and Mondal, S. S. 2016. Artificial Neural Network Based Model for Forecasting of Inflation in India. *Fuzzy Information and Engineering*. 8(1): 87-100.
17. Riansut, W. 2017. Forecasting the Prices of Field Corn in Thailand. *RMUTP Research Journal*. 11(1): 1-14. (In Thai)
18. Khandakar, Y. and Hyndman, R. J. 2008. Automatic Time Series Forecasting: The Forecast Package for R. *Journal of Statistical Software*. 27(03): 1-22.
19. Muller, J., and Bogenberger, K. 2015. Time Series Analysis of Booking Data of a Free-Floating Carsharing System in Berlin. *Transportation Research Procedia*. 10: 345-354.
20. Kokic, P., Crimp, S., and Howden, M. 2014. A Probabilistic Analysis of Human Influence on Recent Record Global Mean Temperature Changes. *Climate Risk Management*. 3: 1-12.
21. Ghodhi, Z., Silva, S. E., and Hassani, H. 2015. *Bicoid* Signal Extraction with a Selection of Parametric and Nonparametric Signal Processing Techniques. *Genomics Proteomics Bioinformatics*. 13: 183-191.
22. B. Ripley, "Package 'nnet'," 2013.
23. Dias, J., Jaganathan, R. and Petrovic, S. 2013. Determining the Number of Beams in 3D Conformal Radiotherapy: A Classification Approach. *Procedia Technology*. 9: 958-967.
24. Rao, T. S., Rao, S. S. and Rao, C. R., 2012. Time Series Analysis: Methods and Applications. (Vol. 30). Elsevier.
25. Larose, D. T. and Larose, C. D. 2015. Data Mining and Predictive Analytics. *John Wiley & Sons*.

ได้รับบทความวันที่ 24 กรกฎาคม 2560

ยอมรับตีพิมพ์วันที่ 29 มกราคม 2561