



ตัวแบบผสมของตัวแบบอาร์มาและโครงข่ายประสาทเทียมด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต สำหรับการพยากรณ์ผลผลิตของผลิตภัณฑ์เนื้อไก่รายปี

เฉลิมชนม์ ไวยศดำรง และ ธรณินทร์ สัจจวิริยทรัพย์*

สาขาวิศวกรรมโลจิสติกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย

* ผู้นิพนธ์ประสานงาน โทรศัพท์ 0 2697 6707 อีเมล: thoranin_suj@utcc.ac.th DOI: 10.14416/j.kmutnb.2024.07.001

รับเมื่อ 22 สิงหาคม 2565 แก้ไขเมื่อ 17 ตุลาคม 2565 ตอบรับเมื่อ 3 พฤศจิกายน 2565 เผยแพร่ออนไลน์ 5 กรกฎาคม 2567

© 2024 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

บทคัดย่อ

สินค้าปศุสัตว์มีบทบาทที่สำคัญสำหรับการบริหารจัดการด้านความมั่นคงทางอาหาร โดยผลิตภัณฑ์เนื้อไก่เป็นหนึ่งในสินค้าปศุสัตว์ที่สำคัญ ซึ่งเป็นแหล่งโปรตีนที่สำคัญสำหรับประชากรและนิยมบริโภคในหลายประเทศทั่วโลก รวมทั้งมีปริมาณความต้องการที่เพิ่มขึ้นอย่างต่อเนื่องตามการเพิ่มขึ้นของจำนวนประชากร สำหรับการบริหารจัดการด้านความมั่นคงทางอาหาร หนึ่งในสารสนเทศที่จำเป็น คือ ปริมาณการผลิตด้านอุปทานเพื่อให้สามารถเตรียมปริมาณผลิตภัณฑ์เนื้อไก่ที่สามารถเข้าถึงได้และเพียงพอสำหรับประชากร แต่ปริมาณการผลิตในแต่ละช่วงเวลามีลักษณะที่ไม่แน่นอน ซึ่งเป็นผลจากปัจจัยที่ไม่สามารถควบคุมได้ การพยากรณ์จึงเข้ามามีบทบาทที่สำคัญเพื่อทำนายค่าในอนาคต โดยงานวิจัยนี้ พัฒนาและนำเสนอตัวแบบผสมของตัวแบบอาร์มาและตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต โดยนำตัวแบบผสมดังกล่าวเปรียบเทียบกับประสิทธิภาพกับตัวแบบพยากรณ์ 4 ตัวแบบ ได้แก่ ตัวแบบอาร์มา ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่าย ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลแบบมีแนวโน้ม และตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชัน ซึ่งตัวแบบพยากรณ์ต่าง ๆ เปรียบเทียบตามเกณฑ์การวัดประสิทธิภาพ 3 เกณฑ์ ได้แก่ ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตร จากผลการเปรียบเทียบแสดงให้เห็นว่า ตัวแบบผสมที่เสนอมีประสิทธิภาพดีกว่าตัวแบบพยากรณ์ต่าง ๆ โดยมีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยกว่าร้อยละ 10 ซึ่งมีความแม่นยำสูงและสามารถใช้เป็นเครื่องมือสำหรับการทำนายปริมาณการผลิตของผลิตภัณฑ์เนื้อไก่ประกอบการวางแผนและบริหารจัดการด้านความมั่นคงทางอาหาร

คำสำคัญ: เนื้อไก่ ตัวแบบผสม วิธีการค้นหาค่าที่เหมาะสม การพยากรณ์อนุกรมเวลา การเรียนรู้ของเครื่อง

การอ้างอิงบทความ: เฉลิมชนม์ ไวยศดำรง และ ธรณินทร์ สัจจวิริยทรัพย์, “ตัวแบบผสมของตัวแบบอาร์มาและโครงข่ายประสาทเทียมด้วยวิธีการกึ่งนิวตันแบบมีขอบเขตสำหรับการพยากรณ์ผลผลิตของผลิตภัณฑ์เนื้อไก่รายปี,” วารสารวิชาการพระจอมเกล้าพระนครเหนือ, ปีที่ 34, ฉบับที่ 4, หน้า 1-15, เลขที่บทความ 244-096260, ต.ค.-ธ.ค. 2567.



A Hybrid ARIMA and Artificial Neural Networks Model Using L-BFGS-B Method for Forecasting the Annual Chicken Meat Production

Chalermchon Visavadamrong and Thoranin Sujjaviriyasup*

Logistics Engineering, School of Engineering, University of the Thai Chamber of Commerce, Bangkok, Thailand

* Corresponding Author, Tel. 0 2697 6707, E-mail: thoranin_suj@utcc.ac.th DOI: 10.14416/j.kmutnb.2024.07.001

Received 22 August 2022 ; Revised 17 October 2022 ; Accepted 3 November 2022; Published online: 5 July 2024

© 2024 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

Abstract

Livestock products play an important role in food security management. One of the livestock products is chicken meat, which is a source of protein and popular staple food for human all over the world. Moreover, the demand of chicken meat tends to increase due to population increment. For food security management, one of the most important information is production of supply side in order to provide available and sufficient production for people. However, the production of chicken meat is fluctuating and uncertain in each year due to uncontrolled effects. Consequently, forecasting techniques play a crucial role for prediction in advance. In this research, a hybridization of ARIMA, Feed-forward neural network, and L-BFGS-B methods is developed and proposed to extrapolate production of chicken meat in advance. Furthermore, the proposed model is compared to four forecasting models, which are ARIMA, Holt's method, simple exponential smoothing, and support vector regression, respectively. The comparison is based on three accuracy measures that are mean absolute error, mean absolute percentage error, and symmetric mean absolute percentage error, respectively. The empirical results revealed that the proposed model outperforms other forecasting models. Moreover, the proposed model provides less than 10% of mean absolute percentage error, which indicates that the proposed model can provide more accuracy of forecasting. Therefore, the proposed model can be a promising tool for prediction of chicken meat productions in order to support decision making on food security management.

Keywords: Chicken Meat, Hybrid Model, Optimization Method, Time Series Forecasting, Machine Learning

Please cite this article as: C. Visavadamrong and T. Sujjaviriyasup, "A Hybrid ARIMA and Artificial neural networks model using L-BFGS-B method for forecasting the annual chicken meat production," *The Journal of KMUTNB*, vol. 34, no. 4, pp. 1-15, ID. 244-096260, Oct.-Dec. 2024 (in Thai).

1. บทนำ

สำหรับการจัดการด้านความมั่นคงทางอาหาร สินค้าปศุสัตว์เป็นหนึ่งในปัจจัยที่สำคัญและมีบทบาทที่สำคัญในมิติของความมั่นคงทางอาหาร ผลิตภัณฑ์เนื้อไก่เป็นหนึ่งในสินค้าปศุสัตว์ที่สำคัญ [1]–[3] ซึ่งเป็นแหล่งโปรตีนสำหรับประชากรและนิยมบริโภคในหลายประเทศทั่วโลก นอกจากนี้ ปริมาณความต้องการผลิตภัณฑ์เนื้อไก่มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องตามการเพิ่มขึ้นของจำนวนประชากร ความเพียงพอด้านอุปทานของผลิตภัณฑ์เนื้อไก่จึงเป็นหนึ่งในปัจจัยที่สำคัญของการจัดการด้านความมั่นคงทางอาหารเพื่อให้ประชากรสามารถเข้าถึงได้อย่างอิสระและปลอดภัยสำหรับอาหารที่มีปริมาณที่เพียงพอได้ตลอดเวลาเพื่อดำรงชีวิตอย่างมีคุณภาพ

การวางแผนเพื่อบริหารจัดการความมั่นคงทางอาหารที่เหมาะสมจำเป็นต้องพิจารณาความสมดุลระหว่างอุปสงค์และอุปทานในภาพรวมระดับประเทศ ซึ่งจำเป็นต้องพึ่งพาข้อมูลและสารสนเทศที่เป็นประโยชน์ประกอบการตัดสินใจ โดยปริมาณการผลิตเป็นหนึ่งในปัจจัยที่สำคัญเพื่อประกอบการพิจารณาด้านอุปทานให้เพียงพอต่อความต้องการที่เกิดขึ้น แต่ปริมาณผลผลิตที่สามารถผลิตได้ในแต่ละปีมีลักษณะไม่คงที่และไม่แน่นอน ซึ่งได้รับผลกระทบจากปัจจัยที่ไม่สามารถควบคุมได้ต่างๆ

การพยากรณ์ปริมาณผลผลิตที่กำลังจะเกิดขึ้นจึงเข้ามามีบทบาทที่สำคัญประกอบการวางแผนเพื่อบริหารจัดการด้านอุปทานให้สอดคล้องและเหมาะสมกับอุปสงค์ที่จะเกิดขึ้น ความแม่นยำของผลการพยากรณ์จึงมีความน่าสนใจเพื่อให้สามารถวางแผนและบริหารจัดการด้านความมั่นคงทางอาหารให้เกิดความเหมาะสมและใกล้เคียงกับสถานการณ์ที่กำลังจะเกิดขึ้นจริงมากที่สุด วิธีการพยากรณ์ต่าง ๆ จึงได้รับความนิยมและใช้สำหรับการทำนายปริมาณอุปทานของผลิตภัณฑ์เนื้อไก่ในอนาคต โดยหนึ่งในวิธีการพยากรณ์ที่สะดวกต่อการใช้งาน คือ การวิเคราะห์อนุกรมเวลา ซึ่งอาศัยเพียงข้อมูลปริมาณผลผลิตที่สามารถผลิตได้ในแต่ละปีตั้งแต่ปัจจุบันย้อนหลังไปในอดีต เพื่อสร้างสมการความสัมพันธ์สำหรับการทำนายปริมาณผลผลิตที่จะสามารถผลิต

ได้ในอดีตไป

โดยตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่าย (Simple Exponential Smoothing; SES) เป็นหนึ่งในตัวแบบพยากรณ์ข้อมูลอนุกรมเวลาที่ใช้สำหรับการอธิบายรูปแบบการเปลี่ยนแปลงระดับของข้อมูลอนุกรมเวลาในแต่ละช่วงเวลาและยังคงได้รับความนิยมประยุกต์ใช้ในงานวิจัย [4] แต่ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่ายไม่สามารถอธิบายข้อมูลที่มีรูปแบบของแนวโน้มส่งผลให้เกิดการพัฒนาตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลแบบมีแนวโน้ม (Holt's Model; Holt) เพื่อให้สามารถอธิบายทั้งรูปแบบการเปลี่ยนแปลงของระดับและแนวโน้มของข้อมูลอนุกรมเวลาในแต่ละช่วงเวลา ซึ่งยังคงได้รับความนิยมประยุกต์ใช้ในงานวิจัยในปัจจุบัน [5] นอกจากนี้ ตัวแบบอาร์มา (Autoregressive Integrated Moving Average; ARIMA) เป็นอีกหนึ่งในตัวแบบพยากรณ์ข้อมูลอนุกรมเวลาที่ได้รับการยอมรับว่ามีประสิทธิภาพดีในการทำนายข้อมูลอนุกรมเวลาที่มีความสัมพันธ์เชิงเส้นตรงและใช้เป็นหนึ่งในตัวแบบพยากรณ์มาตรฐานสำหรับการเปรียบเทียบประสิทธิภาพกับตัวแบบพยากรณ์อื่น ๆ ซึ่งประยุกต์ใช้ในงานวิจัยต่าง ๆ ในปัจจุบัน [6]–[9] อย่างไรก็ตาม ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลที่มีโครงสร้างที่ไม่ซับซ้อนและตัวแบบอาร์มาที่สร้างจากสมมติฐานความสัมพันธ์เชิงเส้นตรงอาจไม่สามารถอธิบายและพยากรณ์ข้อมูลอนุกรมเวลาที่มีความสัมพันธ์ที่ไม่เป็นเชิงเส้นตรงและข้อมูลอนุกรมเวลาที่มีความสัมพันธ์ที่ซับซ้อนได้อย่างมีประสิทธิภาพ

จากประเด็นดังกล่าว ตัวแบบการเรียนรู้ของเครื่อง (Machine Learning) จึงเข้ามามีบทบาทที่สำคัญสำหรับปัญหาดังกล่าว โดยตัวแบบการเรียนรู้ของเครื่องสามารถสร้างโครงความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงและซับซ้อนสำหรับการพยากรณ์ข้อมูลอนุกรมเวลา รวมทั้งตัวแบบการเรียนรู้ของเครื่องสามารถปรับเปลี่ยนโครงสร้างและความสัมพันธ์ได้ตามสถานการณ์ของการใช้งานสำหรับการพยากรณ์ข้อมูลในลักษณะต่าง ๆ

ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า



(Feed-Forward Neural Network) เป็นหนึ่งในตัวแบบการเรียนรู้ของเครื่องด้วยหลักการลดความเสี่ยงเชิงประจักษ์ (Empirical Risk Minimization) ซึ่งได้รับความนิยมและประยุกต์ใช้สำหรับการพยากรณ์ข้อมูลอนุกรมเวลาในงานวิจัยต่าง ๆ [10]–[13] นอกจากนี้ตัวแบบซัพพอร์ตเวกเตอร์เรเกรสชัน (Support Vector Regression) เป็นอีกหนึ่งตัวแบบการเรียนรู้ของเครื่องที่สร้างสมการความสัมพันธ์เพื่อทำนายภายใต้หลักการลดความเสี่ยงเชิงโครงสร้าง (Structural Risk Minimization) และได้รับความนิยมสำหรับการพยากรณ์ข้อมูลอนุกรมเวลาเช่นเดียวกัน [11]–[13] อย่างไรก็ตามตัวแบบการเรียนรู้ของเครื่องทั้งสองต่างมีจุดเด่นและข้อจำกัดที่แตกต่างกันในแต่ละสถานการณ์และยังไม่มีงานวิจัยใดที่ยืนยันถึงประสิทธิภาพของตัวแบบใดที่โดดเด่นเหนือกว่าอีกตัวแบบอย่างชัดเจนในทุกสถานการณ์ส่งผลให้ตัวแบบทั้งสองต่างได้รับความนิยมประยุกต์ใช้ในงานวิจัยต่าง ๆ ในปัจจุบัน นอกจากนี้ การวิเคราะห์ข้อมูลอนุกรมเวลาเพื่อระบุความสัมพันธ์แบบเชิงเส้นตรงหรือแบบไม่เป็นเชิงเส้นตรงที่ชัดเจนเป็นเรื่องที่ยาก ซึ่งส่งผลให้จำเป็นต้องประยุกต์ใช้ตัวแบบต่าง ๆ เพื่ออธิบายรูปแบบความสัมพันธ์ของข้อมูลอนุกรมเวลาต่าง ๆ โดยตัวแบบพยากรณ์เชิงเดี่ยวอาจไม่มีประสิทธิภาพที่ดีเพียงพอสำหรับข้อมูลอนุกรมเวลาที่มีลักษณะความสัมพันธ์ที่ซับซ้อน ส่งผลให้ความสัมพันธ์ที่ซับซ้อนและตัวแบบพยากรณ์เชิงเดี่ยวไม่สามารถอธิบายได้ถูกรวมเข้ากับความสามารถเคลื่อนจากผลกระทบที่ไม่สามารถควบคุมได้ จึงทำให้มีความผิดพลาดเพิ่มมากขึ้น

สำหรับการลดความเสี่ยงของการพยากรณ์ข้อมูลอนุกรมเวลาที่มีความสัมพันธ์ที่ซับซ้อน ซึ่งประกอบไปด้วยความสัมพันธ์ทั้งแบบเชิงเส้นตรงและไม่เป็นเชิงเส้นตรง โดยการประยุกต์ใช้ตัวแบบผสมที่ประกอบไปด้วยตัวแบบที่สร้างสมการความสัมพันธ์เชิงเส้นตรงเพื่ออธิบายรูปแบบข้อมูลอนุกรมเวลาและตัวแบบที่สร้างสมการความสัมพันธ์ไม่เป็นเชิงเส้นตรงเพื่ออธิบายในส่วนของข้อมูลอนุกรมเวลาแบบไม่เป็นเชิงเส้นตรง [14]–[16] ถึงแม้ตัวแบบผสมนี้จะสามารถอธิบายรูปแบบความสัมพันธ์ของข้อมูลอนุกรมเวลาครอบคลุมทั้งแบบเชิงเส้นตรงและไม่เป็นเชิงเส้นตรง

ตัวแบบผสมนี้อาจไม่สามารถได้ตัวแบบที่เหมาะสม หากปราศจากการประยุกต์ใช้วิธีการหาค่าที่เหมาะสม เนื่องจากประสิทธิภาพการพยากรณ์ของตัวแบบการเรียนรู้ของเครื่องขึ้นอยู่กับทางเลือกค่าพารามิเตอร์ที่เหมาะสม

งานวิจัยนี้พัฒนาตัวแบบผสมของตัวแบบอาร์มาและตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าด้วยวิธีการกึ่งนิวตันสำหรับการพยากรณ์ปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่รายปี โดยตัวแบบผสมใช้จุดเด่นของตัวแบบอาร์มาที่มีประสิทธิภาพดีในการอธิบายและพยากรณ์ข้อมูลอนุกรมเวลาที่มีความสัมพันธ์เป็นแบบเชิงเส้นตรง ตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีประสิทธิภาพดีในการอธิบายและพยากรณ์ข้อมูลอนุกรมเวลาที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นตรง ในขณะที่วิธีการกึ่งนิวตันแบบมีขอบเขต (L-BFGS-B) ใช้จุดเด่นของการค้นหาค่าที่เหมาะสมสำหรับการเลือกค่าพารามิเตอร์ของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่เหมาะสมที่สุดเพื่อให้สามารถเพิ่มความแม่นยำของการพยากรณ์ปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่มากยิ่งขึ้น


โดยตัวแบบผสมที่นำเสนอเปรียบเทียบประสิทธิภาพการพยากรณ์กับตัวแบบพยากรณ์เชิงเดี่ยวทั้งตัวแบบเชิงสถิติและตัวแบบการเรียนรู้ของเครื่อง ได้แก่ ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่าย ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลแบบมีแนวโน้ม ตัวแบบอาร์มาและตัวแบบซัพพอร์ตเวกเตอร์เรเกรสชัน ซึ่งประยุกต์ใช้เกณฑ์การวัดประสิทธิภาพ 3 เกณฑ์ ได้แก่ ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error; MAE) ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error; MAPE) และร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตร (Symmetric Mean Absolute Percentage Error; sMAPE) ตามลำดับ โดยเกณฑ์การวัดประสิทธิภาพเหล่านี้ง่ายต่อการอธิบายและนิยมใช้ในการวิจัยต่าง ๆ

2. วัสดุ อุปกรณ์และวิธีการวิจัย

ข้อมูลที่ใช้ศึกษาและวิธีการพยากรณ์ต่าง ๆ ในงานวิจัยดังนี้

2.1 ข้อมูล

ข้อมูลปริมาณการผลิตของผลิตภัณฑ์เนื้อไก่รายปีเป็นข้อมูลอนุกรมเวลาที่เกิดขึ้นตั้งแต่ พ.ศ. 2504 จนกระทั่งถึง พ.ศ. 2563 ที่เผยแพร่บนเว็บไซต์ของฐานข้อมูลสถิติขององค์กรด้านอาหารและเกษตรกรรม (The Food and Agriculture Organization Corporate Statistical Database; FAOSTAT) โดยเป็นข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่รายปีของประเทศ บราซิล จีน อินเดีย และสหรัฐอเมริกา ซึ่งล้วนเป็นประเทศผู้ผลิตรายใหญ่ และมีกำลังการผลิตมาก ดังรูปที่ 1



รูปที่ 1 ปริมาณการผลิตของผลิตภัณฑ์เนื้อไก่รายปีของประเทศผู้ผลิตรายใหญ่

2.2 วิธีวิจัย

2.2.1 ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่าย

การสร้างตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่ายใช้หลักการของการหาค่าเฉลี่ยแบบถ่วงน้ำหนักระหว่างค่าประมาณระดับของช่วงเวลาก่อนหน้ากับข้อมูลอนุกรมเวลาในช่วงเวลาปัจจุบัน เพื่อเป็นค่าพยากรณ์สำหรับข้อมูลอนุกรมเวลาที่กำลังจะเกิดขึ้นในอนาคต โดยมีสมการดังนี้

สมการระดับ

$$I_t = \alpha y_t + (1 - \alpha) I_{t-1} \quad (1)$$

สมการการพยากรณ์

$$\hat{y}_{t+h|t} = I_t \quad (2)$$

เมื่อ I_t และ I_{t-1} คือ ค่าประมาณของระดับข้อมูลอนุกรมเวลา ณ เวลาที่ t และ $t - 1$ ตามลำดับ

α คือ ค่าการปรับเรียบของระดับข้อมูลอนุกรมเวลา ซึ่งมีค่าระหว่าง 0 ถึง 1

h คือ ค่าช่วงการพยากรณ์ไปข้างหน้า h ช่วงเวลา

$\hat{y}_{t+h|t}$ คือ ค่าพยากรณ์ล่วงหน้า h ช่วงเวลา เมื่อทราบข้อมูลอนุกรมเวลาตั้งแต่อดีตจนถึงปัจจุบัน ณ เวลาที่ t

จากสมการความสัมพันธ์ (1) และ (2) ประสิทธิภาพ

การพยากรณ์ของตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่ายจึงอาศัยการกำหนดค่าประมาณของระดับข้อมูลอนุกรมเวลาเริ่มต้นและค่าการปรับเรียบของระดับข้อมูลอนุกรมเวลาที่เหมาะสม ซึ่งการพิจารณาจะใช้เกณฑ์ค่าเฉลี่ยของผลรวมความคลาดเคลื่อนกำลังสองที่น้อยที่สุด โดยตัวแบบพยากรณ์ที่เหมาะสมได้จากการประยุกต์ใช้ฟังก์ชัน $ses()$ ของโปรแกรม R [17] จึงใช้สัญลักษณ์ SES ในส่วนของการนำเสนอผลการวิจัย เพื่อความกระชับ

2.2.2 ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลแบบมีแนวโน้ม

ในการสร้างตัวแบบจะเพิ่มสมการอธิบายความสัมพันธ์ของแนวโน้มจากตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่าย เพื่อให้สามารถอธิบายข้อมูลอนุกรมเวลาที่มีแนวโน้มได้ครอบคลุมมากยิ่งขึ้น ซึ่งมีสมการดังนี้

สมการระดับ

$$I_t = \alpha y_t + (1 - \alpha)(I_{t-1} + b_{t-1}) \quad (3)$$

สมการแนวโน้ม

$$b_t = \beta(I_t - I_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

สมการการพยากรณ์

$$\hat{y}_{t+h|t} = I_t + hb_t \quad (5)$$

เมื่อ I_t และ I_{t-1} คือ ค่าประมาณของระดับข้อมูลอนุกรมเวลา ณ เวลาที่ t และ $t-1$ ตามลำดับ

b_t และ b_{t-1} คือ ค่าประมาณของแนวโน้มข้อมูลอนุกรมเวลา ณ เวลาที่ t และ $t-1$ ตามลำดับ

α คือ ค่าการปรับเรียบของระดับข้อมูลอนุกรมเวลา ซึ่งมีค่าระหว่าง 0 ถึง 1

β คือ ค่าการปรับเรียบของแนวโน้มข้อมูลอนุกรมเวลา ซึ่งมีค่าระหว่าง 0 ถึง 1

h คือ ค่าช่วงการพยากรณ์ไปข้างหน้า h ช่วงเวลา

y_t คือ ค่าข้อมูลอนุกรมเวลาจริง ณ เวลาที่ t

$\hat{y}_{t+h|t}$ คือ ค่าพยากรณ์ล่วงหน้า h ช่วงเวลา เมื่อทราบข้อมูลในอดีตถึงข้อมูลปัจจุบัน ณ เวลาที่ t

จากสมการความสัมพันธ์ที่ (3)–(5) ประสิทธิภาพของตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลแบบมีแนวโน้มอาศัยการกำหนดค่าประมาณของระดับข้อมูลอนุกรมเวลาเริ่มต้น ค่าประมาณของแนวโน้มข้อมูลอนุกรมเวลาเริ่มต้น ค่าการปรับเรียบของระดับข้อมูลอนุกรมเวลา และค่าการปรับเรียบของแนวโน้มข้อมูลอนุกรมเวลาที่เหมาะสม โดยค่าเหล่านี้กำหนดด้วยการใช้เกณฑ์ค่าเฉลี่ยของผลรวมความคลาดเคลื่อนกำลังสองที่น้อยที่สุด ซึ่งตัวแบบที่เหมาะสมได้จากการใช้ฟังก์ชัน `holt()` ของโปรแกรม R [17] จะใช้สัญลักษณ์ Holt ในส่วนของการนำเสนอผลการวิจัยเพื่อการสื่อสารที่กระชับ

2.2.3 ตัวแบบอาร์มีนา

การประยุกต์ใช้ตัวแบบอาร์มีนาสำหรับการพยากรณ์ข้อมูลอนุกรมเวลาอาศัยหลักการของฟังก์ชันสหสัมพันธ์ในตัวเอง (Autocorrelation Function; ACF) และฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (Partial Autocorrelation Function; PACF) เพื่อสร้างสมการความสัมพันธ์สำหรับทำนายข้อมูลอนุกรมเวลา โดยมีสมการที่ (6) ดังนี้

$$\left(1 - \sum_{i=1}^p \phi_i B^i\right) (1-B)^d (Y_t - \mu) = \left(1 - \sum_{j=1}^q \theta_j B^j\right) \varepsilon_t \quad (6)$$

เมื่อ y_t และ ε_t คือ ค่าข้อมูลอนุกรมเวลาและค่าความคลาดเคลื่อน ณ เวลาที่ t ตามลำดับ

μ และ B คือ ค่าเฉลี่ยและตัวแปลงค่าอนุกรมเวลาแบบย้อนกลับ (Backward Shift Operator) ตามลำดับ

ϕ_i และ θ_j คือ ค่าสัมประสิทธิ์ตัวแบบอาร์มีนา

d คือ ผลต่างข้อมูลแบบอนุกรมเวลา

p และ q คือ ลำดับของตัวแบบอาร์มีนา

โดยการพิจารณาตัวแบบอาร์มีนาที่เหมาะสมใช้เกณฑ์สารสนเทศอะไกเกะ (Akaike's Information Criterion; AIC) สำหรับข้อมูลขนาดเล็กที่น้อยที่สุด ซึ่งได้จากการประยุกต์ใช้ฟังก์ชัน `auto.arima()` ของโปรแกรม R [17] แต่เนื่องจากลำดับของตัวแบบอาร์มีนาจะปรับเปลี่ยนไปตามชุดข้อมูลในแต่ละช่วงเวลาสำหรับการพิจารณาตัวแบบที่เหมาะสมที่สุดสำหรับข้อมูลชุดนั้น [18] จึงใช้สัญลักษณ์ ARIMA แทนตัวแบบอาร์มีนาที่ระบุลำดับ ARIMA(p, d, q) ดังนั้น จึงใช้สัญลักษณ์ ARIMA ในส่วนของการนำเสนอผลการวิจัยเพื่อความสะดวกของการนำเสนอ

2.2.4 ตัวแบบซัพพอร์ตเวกเตอร์เรกเรชัน

การสร้างสมการความสัมพันธ์ของตัวแบบซัพพอร์ตเวกเตอร์เรกเรชันสำหรับการพยากรณ์ [18] โดยมีสมการที่ (7) ดังนี้

$$f(x) = \sum_{i=1}^T (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (7)$$

เมื่อ α_i และ α_i^* คือ ค่าของลากรางจ์

$(\cdot, \cdot)$ คือ การคูณแบบดอท (Dot Product)

b คือ ค่าเอนเอียง

x_i คือ ข้อมูลลำดับที่ i

T คือ ขนาดข้อมูล

$K(x, x_i)$ คือ ฟังก์ชันเคอร์เนล

โดยฟังก์ชันเคอร์เนลที่ใช้สำหรับงานวิจัยนี้ ประกอบไปด้วยฟังก์ชันเชิงเส้นตรงและฟังก์ชันเรเดียลเบสิกสำหรับความสัมพันธ์แบบไม่เป็นเชิงเส้นตรง ดังนี้สมการที่ (8)

ฟังก์ชันเชิงเส้นตรง

$$K(x, x_i) = x^T x_i \quad (8)$$

ฟังก์ชันเรเดียลเบสิก ดังสมการที่ (9)

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (9)$$

เมื่อ γ คือ ค่าพารามิเตอร์ของฟังก์ชันเรเดียลเบสิก

โดยการสร้างสมการความสัมพันธ์เพื่อทำนายของตัวแบบซัพพอร์ตเวกเตอร์รีเกรดชันมีลักษณะคล้ายคลึงกับการวิเคราะห์สมการถดถอย ซึ่งจะต้องประกอบไปด้วยข้อมูลป้อนเข้าและข้อมูลเป้าหมาย เพื่อให้ตัวแบบซัพพอร์ตเวกเตอร์รีเกรดชันเรียนรู้และสร้างสมการความสัมพันธ์ จึงต้องจัดรูปแบบข้อมูลอนุกรมเวลาดังนี้

$$\begin{bmatrix} y_1 & y_2 & y_3 & \cdots & y_m \\ y_2 & y_3 & y_4 & \cdots & y_{m+1} \\ y_3 & y_4 & y_5 & \cdots & y_{m+2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ y_{t-m+1} & \cdots & y_{t-2} & y_{t-1} & y_t \end{bmatrix}$$

ข้อมูลคอลัมน์ $m - 1$ คอลัมน์แรกใช้สำหรับข้อมูลป้อนเข้าและคอลัมน์สุดท้ายใช้สำหรับเป็นข้อมูลเป้าหมายสำหรับการเรียนรู้และการสร้างสมการความสัมพันธ์ จึงใช้สัญลักษณ์ SVR ในส่วนของผลการวิจัยเพื่อให้เกิดความกระชับของการนำเสนอ

2.2.5 ตัวแบบผสมของตัวแบบอาร์มาและโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต

ตัวแบบผสมที่พัฒนาและนำเสนออาศัยหลักการของการรวมจุดเด่นของแต่ละวิธีเพื่อช่วยลดข้อด้อยของวิธีอื่น ๆ ให้ลดน้อยลง ส่งผลให้ได้ผลการพยากรณ์ที่มีความแม่นยำมากยิ่งขึ้น โดยตัวแบบผสมประยุกต์ใช้จุดเด่นของตัวแบบอาร์มาเพื่อสร้างสมการอธิบายข้อมูลอนุกรมเวลาที่มีความสัมพันธ์แบบเชิงเส้นตรงสำหรับทำนายส่วนประกอบของข้อมูลอนุกรมเวลาที่มีความสัมพันธ์แบบเชิงเส้นตรงในอนาคตได้อย่างเหมาะสม ส่วนตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าใช้จุดเด่นของความสามารถในการสร้างสมการความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงเพื่ออธิบายข้อมูลส่วนที่เหลือจากตัวแบบอาร์มาสำหรับทำนายข้อมูลที่มี

ความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงในอนาคต ซึ่งสามารถช่วยลดข้อจำกัดของตัวแบบอาร์มาที่ไม่สามารถอธิบายข้อมูลที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงได้ ในขณะที่วิธีการกึ่งนิวตันแบบมีขอบเขตใช้สำหรับการค้นหาจำนวนโนนดที่เหมาะสมของชั้นซ่อนตัว (Hidden Layer) ของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า ซึ่งเป็นหนึ่งในค่าพารามิเตอร์ที่สำคัญของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีผลโดยตรงต่อประสิทธิภาพการทำนาย หลังจากการรวมข้อมูลที่มีความสัมพันธ์ทั้งแบบเชิงเส้นตรงและไม่เป็นเชิงเส้นตรงเข้าด้วยกันจะได้ผลการพยากรณ์ที่มีความแม่นยำเพิ่มมากยิ่งขึ้น โดยขั้นตอนการดำเนินการต่าง ๆ ดังนี้

ขั้นตอนที่ 1 กำหนดขอบเขตการค้นหาจำนวนโนนดในชั้นซ่อนตัว โดยการระบุขอบเขตล่างและขอบเขตบนของโอกาสที่เป็นไปได้ดังสมการที่ (10)

$$l \leq \theta \leq u \quad (10)$$

เมื่อ l คือ ขอบเขตล่างของการค้นหาจำนวนโนนดในชั้นซ่อนตัว

θ คือ จำนวนโนนดในชั้นซ่อนตัวของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า

u คือ ขอบเขตบนของการค้นหาจำนวนโนนดในชั้นซ่อนตัว

ขั้นตอนที่ 2 กำหนดจำนวนโนนดในชั้นซ่อนตัวเริ่มต้น θ_0 และปรับค่าจำนวนโนนดในชั้นซ่อนตัวขึ้นทีละ 10 โดยกำหนดครั้งของการค้นหา $k = 0$

ขั้นตอนที่ 3 ตัวแบบอาร์มาพิจารณาตัวแบบที่เหมาะสมกับชุดข้อมูลสำหรับการสร้างตัวแบบ เพื่อพยากรณ์ค่าล่วงหน้าที่เหมาะสม 1 ช่วงเวลา ซึ่งค่าดังกล่าวเป็นข้อมูลที่มีความสัมพันธ์แบบเชิงเส้นตรง พร้อมทั้งให้ค่าส่วนเหลือ (Residuals) ซึ่งตัวแบบอาร์มาไม่สามารถสร้างสมการความสัมพันธ์เพื่ออธิบายได้ ดังสมการที่ (11)

$$y_t = \hat{L}_t + R_t \quad (11)$$

เมื่อ y_t คือ ค่าข้อมูลอนุกรมเวลาจริง ณ เวลาที่ t

$\hat{L}_t$ คือ ค่าประมาณส่วนประกอบเชิงเส้นตรงของข้อมูลอนุกรมเวลา t

R_t คือ ค่าของข้อมูลส่วนที่เหลือของข้อมูลอนุกรมเวลา t

ขั้นตอนที่ 4 จัดรูปแบบของข้อมูลส่วนเหลือให้อยู่ในรูปแบบดังนี้

$$\begin{bmatrix} R_{m+1} & R_{m+2} & R_{m+3} & \cdots & R_{2m} \\ R_{m+2} & R_{m+3} & R_{m+4} & \cdots & R_{2m+1} \\ R_{m+3} & R_{m+4} & R_{m+5} & \cdots & R_{2m+2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ R_{t-m+1} & \cdots & R_{t-2} & R_{t-1} & R_t \end{bmatrix}$$

โดยใช้ข้อมูล $m-1$ คอลัมน์แรกสำหรับเป็นชุดข้อมูลป้อนเข้า และคอลัมน์สุดท้ายเป็นชุดข้อมูลเป้าหมาย เพื่อให้โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าเรียนรู้และสร้างสมการความสัมพันธ์แบบไม่เป็นเชิงเส้นตรงสำหรับอธิบายและทำนายข้อมูลที่มีความสัมพันธ์ไม่เป็นเชิงเส้นตรง

ขั้นตอนที่ 5 ตัวแบบโครงข่ายประสาทเทียมสร้างสมการความสัมพันธ์ที่เหมาะสมด้วยค่าจำนวนโหนดที่กำหนดจากวิธีการกึ่งนิวตันแบบมีขอบเขต ดังสมการที่ (12)

$$R_{t+1} = h \left(\beta_0 + \sum_{j=1}^{\theta} \beta_j g \left(w_{0j} + \sum_{i=1}^m w_{ij} R_{t-(i-1)} \right) \right) \quad (12)$$

เมื่อ θ และ m คือ จำนวนโหนด (Node) ในชั้นซ่อนตัว ด้วยการปรับค่าจากจำนวนจริงให้เป็นจำนวนเต็มและจำนวนของข้อมูลป้อนเข้า

w_{0j} , w_{ij} และ R_t คือ ค่าเอนเอียง (Bias) ของโหนดที่ j ในชั้นของชั้นซ่อนตัว ค่าถ่วงน้ำหนัก (Weight) ของข้อมูลป้อนเข้าที่ i ไปยังโหนดที่ j และค่าส่วนเหลือซึ่งเป็นข้อมูลป้อนเข้าที่ลำดับ t ตามลำดับ

β_0 และ β_j คือ ค่าเอนเอียง (Bias) ของชั้นแสดงผล และค่าถ่วงน้ำหนัก (Weight) ของโหนดที่ j ไปยังชั้นแสดงผลตามลำดับ

$g(\bullet)$ และ $h(\bullet)$ คือ ฟังก์ชันไม่เป็นเชิงเส้นตรงของแต่ละโหนด

ในชั้นซ่อนตัวและฟังก์ชันเชิงเส้นตรงของความสัมพันธ์ระหว่างแต่ละโหนดและค่าเป้าหมายในชั้นแสดงผล

โดยตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าอาศัยหลักการลดความเสี่ยงเชิงประจักษ์ในการปรับค่าความผิดพลาดของการทำนายให้ลดน้อยลง ซึ่งรอบของการเรียนรู้จำนวน 100 รอบ ด้วยการลดค่าผลรวมกำลังสองของความคลาดเคลื่อนให้น้อยที่สุด เพื่อปรับค่าถ่วงน้ำหนักของแต่ละเส้นเชื่อมภายในโครงสร้างของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า และทำนายค่าข้อมูลที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นตรง

ขั้นตอนที่ 6 ดำเนินการรวมผลการพยากรณ์ข้อมูลทั้งแบบความสัมพันธ์เชิงเส้นตรงและไม่เป็นเชิงเส้นตรงเพื่อใช้เป็นค่าพยากรณ์ผลผลิตของผลิตภัณฑ์เนื้อไก่ ดังสมการที่ (13)

$$\hat{y}_{t+1} = \hat{L}_{t+1} + \hat{R}_{t+1} \quad (13)$$

เมื่อ $\hat{L}_{t+1}$ และ $\hat{R}_{t+1}$ คือ ค่าพยากรณ์ส่วนประกอบเชิงเส้นตรงของข้อมูลอนุกรมเวลาและค่าพยากรณ์ข้อมูลอนุกรมเวลาส่วนเหลือ ณ เวลาที่ $t+1$

$\hat{y}_{t+1}$ คือ ค่าพยากรณ์ล่วงหน้า ณ เวลาที่ $t+1$

ขั้นตอนที่ 7 คำนวณหาค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยและกำหนดให้เป็นฟังก์ชัน $f(\theta_k)$ เพื่อการพิจารณาปรับค่าพารามิเตอร์ใหม่ในครั้งต่อไป

ขั้นตอนที่ 8 พิจารณาความชันของฟังก์ชัน $f(\theta_k)$ และกำหนดเก็บค่าดังสมการที่ (14)

$$g_k = \nabla f(\theta_k) \quad (14)$$

เมื่อ g_k คือ ความชันของฟังก์ชันที่ k

ขั้นตอนที่ 9 พิจารณาทิศทางการค้นหาจำนวนโหนดของชั้นซ่อนตัวด้วยสมการที่ (15)

$$d_k = -H_k g_k \quad (15)$$

เมื่อ d_k คือ ทิศทางการปรับค่าจำนวนโหนดในชั้นซ่อนตัวของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่ k

H_k คือ เมตริกซ์ผกผันของ Hessian ที่ k
 ขั้นตอนที่ 10 ปรับค่าจำนวนโหนดในชั้นซ่อนตัวดังสมการที่ (16)

$$\theta_{k+1} = \theta_k + \alpha_k d_k \quad (16)$$


เมื่อ α_k คือ ขนาดการปรับค่าจำนวนโหนดในชั้นซ่อนตัวของตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่ k

ขั้นตอนที่ 11 ปรับปรุงเมตริกซ์ผกผันของ Hessian
 ขั้นตอนที่ 12 ดำเนินการซ้ำตั้งแต่ ขั้นตอนที่ 2 ถึงขั้นตอนที่ 11 จนกระทั่งถึงเงื่อนไขการหยุด

ในส่วนของการนำเสนอผลการวิจัยใช้สัญลักษณ์ Proposed Model แทนตัวแบบผสมของตัวแบบอาร์มีนาและตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต เพื่อความกระชับของการนำเสนอ

2.2.6 การประเมินประสิทธิภาพการพยากรณ์

สำหรับการประเมินประสิทธิภาพการพยากรณ์ของตัวแบบพยากรณ์ต่าง ๆ ข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่รายปีจะถูกแบ่งออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลสำหรับการสร้างตัวแบบในสัดส่วนร้อยละ 70 (ตั้งแต่ พ.ศ. 2504–2545) และชุดข้อมูลสำหรับการทดสอบตัวแบบในสัดส่วนร้อยละ 30 (ตั้งแต่ พ.ศ. 2546–2563) ตามลำดับ [19] โดยชุดข้อมูลสำหรับการทดสอบตัวแบบจะไม่ถูกนำมาเกี่ยวข้องกับขั้นตอนการสร้างตัวแบบพยากรณ์จนกว่าตัวแบบพยากรณ์ต่าง ๆ จะสร้างสมการความสัมพันธ์ที่เหมาะสมที่สุดจากชุดข้อมูลสำหรับการสร้างตัวแบบเพื่อการทำนายค่าในอนาคต 1 ช่วงเวลา ซึ่งค่านี้จะเป็นค่าพยากรณ์ของค่าแรกในชุดข้อมูลสำหรับทดสอบตัวแบบ จึงนำค่าแรกในชุดข้อมูลทดสอบตัวแบบมาเปรียบเทียบกับหาความคลาดเคลื่อนของการพยากรณ์



รูปที่ 2 ผลการพยากรณ์และปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศบราซิล

ภายหลังจากค่าแรกในชุดข้อมูลสำหรับทดสอบตัวแบบถูกเปิดเผยจะนำค่าดังกล่าวมารวมเข้ากับชุดข้อมูลสำหรับการสร้างตัวแบบเดิมเพื่อปรับปรุงชุดข้อมูลสำหรับการสร้างตัวแบบให้ทันสมัยสำหรับการสร้างสมการความสัมพันธ์เพื่อทำนายค่าในอนาคต 1 ช่วงเวลาลัดไป และดำเนินการตามที่ได้กล่าวมาข้างต้น จนกระทั่งการพยากรณ์และเปรียบเทียบค่าสุดท้ายของชุดข้อมูลสำหรับทดสอบตัวแบบ เพื่อคำนวณหาความคลาดเคลื่อนตามเกณฑ์ต่าง ๆ ดังนี้

ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยดังสมการที่ (17)

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (17)$$

ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยดังสมการที่ (18)

$$MAPE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i| / y_i}{n} \times 100 \quad (18)$$

ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตรดังสมการที่ (19)

$$sMAPE = \frac{\sum_{i=1}^n 2 \times |y_i - \hat{y}_i| / (y_i + \hat{y}_i)}{n} \times 100 \quad (19)$$

3. ผลการทดลอง

ผลการพยากรณ์ปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่เทียบกับข้อมูลปริมาณการผลิตของผลิตภัณฑ์เนื้อไก่จริงของประเทศบราซิล ดังรูปที่ 2



```
Best model: ARIMA(0,2,1)

Series: data
ARIMA(0,2,1)

Coefficients:
      ma1
    -0.6835
s.e.    0.1013

sigma^2 estimated as 2.515e+10: log likelihood=-535.53
AIC=1075.05   AICc=1075.38   BIC=1078.43
```

รูปที่ 3 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศบราซิล 42 ค่าแรก

```
Best model: ARIMA(1,2,3)

Series: data
ARIMA(1,2,3)

Coefficients:
      ar1      ma1      ma2      ma3
    -0.8642    0.2927   -0.2940   -0.7149
s.e.    0.1092    0.1372    0.1404    0.1951

sigma^2 estimated as 6.21e+10: log likelihood=-608.88
AIC=1227.76   AICc=1229.34   BIC=1236.68
```


รูปที่ 4 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศบราซิล 46 ค่าแรก

หากใช้ชุดข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศบราซิลตั้งแต่ พ.ศ. 2504 ถึง พ.ศ. 2545 พบว่า ตัวแบบอาร์มาที่เหมาะสม ดังรูปที่ 3

ตัวแบบอาร์มาที่เหมาะสม คือ ARIMA(0,2,1) ในขณะที่เมื่อพิจารณาตัวแบบที่เหมาะสมสำหรับข้อมูลอนุกรมเวลาตั้งแต่ พ.ศ. 2504–2549 ตัวแบบ อาร์มาที่เหมาะสมเปลี่ยนแปลง ดังรูปที่ 4

ตัวแบบอาร์มาที่เหมาะสม คือ ARIMA(1,2,3) จากการเปลี่ยนแปลงตัวแบบที่เหมาะสมของตัวแบบอาร์มา การปรับปรุงข้อมูลสำหรับการสร้างตัวแบบให้ทันสมัยและสอดคล้องกับการพยากรณ์ จึงไม่สามารถระบุลำดับและค่าสัมประสิทธิ์ของตัวแบบอาร์มาสำหรับข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศบราซิลเพียงตัวแบบเดียวเพื่อใช้พยากรณ์ทุกช่วงได้

สำหรับตัวแบบซัพพอร์ตเวกเตอร์เรกเรชันที่เหมาะสมใช้จำนวนข้อมูลย้อนหลัง 1 ช่วงเวลา โดยฟังก์ชันเคอร์เนล



รูปที่ 5 ผลการพยากรณ์และปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศจีน

```
Best model: ARIMA(2,2,1)

Series: data
ARIMA(2,2,1)

Coefficients:
      ar1      ar2      ma1
    -1.5860   -0.7836    0.8441
s.e.    0.1389    0.0909    0.2267

sigma^2 estimated as 4.908e+10: log likelihood=-548.38
AIC=1104.75   AICc=1105.89   BIC=1111.51
```

รูปที่ 6 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศจีน 42 ค่าแรก

แบบฟังก์ชันเชิงเส้นตรงที่มีค่าสัมประสิทธิ์ C เท่ากับ 334

นอกจากนี้ ตัวแบบผสมที่น่าเสนอที่เหมาะสมที่สุดสำหรับข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศบราซิล คือ ตัวแบบอาร์มาที่เหมาะสมและการลดความคลาดเคลื่อนของค่าส่วนเหลือของข้อมูลอนุกรมเวลาด้วยตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างที่มีจำนวนโนดในชั้นซ่อนตัวหนึ่งชั้น จำนวน 81 โหนด โดยใช้ข้อมูลย้อนหลังของค่าส่วนเหลือจำนวน 5 ค่า

สำหรับการพยากรณ์ปริมาณการผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศจีนเทียบกับปริมาณการผลิตจริง ดังรูปที่ 5

หากใช้ชุดข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศจีนตั้งแต่ พ.ศ. 2504–2545 พบว่า ตัวแบบอาร์มาที่เหมาะสม ดังรูปที่ 6

ตัวแบบอาร์มาที่เหมาะสม คือ ARIMA(2,2,1) แต่เมื่อพิจารณาตัวแบบอาร์มาที่เหมาะสมสำหรับข้อมูลอนุกรมเวลา

```
Best model: ARIMA(4,2,0)

Series: data
ARIMA(4,2,0)

Coefficients:
      ar1      ar2      ar3      ar4
    -0.5826  -0.3833  -0.4635  -0.5311
    s.e.   0.1329   0.1804   0.1746   0.1365

sigma^2 estimated as 8.389e+10: log likelihood=-768.5
AIC=1547   AICc=1548.23   BIC=1557.04
```

รูปที่ 7 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศจีน 57 ค่าแรก

ตั้งแต่ พ.ศ. 2504–2560 ตัวแบบอาร์มาที่เหมาะสมเปลี่ยนแปลงดังรูปที่ 7

จากการพิจารณาตัวแบบอาร์มาที่เหมาะสมสำหรับข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศไทยตั้งแต่ พ.ศ. 2504–2560 คือ ARIMA(4,2,0) ซึ่งเกิดการเปลี่ยนแปลงและตัวแบบอาร์มาที่เหมาะสมเดิมไม่สามารถอธิบายข้อมูลที่มีการปรับปรุงให้ทันสมัยได้

โดยตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชันที่เหมาะสมใช้ข้อมูลอนุกรมเวลาย้อนหลัง 2 ค่า โดยฟังก์ชันเคอร์เนลแบบฟังก์ชันเชิงเส้นตรงที่มีค่าสัมประสิทธิ์ C เท่ากับ 292


สำหรับตัวแบบผสมที่น่าเสนอ คือ ตัวแบบอาร์มาที่ลดความคลาดเคลื่อนของค่าส่วนเหลือด้วยโครงข่ายประสาทเทียมที่ใช้ข้อมูลย้อนหลัง 2 ค่า ที่มีจำนวนโนดในชั้นซ่อนตัวหนึ่งชั้นจำนวน 68 โหนด

ในส่วนของประเทศอินเดีย การเปรียบเทียบค่าพยากรณ์และปริมาณการผลิตของผลิตภัณฑ์เนื้อไก่จริงดังรูปที่ 8

หากใช้ชุดข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศอินเดียตั้งแต่ พ.ศ. 2504–2545 พบว่า ตัวแบบอาร์มาที่เหมาะสม ดังรูปที่ 9

ตัวแบบอาร์มาที่เหมาะสม คือ ARIMA(1,2,0) แต่เมื่อพิจารณาตัวแบบอาร์มาที่เหมาะสมสำหรับข้อมูลอนุกรมเวลาดังตั้งแต่ พ.ศ. 2504–2553 ตัวแบบอาร์มาที่เหมาะสมเปลี่ยนแปลงดังรูปที่ 10

การพิจารณาตัวแบบอาร์มาที่เหมาะสมสำหรับข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของ



รูปที่ 8 ผลการพยากรณ์และปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศอินเดีย

```
Best model: ARIMA(1,2,0)

Series: data
ARIMA(1,2,0)

Coefficients:
      ar1
    -0.6211
    s.e.   0.1388

sigma^2 estimated as 998394536: log likelihood=-470.93
AIC=945.86   AICc=946.18   BIC=949.23
```

รูปที่ 9 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศอินเดีย 42 ค่าแรก

```
Best model: ARIMA(3,2,0)

Series: data
ARIMA(3,2,0)


Coefficients:
      ar1      ar2      ar3
    -0.6967  -0.2503  -0.3195
    s.e.   0.1381   0.1655   0.1433

sigma^2 estimated as 1.278e+09: log likelihood=-570.26
AIC=1148.51   AICc=1149.44   BIC=1156
```

รูปที่ 10 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศอินเดีย 50 ค่าแรก

ประเทศอินเดียตั้งแต่ พ.ศ. 2504–2553 กลับให้ตัวแบบที่เหมาะสม คือ ARIMA(3,2,0) และตัวแบบที่เหมาะสมเดิมไม่สามารถอธิบายข้อมูลที่มีการปรับปรุงให้ทันสมัยได้

นอกจากนี้ ตัวแบบซัพพอร์ตเวกเตอร์รีเกรตชันที่เหมาะสมใช้ฟังก์ชันเคอร์เนลแบบฟังก์ชันเรเดียลเบสิกที่มีค่าสัมประสิทธิ์ C และ γ เท่ากับ 120 และ 0.02 ตามลำดับ โดยมีจำนวนข้อมูลย้อนหลัง 1 ช่วงเวลา



รูปที่ 11 ผลการพยากรณ์และปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศสหรัฐอเมริกา

Best model: ARIMA(2,2,0)

Series: data
ARIMA(2,2,0)

Coefficients:

	ar1	ar2
	-0.8177	-0.3729
s.e.	0.1447	0.1423

sigma^2 estimated as 2.961e+10: log likelihood=-538.33
AIC=1082.66 AICc=1083.33 BIC=1087.73

รูปที่ 12 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศสหรัฐอเมริกา 42 ค่าแรก

สำหรับตัวแบบผสมที่นำเสนอ คือ ตัวแบบอาร์มาที่เหมาะสมกับชุดข้อมูลในแต่ละช่วงเวลาที่ช่วยลดค่าความคลาดเคลื่อนของค่าส่วนเหลือด้วยโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีจำนวนโหนดในชั้นซ่อนตัวหนึ่งชั้นจำนวน 110 โหนดและใช้ข้อมูลย้อนหลัง 4 ค่า

นอกจากนี้ การเปรียบเทียบการพยากรณ์กับผลผลิตของผลิตภัณฑ์เนื้อไก่ที่เกิดขึ้นจริงของประเทศสหรัฐอเมริกา ดังรูปที่ 11

ตัวแบบอาร์มาที่เหมาะสมสำหรับข้อมูลอนุกรมเวลาของปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศสหรัฐอเมริกา คือ ARIMA(2,2,0) แต่ค่าสัมประสิทธิ์ของตัวแบบอาร์มาที่เหมาะสมในแต่ละช่วงเวลามีค่าที่เปลี่ยนแปลงไป โดยค่าสัมประสิทธิ์ของตัวแบบอาร์มาที่เหมาะสมสำหรับข้อมูลตั้งแต่ พ.ศ. 2504-2545 ดังรูปที่ 12

Best model: ARIMA(2,2,0)

Series: data
ARIMA(2,2,0)

Coefficients:

	ar1	ar2
	-1.0351	-0.6273
s.e.	0.1268	0.1412

sigma^2 estimated as 4.854e+10: log likelihood=-658.38
AIC=1322.77 AICc=1323.31 BIC=1328.38

รูปที่ 13 ตัวแบบอาร์มาที่เหมาะสมสำหรับชุดข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ประเทศสหรัฐอเมริกา 50 ค่าแรก

เมื่อปรับปรุงข้อมูลอนุกรมเวลาตั้งแต่ พ.ศ. 2504-2553 ถึงแม้จะมีลำดับของตัวแบบอาร์มาเหมือนเดิม แต่ค่าสัมประสิทธิ์มีการเปลี่ยนแปลงดังรูปที่ 13

สำหรับตัวแบบซัพพอร์ตเวกเตอร์เกรดชันที่เหมาะสมใช้ฟังก์ชันเคอร์เนลแบบฟังก์ชันเชิงเส้นตรงที่มีค่าสัมประสิทธิ์ C เท่ากับ 216 ที่ใช้ข้อมูลย้อนหลัง 1 ค่า

ตัวแบบผสมที่นำเสนอ คือ ตัวแบบอาร์มาที่เหมาะสมกับชุดข้อมูลในแต่ละช่วงเวลาที่ลดความคลาดเคลื่อนของค่าส่วนเหลือด้วยโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าที่มีจำนวนโหนดในชั้นซ่อนตัวหนึ่งชั้นจำนวน 70 โหนดและใช้ข้อมูลย้อนหลัง 8 ค่า โดยสามารถสรุปค่าเฉลี่ยของความคลาดเคลื่อนของเกณฑ์การวัดประสิทธิภาพต่าง ๆ ดังตารางที่ 1

ตารางที่ 1 สรุปค่าเฉลี่ยของความคลาดเคลื่อนของเกณฑ์การวัดประสิทธิภาพ

ชุดข้อมูล	รูปแบบ	MAE*	MAPE	sMAPE
ประเทศบราซิล	ARIMA	4.92	4.83	4.80
	Holt	4.28	4.33	4.23
	SES	5.05	5.04	5.18
	SVR	3.67	3.67	3.50
	Propose model	3.55	3.45	3.36
ประเทศสาธารณรัฐประชาชนจีน	ARIMA	2.88	2.24	2.26
	Holt	3.10	2.44	2.45
	SES	4.46	3.55	3.62
	SVR	2.86	2.35	2.33
	Propose model	2.52	2.00	2.01

ตารางที่ 1 สรุปค่าเฉลี่ยของความคลาดเคลื่อนของเกณฑ์การวัดประสิทธิภาพ (ต่อ)

ชุดข้อมูล	รูปแบบ	MAE*	MAPE	sMAPE
ประเทศอินเดีย	ARIMA	1.10	3.78	3.64
	Holt	1.03	3.56	3.43
	SES	2.07	8.14	8.38
	SVR	0.98	3.48	3.37
	Propose model	0.95	3.08	2.92
ประเทศสหรัฐอเมริกา	ARIMA	2.42	1.41	1.41
	Holt	2.44	1.44	1.43
	SES	3.94	2.25	2.27
	SVR	3.15	1.79	1.79
	Propose model	2.05	1.19	1.19

*หมายเหตุ: * แทน 100,000 ต้น

ARIMA แทน ตัวแบบอาร์มา

Holt แทน ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลแบบมีแนวโน้ม

SES แทน ตัวแบบการปรับเรียบแบบเอ็กโพเนนเชียลอย่างง่าย

SVR แทน ตัวแบบซัพพอร์ตเวกเตอร์รีเกรชัน

Proposed model แทน ตัวแบบผสมของตัวแบบอาร์มาและโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าด้วยวิธีการกึ่งนิวตันแบบมีขอบเขต

MAE แทน ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย

MAPE แทน ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย

sMAPE แทน ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตร

4. อภิปรายผลและสรุป

จากผลการพยากรณ์และปริมาณการผลิตของผลิตภัณฑ์เนื้อไก่ของแต่ละประเทศพบว่า ตัวแบบพยากรณ์ต่าง ๆ สามารถให้ผลการพยากรณ์ที่สอดคล้องกับปริมาณผลผลิตที่เกิดขึ้นจริง ซึ่งประสิทธิภาพการพยากรณ์ของตัวแบบพยากรณ์เชิงเดี่ยวต่าง ๆ มีประสิทธิภาพที่แตกต่างกันของการพยากรณ์ในแต่ละช่วงเวลา โดยตัวแบบการเรียนรู้ของเครื่องมีประสิทธิภาพดีสำหรับข้อมูลปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่ของประเทศบราซิลและอินเดีย ในขณะที่ตัวแบบอาร์มาที่มีประสิทธิภาพดีในการพยากรณ์ข้อมูลแบบเชิงเส้นตรงเหมาะสมสำหรับข้อมูลปริมาณผลผลิตของผลิตภัณฑ์

เนื้อไก่ของประเทศจีนและสหรัฐอเมริกา

การพิจารณาค่าที่เข้าสู่บริเวณศูนย์กลางของค่าความคลาดเคลื่อนสามารถใช้เป็นตัวแทนของประสิทธิภาพโดยเฉลี่ยของภาพรวมการพยากรณ์ของตัวแบบต่าง ๆ ซึ่งผลการพิจารณาค่าเฉลี่ยของความคลาดเคลื่อนทั้ง 3 ของเกณฑ์การวัดประสิทธิภาพบ่งชี้ว่า ตัวแบบผสมของตัวแบบอาร์มาและตัวแบบโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าด้วยวิธีการกึ่งนิวตันแบบมีขอบเขตสามารถให้ค่าเฉลี่ยของความคลาดเคลื่อนที่น้อยที่สุดหรือกล่าวอีกนัยหนึ่งว่าตัวแบบผสมดังกล่าวให้ความถูกต้องของการพยากรณ์โดยเฉลี่ยดีกว่าตัวแบบอื่น ๆ

การลดความคลาดเคลื่อนของการพยากรณ์สามารถช่วยให้นำข้อมูลหรือสารสนเทศที่ได้ประกอบการตัดสินใจได้ถูกต้องและใกล้เคียงกับสถานการณ์ที่กำลังจะเกิดขึ้นจริงได้มากยิ่งขึ้น ซึ่งมีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยกว่าร้อยละ 10 หรือกล่าวได้ว่าตัวแบบผสมที่นำเสนอมีความแม่นยำสูง โดยตัวแบบผสมที่นำเสนอเหมาะสมสำหรับข้อมูลอนุกรมเวลาที่มีส่วนประกอบที่มีความสัมพันธ์เชิงเส้นตรงและความสัมพันธ์ไม่เป็นแบบเชิงเส้นตรงเพื่อการพยากรณ์ระยะสั้นสำหรับทำนายค่าล่วงหน้า 1 ปี ดังนั้นจึงสามารถสรุปได้จากงานวิจัยว่า ตัวแบบผสมของตัวแบบอาร์มาและโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าด้วยวิธีการกึ่งนิวตันแบบมีขอบเขตสามารถใช้เป็นหนึ่งในเครื่องมือที่มีประโยชน์สำหรับการพยากรณ์ปริมาณผลผลิตของผลิตภัณฑ์เนื้อไก่เพื่อประกอบการตัดสินใจได้อย่างมีประสิทธิภาพ

เอกสารอ้างอิง

- [1] N. Daghir, M. Diab-El-Harake, and S. Kharroubi, "Poultry production and its effects on food security in the Middle Eastern and North African region," *Journal of Applied Poultry Research*, vol. 30, no. 1, 2021.
- [2] E. M. Idamokoro and Y. S. Hosu, "Village chicken production and food security: A



- two-decade bibliometric analysis of global research trends,” *Agriculture and Food Security*, vol. 11, no. 1, pp. 1–20, 2022.
- [3] L. O. Pius, P. Strausz, and S. Kusza, “Overview of poultry management as a key factor for solving food and nutritional security with a special focus on chicken breeding in East African countries,” *Biology*, vol. 10, no. 8, 2021.
- [4] D. I. A. Hamzah, M. S. Rusiman, N. C. Him, M. A. Shafi, O. G. Alma, and S. Suhartono, “A time series analysis for sales of chicken based food product,” in *AIP Conference Proceedings*, 2021, pp. 060002.
- [5] V. Tenrisanna and S. N. Kasim, “Trends and forecasting of meat production and consumption in Indonesia: Livestock development strategies,” in *IOP conference series: Earth and Environmental Science*, 2020, vol. 492, no. 1, 2020.
- [6] J. F. Mgaya, “Application of ARIMA models in forecasting livestock products consumption in Tanzania,” *Cogent Food & Agriculture*, vol. 5, no.1, 2019.
- [7] Ö. Z. E. N. Doğukan, “Modeling and forecasting meat consumption per Capita in Turkey.” *Erciyes Üniversitesi Veteriner Fakültesi Dergisi*, vol. 16, no. 2, pp. 122–129, 2019.
- [8] A. Pujiati, S. Oktavilia, and N. Damayanti, “The Projection Model As an Early Warning of Food Price Commodity Fluctuation,” in *International Conference on Economics, Business and Economic Education 2018 (ICE-BEES 2018)*, 2018, pp. 860–868.
- [9] M. M. Alderiny, K. N. Alrwis, S. B. Ahmed, and N. M. Aldawdahi, “Forecasting Saudi Arabia’s production and imports of broiler meat chickens and its effect on expected self-sufficiency ratio,” *Journal of the Saudi Society of Agricultural Sciences*, vol. 19, no. 4, pp. 306–312, 2020.
- [10] E. R. Abraham, J. G. M. dos Reis, O. Ven drametto, P. L. D. Oliveira Costa Neto, R. C. Toloi, A. E. D. Souza, and M. D. Oliveira Moraes, “Time series prediction with Artificial Neural Networks: An analysis using Brazilian soybean production,” *Agriculture*, vol. 10, no. 10, pp. 475, 2020.
- [11] D. Zhang, S. Chen, L. Liwen, and Q. Xia, “Forecasting agricultural commodity prices using model selection framework with time series features and forecast horizons,” *IEEE Access*, vol. 8, pp. 28197–28209, 2020.
- [12] B. Madhu, M. A. Rahman, A. Mukherjee, M. Z. Islam, R. Roy, and L. E. Ali, “A comparative study of support vector machine and artificial neural network for option price prediction,” *Journal of Computer and Communications*, vol. 9, no. 5, pp.78–91, 2021.
- [13] Y. Tang, and C. Li, “The study on livestock production prediction in heilongjiang province based on support vector machine,” in *Conference of the 2nd International Conference on Computer Science and Electronics Engineering (ICCSEE 2013)*, 2013, pp. 1192–1195.
- [14] K. Naveena, S. Singh, S. Rathod, and A. Singh, “Hybrid ARIMA-ANN modelling for forecasting the price of robusta coffee in India,” *International Journal of Current Microbiology and Applied Sciences*, vol. 6, no. 7, pp. 1721–1726, 2017.
- [15] R. Mrinmoy, R. S. Tomar, V. Ramasubramanian,

- and K. N. Singh, "Forecasting sugarcane yield of India using ARIMA-ANN hybrid model," *Bhartiya Krishi Anusandhan Patrika*, vol.33, no. 1/2, pp.120–127, 2018.
- [16] Z. Liu, Z. Zhu, J. Gao, and C. Xu, "Forecast methods for time series data: A survey," *IEEE Access*, vol. 9, pp. 91896–91912, 2021.
- [17] R. Hyndman, G. Athanasopoulos, C. Bergmeir, G. Caceres, L. Chhay, K. Kuroptev, M. O'Hara-Wild, F. Petropoulos, S. Razbash, E. Wang, F. Yasmeen, D. Reid, D. Shaub, F. Garza, R. Core Team, R. Ihaka, X. Wang, Y. Tang, and Z. Zhou. (2022, October). *Forecast: Forecasting functions for time series and linear models*. [Online]. Available: <https://cran.r-project.org/web/packages/forecast/index.html>
- [18] T. Sujjaviriyasup, "Hybrid model of support vector machine and genetic algorithm for forecasting the annual peak electricity demand of Thailand," *The Journal of KMUTNB*, vol. 27, no. 3, pp. 453–465, 2017 (in Thai).
- [19] C. Bergmeir, R. J. Hyndman, and B. Koo, "A note on the validity of cross-validation for evaluating autoregressive time series prediction," *Computational Statistics & Data Analysis*, vol. 120, pp. 70–83, 2018.

