



การพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมสำหรับการพยากรณ์ ปริมาณน้ำฝนด้วยโครงข่ายประสาทเทียม

Development of Tournament Selection of Genetic Algorithm for Forecasting Rainfall with Artificial Neural Network

ปิยธิดา ต.ไชยสุวรรณ^{1*}, พูลพงษ์ สุขสว่าง², จตุภัทร เมฆมพาศัย³
Piyatida T.Chaisuwan^{1*}, Poonpong Suksawang², Jatupat Mekpariyup³

(Received: January 25, 2020; Revised: March 19, 2020; Accepted: March 31, 2020)

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมสำหรับการพยากรณ์ปริมาณน้ำฝนด้วยโครงข่ายประสาทเทียม (ANN) โดยอาศัย 30 หลักการ ได้แก่ 1) หลักการจัดลำดับที่พันธุกรรมให้เป็นค่ามาตรฐาน (NGR) 2) หลักการคัดเลือกแบบวงล้อรูเล็ต (RWS) และ 3) หลักการคัดเลือกแบบแข่งขัน (TS) การวิจัยแบ่งออกเป็น 2 ส่วน ได้แก่ ส่วนแรกเป็นการพัฒนาตัวแบบพยากรณ์ภายใต้การจำลองข้อมูล 1100 ข้อมูล ทำซ้ำ 1000 รอบ และส่วนที่สองเป็นการนำตัวแบบพยากรณ์ที่ได้จากส่วนแรกมาใช้พยากรณ์ ในส่วนนี้จะนำข้อมูลจริงมาใช้โดยทำการแบ่งข้อมูลออกเป็น 2 ชุด คือ ชุดการเรียนรู้ และชุดการทดสอบ คิดเป็นร้อยละ 77 และ 23 ตามลำดับ จากนั้นทำการเปรียบเทียบประสิทธิภาพการพยากรณ์ระหว่างตัวแบบโครงข่ายประสาทเทียมที่พัฒนาการคัดเลือกแบบแข่งขันกับตัวแบบโครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบเดิมของ Wang et al. (2017) โดยพิจารณาประสิทธิภาพการพยากรณ์จากค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) ค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (MAPE) รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และค่าสัมประสิทธิ์ตัวกำหนด (R^2) ตัวแปรนำเข้าในโครงข่ายประสาทเทียมได้แก่ ความชื้นสัมพัทธ์ของอากาศ ความเร็วลมและทิศทางลมในแนวตะวันออก-ตะวันตก ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ การระเหยของน้ำ อุณหภูมิ

¹หลักสูตรปรัชญาดุษฎีบัณฑิต สาขาวิชาการวิจัยและสถิติทางวิทยาการปัญญา มหาวิทยาลัยบูรพา

¹Doctor of Research and Statistics in Cognitive Science, Burapha University

²วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา มหาวิทยาลัยบูรพา

²College of Research Methodology and Cognitive Science, Burapha University

³คณะวิทยาศาสตร์ มหาวิทยาลัยบูรพา

³Faculty of Science, Burapha University

*Corresponding Author: piyatida2pung@gmail.com



อากาศสูงสุด อุณหภูมิอากาศต่ำสุด และอุณหภูมิอากาศเฉลี่ย และตัวแปรออกได้แก่ ปริมาณน้ำฝนของภาคกลางในประเทศไทย ข้อมูลที่นำมาวิเคราะห์เป็นข้อมูลรายฤดูกาลจำนวน 1100 ข้อมูล ผลการวิจัยแสดงให้เห็นว่าตัวแบบพยากรณ์ที่พัฒนาการคัดเลือกแบบแข่งขันมีประสิทธิภาพการพยากรณ์มากกว่าตัวแบบพยากรณ์ที่ใช้การคัดเลือกแบบเดิมของ Wang et al. (2017) ในทุกฤดู

คำสำคัญ: การคัดเลือกแบบแข่งขัน วิธีทางพันธุกรรม โครงข่ายประสาทเทียม การพยากรณ์ปริมาณน้ำฝน

Abstract

This research objectives were to develop the tournament selection of genetic algorithm (GA) for forecasting rainfall with artificial neural network (ANN) based on 3 principles; 1) normalized geometric ranking (NGR), 2) roulette wheel selection (RWS) and 3) tournament selection (TS). The research was divided into 2 parts. The first part was the development of forecasting model under the simulation of 1,100 data with iteration 1,000 epochs, and the second part was the forecasting by model of the previous one. For the latter part, the actual data were brought to divide into 2 sets; namely training and testing data set at 77% and 23%, respectively. Then, the artificial neural network model developed in the tournament selection and the artificial neural network model using the original selection of Wang et al. (2017), in aspect of forecasting efficiency by mean absolute error (MAE), mean absolute percentage error (MAPE), root mean square Error (RMSE), and coefficient of determination (R^2). The input variables of artificial neural network were relative humidity, wind speed, zonal wind, meridional wind, evaporation, minimum air temperature, maximum air temperature and average temperature. The output variable was rainfall of Central Thailand. The total data of 1,100 was seasonally analyzed. The results showed that the forecasting model developed by the tournament selection of genetic algorithm was more effective than the model with original selection of Wang et al. (2017) in every season.

Keywords: Tournament selection, Genetic algorithm, Artificial neural network, Rainfall forecasting

บทนำ

การติดตามและเฝ้าระวังสถานการณ์น้ำเป็นสิ่งจำเป็นสำหรับการวางแผนเพื่อรับมือกับปัญหาหรือผลกระทบที่อาจเกิดขึ้น (Phatcharopaswatnagul, Satienspirakul, Sittbisuntikul, & Sinnarong, 2017) น้ำฝนจึงเป็นหนึ่งในประเด็นสำคัญที่มีการศึกษามากมายเนื่องจากส่งผลกระทบต่อสังคมทั้งในเมืองและ



ชนบท (Sihananto & Mahmudy, 2017) น้ำฝนถือเป็นองค์ประกอบที่สำคัญของสภาพอากาศซึ่งมีการเก็บรวบรวมข้อมูลและเผื่อไว้ ถ้าน้ำฝนมีปริมาณมากเกินไปจะทำให้เกิดอุทกภัย ดินถล่ม น้ำป่าไหลหลาก แต่ถ้าน้ำฝนมีปริมาณน้อยเกินไปจะทำให้เกิดภัยแล้ง ภาวะขาดแคลนน้ำ ดังนั้นการพยากรณ์ปริมาณน้ำฝนจึงเป็นสิ่งสำคัญ (Mislan, Haviluddin, Hardwinarto, Sumaryono, & Aipassa, 2015) แต่การพยากรณ์ปริมาณน้ำฝนให้มีความแม่นยำนั้นเป็นเรื่องยากเนื่องจากข้อมูลที่นำมาใช้วิเคราะห์มีผันแปรและมีความซับซ้อน ดังนั้นการเลือกตัวแบบที่นำมาใช้พยากรณ์ปริมาณน้ำฝนต้องมีประสิทธิภาพและสามารถวิเคราะห์ข้อมูลที่มีความซับซ้อนได้ โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) เป็นอีกวิธีหนึ่งที่น่าสนใจในการพยากรณ์กันอย่างแพร่หลายเนื่องจากเป็นวิธีที่ให้ค่าพยากรณ์ที่มีความแม่นยำสูงขึ้น อาทิเช่น Asadi, Shahrabi, Abbaszadeh, & Tabanmehr (2013) ศึกษาการพยากรณ์ปริมาณน้ำฝนด้วยโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feed Forward Neural Network: FFNN) ด้วยขั้นตอนวิธีแบบเลเวนเบิร์ก-มาร์ควอดท์ (Levenberg-Marquardt Algorithm: LMA) ร่วมกับขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) และการวิเคราะห์การถดถอย (Regression Analysis: RA) โดยแบ่งกลุ่มข้อมูลแบบเคมีน (K-means Clustering) จากนั้นทำการเปรียบเทียบประสิทธิภาพการพยากรณ์กับระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS) ที่ใช้โครงข่ายประสาทเทียมร่วมกับฟัซซีลอจิก (Fuzzy Logic) ด้วยรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) และค่าสัมประสิทธิ์ตัวกำหนด (Coefficient of Determination: R^2) ผลการศึกษาแสดงให้เห็นว่าค่าพยากรณ์ปริมาณน้ำฝนจาก FFNN ร่วมกับ GA มีความแม่นยำกว่าค่าพยากรณ์ที่ได้จากโครงข่ายประสาทเทียมร่วมกับ Fuzzy Logic

Saxena, Verma, & Tripathi (2014) ศึกษาการพยากรณ์ปริมาณน้ำฝนด้วยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation Neural Network: BPNN) ร่วมกับ GA โดยปรับค่าน้ำหนักและความเอนเอียง (Bias) ของแต่ละเส้นเชื่อมต่อระหว่างโหนดพร้อมทั้งเปรียบเทียบความแม่นยำของการพยากรณ์กับ FFNN ผลการศึกษาแสดงให้เห็นว่าการพยากรณ์ด้วย BPNN ร่วมกับ GA มีความแม่นยำมากกว่าการพยากรณ์ด้วย FFNN อีกทั้งยังช่วยแก้ปัญหาความล่าช้าในการลู่เข้าหาคำตอบได้อีกด้วย

Shaikh & Sawlani (2017) ศึกษาการพยากรณ์ปริมาณน้ำฝนด้วย FFNN ในเมืองมุมไบ ประเทศอินเดีย โดยใช้โปรแกรม Matlab สำหรับตัวแปรนำเข้าประกอบด้วย ความชื้นเฉลี่ย อุณหภูมิเฉลี่ย ความเร็วลมเฉลี่ย ผลการศึกษาแสดงให้เห็นว่า ตัวแบบพยากรณ์ที่มีความเหมาะสมให้ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error: MSE) เท่ากับ 0.579 โดยมีจำนวนชั้นซ่อน 2 ชั้น



อย่างไรก็ตามด้วยแบบพยากรณ์ปริมาณน้ำฝนที่ใช้โครงข่ายประสาทเทียมยังสามารถพัฒนาให้มีประสิทธิภาพการพยากรณ์เพิ่มมากขึ้น อาทิเช่น การคัดเลือกตัวแปรนำเข้า การกำหนดค่าน้ำหนักเริ่มต้น การปรับค่าคลาดเคลื่อนของการพยากรณ์ การนำวิธีอื่น มาใช้ร่วมกับโครงข่ายประสาทเทียม เป็นต้น สำหรับการวิจัยนี้สนใจพัฒนาการคัดเลือกตัวแปรนำเข้าโดยนำขั้นตอนวิธีทางพันธุกรรม (GA) ที่มีการพัฒนาในส่วนการคัดเลือกโครโมโซมเพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าเอนเอียงมาใช้ร่วมกับโครงข่ายประสาทเทียม เพื่อสร้างแบบพยากรณ์ปริมาณน้ำฝน

วัตถุประสงค์


1. เพื่อพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมร่วมกับโครงข่ายประสาทเทียมสำหรับสร้างแบบพยากรณ์ปริมาณน้ำฝน
2. เพื่อเปรียบเทียบความแม่นยำของการพยากรณ์ปริมาณน้ำฝนจากแบบพยากรณ์ที่ได้จากข้อ 1 กับแบบพยากรณ์ของ Wang, Gong, Li, Li, & Zhang (2017)

แนวคิดทฤษฎีที่เกี่ยวข้อง

1. ขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) GA เป็นขั้นตอนวิธีในการหาคำตอบหรือค่าเหมาะสมด้วยการประมาณค่า (Approximation Optimization) (Whitley, 1994) ซึ่งปัจจุบันขั้นตอนวิธีนี้ถูกนำมาใช้กันอย่างแพร่หลาย (Khadwilard, 2011) ลักษณะการทำงานของ GA มีรูปแบบการหาคำตอบแบบฮิวริสติก (Heuristic) ซึ่งถูกคิดค้นในปี ค.ศ. 1975 โดยจอห์น ฮอลแลนด์ (John Holland) ที่ได้รับแรงบันดาลใจจากทฤษฎีการคัดเลือกโดยธรรมชาติของชาร์ล ดาร์วิน (Charles Darwin) (Mohammadi, Lakestani, & Mohamed, 2018) โดยอิงแนวคิดเรื่องการอยู่รอดของผู้ที่แข็งแกร่งที่สุดคือ ผู้ที่แข็งแกร่งกว่าย่อมมีโอกาสในการอยู่รอดมากกว่าและมีโอกาสในการถ่ายทอดลักษณะที่แข็งแกร่งนั้นไปยังรุ่นถัดไป (Survival of the Fittest) (Gupta, Vasudev, & Bhattacharyya, 2018; Raeisi-Vanani et al., 2017) โดยคำตอบที่ได้จากการหาคำตอบในหนึ่งรุ่น (Generation) จะผ่านการแปลง (Transformation) เพื่อนำไปสู่การหาคำตอบที่ดีขึ้นในรุ่นถัดไป การแปลงที่เกิดขึ้นกับคำตอบในหนึ่งรุ่นนั้นเป็นการค้นหาคำตอบหรือคุณลักษณะที่เหมาะสม (Fit Characteristics) ให้มีการถ่ายทอดไปยังรุ่นถัดไป (Gupta et al., 2018) ซึ่งคำตอบหรือคุณลักษณะดังกล่าวจะนำไปสู่คำตอบที่เหมาะสมที่สุด (Optimum Solution) จุดเด่นของการค้นหาด้วย GA คือ ความทนทานต่อความผิดพลาดและความแตกต่างของข้อมูลที่ใช้ในการค้นหาคำตอบ อีกทั้ง GA จะเก็บคำตอบในรูปแบบของเซตขณะที่ขั้นตอนวิธีอื่นจะเก็บและเปลี่ยนแปลงทีละคำตอบ (Goldberg, 1989; Raeisi-Vanani et al., 2017) ดังนั้น GA จึงเป็นขั้นตอนวิธีที่ถูกนำมาใช้ค้นหาโครงสร้างและตัวแปรที่เหมาะสม เพื่อทำให้มีประสิทธิภาพการทำงานสูงสุด (Meesad, 2012) สำหรับ



การประยุกต์ GA กับการพยากรณ์นั้นไม่ถูกนำมาใช้โดยตรงแต่นำ GA ไปใช้ร่วมกับวิธีการพยากรณ์อื่นเพื่อให้ประสิทธิภาพการพยากรณ์ดีขึ้น (Kantanatha, 2012) กระบวนการทำงานของวิธี GA ดังภาพที่ 1



ภาพที่ 1 กระบวนการทำงานของวิธี GA

กระบวนการที่สำคัญอย่างหนึ่งของ GA คือการคัดเลือกโครโมโซม (Chromosome Selection) เป็นการคัดเลือกคู่โครโมโซมต้นกำเนิดสายพันธุ์สำหรับการสืบสายพันธุ์เพื่อให้กำเนิดเป็นรุ่นถัดไป โดยปรกติแล้ว ถ้าต้องการได้สายพันธุ์ที่ดีต้นกำเนิดสายพันธุ์จะต้องดีด้วย เพราะถ้าต้นกำเนิดสายพันธุ์ไม่ดีอาจทำให้ได้การสืบสายพันธุ์รุ่นถัดไปไม่ดีตามไปด้วย การคัดเลือกโครโมโซมมีหลายวิธีด้วยกันแต่สำหรับการวิจัยนี้สนใจพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอน GA โดยมีหลักการ ดังนี้

1. การจัดลำดับที่พันธุกรรมให้เป็นค่ามาตรฐาน (Normalized Geometric Ranking: NGR) ของ Joines & Houck (1994) อ้างโดย Houck, Joines, & Kay (1995) ที่มีขั้นตอนดังนี้

1.1 หาค่าความเหมาะสม (Fitness Value) ของโครโมโซมแต่ละตัวในประชากรจากฟังก์ชันที่กำหนดขึ้น



1.2 นำค่าความเหมาะสมมาจัดลำดับให้กับโครโมโซมแต่ละตัว โดยเรียงจากค่าความเหมาะสมที่ดีที่สุดไปแย่ที่สุดเพื่อหาดัชนี (Index) ของการจัดลำดับ จากนั้นนำลำดับมาใช้ในการหาค่าการแจกแจงปกติ (Normal Distribution) ของค่าความเหมาะสม แล้วนำค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัวแทนตามตำแหน่งดัชนีของลำดับการจัดเรียง

1.3 หาค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัวด้วย NGR ที่มีสูตรคือ

$$(1-q)^{r-1} q'; q' = \frac{q}{1-(1-q)^p}$$

โดยที่ q แทนค่าความน่าจะเป็นในการเลือกโครโมโซมที่ดีที่สุด

r แทนค่าลำดับของโครโมโซมแต่ละตัว โดยลำดับที่ 1 เป็นค่าความเหมาะสมที่ดีที่สุด และลำดับที่ n เป็นค่าความเหมาะสมที่แย่ที่สุด

p แทนขนาดของประชากร

1.4 นำค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัวแทนด้วยตำแหน่งดัชนีของลำดับของการจัดเรียงที่ได้ตามขั้นตอนที่ 1.2 อีกครั้ง

2. การคัดเลือกแบบวงล้อรูเล็ตต์ (Roulette Wheel Selection: RWS) ของ Yu, Fu, Li, & Dong (2016) ที่มีขั้นตอนดังนี้

2.1 หาค่าความน่าจะเป็นของแต่ละโครโมโซมจากค่าความเหมาะสม จะได้จำนวนค่าความน่าจะเป็นเท่ากับจำนวนโครโมโซม โดยคำนวณจาก

$$p_i = \frac{f_i}{\sum_{i=1}^n f_i}$$

โดยที่ p_i แทนค่าความน่าจะเป็นเหมาะสมของโครโมโซมตัวที่ i

f_i แทนค่าความเหมาะสมของโครโมโซมตัวที่ i

n แทนจำนวนโครโมโซมทั้งหมด

2.2 หาผลรวมสะสม (Cumulative Sum) ของค่าความน่าจะเป็นเขียนแทนด้วยสัญลักษณ์ $Prob$

2.3 สร้างตัวแปรสุ่มเอกกรูป (Uniform Random Variable Generation) เพื่อกำหนดขนาดชุดตัวเลขสุ่มให้เท่ากับจำนวนของโครโมโซม โดยมีช่วงการสุ่มอยู่ที่ 0 ถึง 1 เขียนแทนด้วยสัญลักษณ์ Rng

2.4 ทำซ้ำขั้นตอนที่ 2.2 และ 2.3 เพื่อจับคู่การเปรียบเทียบระหว่าง $Prob$ กับ Rng โดยที่



2.4.1 นำค่าตัวเลขสุ่ม Rng มาเทียบกับ $Prob$ ที่ละคู่

- ถ้าตำแหน่งที่ 1 ของ Rng น้อยกว่าตำแหน่งที่ 1 ของ $Prob$ ให้เลือกโครโมโซมตามตำแหน่ง Rng (ตำแหน่งของ Rng เป็นตำแหน่งที่ 1) จากนั้นเลื่อนตำแหน่งของค่า Rng ไปอีก 1 ค่า (ตำแหน่งของ $Prob$ เป็นตำแหน่งที่ 1 และตำแหน่งของ Rng เป็นตำแหน่งที่ 2)

- ถ้าตำแหน่งที่ 1 ของ Rng มากกว่าตำแหน่งที่ 1 ของ $Prob$ ให้เลือกโครโมโซมตามตำแหน่ง Rng (ตำแหน่งของ Rng เป็นตำแหน่งที่ 1) แต่เลื่อนตำแหน่งของ $Prob$ ไปอีก 1 ตำแหน่ง (ตำแหน่งของ $Prob$ เป็นตำแหน่งที่ 2 และตำแหน่งของ Rng เป็นตำแหน่งที่ 1)

2.4.2 ทำกระบวนการ 2.4.1 ซ้ำจนครบตามจำนวนโครโมโซมจะทำให้ตำแหน่งของ Rng หรือตำแหน่งของ $Prob$ เปลี่ยนตามเงื่อนไขที่กำหนด

2.4.3 ผลที่ได้คือ ประเภท (Type) โครโมโซมลดลงแต่จำนวนโครโมโซมเท่าเดิม

3. หลักการคัดเลือกแบบแข่งขัน (Tournament Selection: TS) ของ Goldberg & Deb (1991) อ้างถึงใน Oladele & Sadiku (2013) มีขั้นตอนดังนี้

3.1 หาค่าความเหมาะสมของโครโมโซมทุกตัวจากฟังก์ชันที่กำหนด

3.2 กำหนดจำนวนการแข่งขัน (จำนวนหลัก) ในแต่ละแถว ส่วนจำนวนแถวของเมตริกซ์การแข่งขัน (Tournament Matrix) จะเท่ากับจำนวนโครโมโซมที่มีขนาดเท่ากับขนาดประชากร

3.3 สร้างเมตริกซ์การแข่งขันของค่าดัชนีสุ่มโดยค่าสุ่มนี้จะต้องอยู่ในช่วงของขนาดประชากร

3.4 แทนค่าดัชนีสุ่มด้วยค่าความเหมาะสมตามที่จับคู่ไว้ในแต่ละตำแหน่งของเมตริกซ์การแข่งขัน

3.5 หาค่ามากที่สุดของแต่ละแถวของขั้นตอนที่ 3.4 ซึ่งเรียกว่า ผู้ชนะ (Winner) ของการแข่งขันทำให้ได้ดัชนีการคัดเลือกโครโมโซมที่ต้องการ จากนั้นนำตำแหน่งนี้กลับไปเลือกค่าดัชนีของเมตริกซ์การแข่งขันในขั้นตอนที่ 3.3 อีกครั้ง ผลที่ได้คือ โครโมโซมที่เหมาะสมที่อยู่ตามตำแหน่งนั้น

2. โครงข่ายประสาทเทียม (Artificial Neural Network) โครงข่ายประสาทเทียมเป็นการจำลองการทำงานของโครงข่ายประสาทในสมองมนุษย์ผ่านกระบวนการเรียนรู้ที่มีโครงข่ายเชื่อมโยงกันระหว่างหน่วยทำให้สามารถรับข้อมูลและปรับตัวให้เข้ากับสถานการณ์หรือสิ่งแวดล้อมที่กำลังเผชิญอยู่ได้ (Nontasud & Wessapan, 2017) โครงข่ายประสาทเทียมประกอบด้วย 5 องค์ประกอบ (Mekpariyup & Saithanu, 2011; Phiwma, 2015; Prakobphol, 2009; Saengsawang, 2016) ดังนี้

1. ข้อมูลนำเข้า (Input Data) เป็นข้อมูลที่นำเข้ามาประมวลผลตามรูปแบบของปัญหาที่ต้องการแก้ไขหรือพิจารณา ซึ่งข้อมูลนำเข้าจะมีความสอดคล้องและสัมพันธ์กับปัญหา



2. ค่าน้ำหนัก (Weight Values) เป็นค่าที่ได้จากการเรียนรู้จากโครงข่ายประสาทเทียมหรือเรียกอีกอย่างว่า “ค่าความรู้” ซึ่งถูกกำหนดให้กับข้อมูลนำเข้าแต่ละตัว ค่าน้ำหนักที่แตกต่างกันแสดงถึงระดับความสำคัญของข้อมูลนำเข้าซึ่งถือเป็นองค์ประกอบที่สำคัญมากในโครงข่ายประสาทเทียม

3. ฟังก์ชันผลรวม (Summation Function: S) เป็นฟังก์ชันที่ทำหน้าที่รวมค่าน้ำหนักที่ได้จากโครงข่ายของข้อมูลนำเข้า เขียนแทนด้วยสัญลักษณ์ a_i และค่าน้ำหนักในแต่ละชั้นเขียนแทนด้วยสัญลักษณ์ w_i เพื่อใช้สำหรับสรุปผลความสัมพันธ์ระหว่างข้อมูลนำเข้าทั้งหมด ฟังก์ชันผลรวมพิจารณาจาก

$$S = \left(\sum_{i=1}^n a_i w_i \right) + b$$

โดยที่ n แทนจำนวนข้อมูลนำเข้าในชั้นรับข้อมูล (Input Layer)

b แทนความเอนเอียงที่เพิ่มเข้าไปในฟังก์ชันผลรวม

4. ฟังก์ชันการแปลง (Transformation Function) ทำหน้าที่ในการประสานสารสนเทศที่ผ่านการประมวลผลจากโครงข่ายในแต่ละชั้นแล้วนำสารสนเทศเหล่านั้นมาแปลงให้สามารถสื่อความหมายได้ เพื่อนำมาใช้ในการแสดงผลต่อไป ในบางครั้งอาจเรียกว่า ฟังก์ชันกระตุ้น (Activation Function) ฟังก์ชันการแปลงแบ่งออกเป็น 2 ลักษณะคือ ฟังก์ชันการแปลงเชิงเส้น (Linear Transfer Function) และฟังก์ชันการแปลงไม่เชิงเส้น (Nonlinear Transfer Function)

5. ข้อมูลส่งออก (Output Data) เป็นผลลัพธ์จากโครงข่ายประสาทเทียมที่เกิดจากการประมวลผลข้อมูลผ่านกระบวนการจากผลรวมค่าน้ำหนักของข้อมูลนำเข้าที่ถูกปรับเปลี่ยนค่าน้ำหนักแล้วจะถูกประมวลผลผ่านฟังก์ชันการแปลงทำให้ได้ผลลัพธ์ที่เป็นแนวทางในการแก้ไขปัญหาตามที่คาดหวังไว้

หลักการทำงานของโครงข่ายประสาทเทียมประกอบด้วย 2 ขั้นตอน ดังนี้ (Golic, 2013)

ขั้นตอนที่ 1 ขั้นตอนการเรียนรู้ (Training) เริ่มจากป้อนข้อมูลนำเข้าและข้อมูลส่งออกที่ต้องการจากชุดข้อมูลการเรียนรู้ (Training Data Set) ที่ประกอบด้วย 2 ส่วน คือ 1) การคำนวณแบบป้อนไปข้างหน้า (Feed Forward) จากชั้นรับข้อมูลแล้วส่งต่อไปยังชั้นซ่อน (Hidden Layer) ต่อไปยังชั้นส่งออก (Output Layer) และ 2) การคำนวณแบบย้อนกลับ (Backward) เพื่อทำการปรับค่าน้ำหนักและความเอนเอียง

ขั้นตอนที่ 2 ขั้นตอนการทดสอบ (Testing) โดยนำโครงข่ายประสาทเทียมที่ได้จากขั้นตอนการเรียนรู้มาใช้งาน เริ่มจากป้อนข้อมูลนำเข้าจากชุดข้อมูลทดสอบ (Testing Data Set) ขั้นตอนของการ



ทดสอบมีเพียงส่วนเดียวคือ การคำนวณแบบป้อนไปข้างหน้าโดยนำค่าน้ำหนักที่ได้จากขั้นตอนการเรียนรู้มาใช้งาน

3. การพัฒนาคัดเลือกรโมโซมของขั้นตอนวิธีทางพันธุกรรมที่นำมาใช้กับโครงข่ายประสาทเทียม Wang et al. (2017) ศึกษาเกี่ยวกับการใช้โครงข่ายประสาทเทียมที่ถูกปรับค่าให้เหมาะสมโดย GA เพื่อสร้างตัวแบบพยากรณ์แรงงอ (Bending Force) ในการวัดเหล็กร้อนชนิดม้วน ข้อมูลที่ใช้เก็บรวบรวมจากโรงงานผลิตเหล็กซึ่งถูกคัดเลือกมาเป็นข้อมูลนำเข้าและใช้โปรแกรม Matlab ในการสร้างตัวแบบพยากรณ์เขียนแทนด้วยสัญลักษณ์ GA-ANN โดยใช้ GA เพื่อหาค่าน้ำหนักเริ่มต้นและความเอนเอียงของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ การประเมินประสิทธิภาพของการพยากรณ์พิจารณาจากค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) และค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient: R) สำหรับสถาปัตยกรรมของโครงข่ายประสาทเทียมคือ 9-11-1 จากผลการศึกษาแสดงให้เห็นว่า ประสิทธิภาพของตัวแบบ GA-ANN ที่ดีที่สุดมีค่า MAE เท่ากับ 0.01 และค่า R เท่ากับ 0.983

สมมติฐานการวิจัย

ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมร่วมกับการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (GA) ที่พัฒนาขึ้นมีความแม่นยำมากกว่าตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมร่วมกับการคัดเลือกแบบเดิมของ Wang et al. (2017)

ขอบเขตการวิจัย

1. ข้อมูลจำลองมีขนาดเท่ากับ 1100 และกำหนดการทำซ้ำในแต่ละรอบเท่ากับ 1000 (Wang et al., 2017)
2. ข้อมูลจริงเก็บรวบรวมจาก National Centers for Environmental Prediction (NCEP) – NOAA (NOAA NCEP-NCAR, 2019) เป็นข้อมูลจังหวัดในภาคกลางของประเทศไทยตั้งแต่ 1 มกราคม พ.ศ. 2503 ถึง 31 มกราคม พ.ศ. 2561 รวมทั้งหมด 1100 ข้อมูล ประกอบด้วยข้อมูลนำเข้าจำนวน 7 ตัวแปร ได้แก่ ความชื้นสัมพัทธ์ของอากาศ (x_1) ความเร็วลมและทิศทางลมในแนวตะวันออก-ตะวันตก (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (x_3) การระเหยของน้ำ (x_4) อุณหภูมิอากาศสูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และอุณหภูมิอากาศเฉลี่ย (x_7) และข้อมูลออกจำนวน 1 ตัวแปร ได้แก่ ปริมาณน้ำฝน (y) ซึ่งแบ่งตามฤดูกาลคือ ฤดูร้อน (กุมภาพันธ์ มีนาคม เมษายน และพฤษภาคม) ฤดูฝน (มิถุนายน กรกฎาคม สิงหาคม และกันยายน) และฤดูหนาว (ตุลาคม พฤศจิกายน ธันวาคม และมกราคม)



3. ทั้งข้อมูลจำลองและข้อมูลจริงจะถูกแบ่งเป็น 2 ชุด ได้แก่ ชุดข้อมูลการเรียนรู้คิดเป็นร้อยละ 77 และชุดข้อมูลทดสอบคิดเป็นร้อยละ 23 (Wang et al., 2017)

4. สถาปัตยกรรมของโครงข่ายประสาทเทียมประกอบด้วยจำนวนชั้นรับข้อมูลจำนวน 1 ชั้น 7 โหนด ชั้นซ่อนจำนวน 1 ชั้น 11 โหนด และชั้นส่งออกจำนวน 1 ชั้น 1 โหนด โดยกำหนดฟังก์ชันชั้นรับข้อมูลออก คือ ฟังก์ชันเพียวลิน (Purelin function) และชั้นซ่อน คือ ฟังก์ชันล็อก-ซิกมอยด์ (Log-sigmoid function) ขั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ Bayesian Regularization (BR)

5. การคัดเลือกแบบแข่งขันมีการสลับสายพันธุ์แบบ Arithmetic Crossover โดยกำหนดความน่าจะเป็นในการสลับสายพันธุ์เท่ากับ 0.7 และการกลายพันธุ์แบบนอนยูนิฟอร์ม (Non-uniform Mutation) โดยกำหนดความน่าจะเป็นในการกลายพันธุ์เท่ากับ 0.05

6. การเปรียบเทียบประสิทธิภาพการพยากรณ์ใช้ค่า MAE, MAPE และ RMSE ที่มีค่าน้อย และ R^2 ที่มีค่ามากกว่าหมายความว่าตัวแบบนั้นมีประสิทธิภาพการพยากรณ์มาก

วิธีการวิจัย

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมสำหรับการพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม จากนั้นทำการเปรียบเทียบประสิทธิภาพการพยากรณ์กับตัวแบบพยากรณ์ของ Wang et al. (2017) ที่ใช้การคัดเลือกแบบเดิมของขั้นตอนวิธีทางพันธุกรรม รายละเอียดมีดังนี้

1. พัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมสำหรับการพยากรณ์โดยใช้โครงข่ายประสาทเทียมเขียนแทนด้วยสัญลักษณ์ GA(New)-ANN ซึ่งประกอบด้วย

- หลักการ NGR (Joines & Houck, 1994 อ้างโดย Houck et al., 1995) เพื่อให้ได้ค่าลำดับ
- หลักการ RWS (Yu et al., 2016) เพื่อให้ได้ค่าความน่าจะเป็นของแต่ละโครโมโซมโดยใช้ค่าความเหมาะสม

ความเหมาะสม

- หลักการ TS (Goldberg & Deb, 1991 อ้างโดย Oladele & Sadiku, 2013) เพื่อคัดเลือกโครโมโซมที่ดีและตัดทิ้งโครโมโซมที่ไม่ดี โดยกำหนดจำนวนของการแข่งขันในแต่ละแถวเท่ากับ s ซึ่งมีค่าเท่ากับจำนวนเส้นเชื่อมต่อระหว่างโหนดทั้งหมดของโครงข่ายประสาทเทียมและกำหนดจำนวนแถวเท่ากับ n ซึ่งมีค่าเท่ากับจำนวนโครโมโซมที่เป็นขนาดของประชากร สำหรับงานวิจัยนี้จะกำหนดให้ $s = 96$ และ $n = 40$ นอกจากนี้จะกำหนดจำนวนรอบของการดำเนินการทางพันธุกรรมเพื่อหาคำตอบในแต่ละรุ่นเท่ากับ 50 รอบ (Wang et al., 2017)



2. สร้างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมร่วมกับการคัดเลือกแบบเดิมของ Wang et al. (2017) เขียนแทนด้วยสัญลักษณ์ GA-ANN

3. ตรวจสอบประสิทธิภาพการพยากรณ์ระหว่างตัวแบบ GA-ANN และตัวแบบ GA(New)-ANN ของข้อมูลจริงแยกตามฤดูกาล (ฤดูร้อน ฤดูฝน และฤดูหนาว) และชุดข้อมูล (ชุดการเรียนรู้ และชุดการทดสอบ)

ผลการวิจัย

1. ค่าสถิติพื้นฐานของข้อมูลมีดังนี้

ตารางที่ 1 แสดงค่าสถิติพื้นฐานจำแนกตามฤดูกาลดังนี้ ปริมาณน้ำฝนมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 11.27 มิลลิเมตร และมีส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.63 มิลลิเมตร ความชื้นสัมพัทธ์ของอากาศมีค่าเฉลี่ยสูงสุดในฤดูร้อนคิดเป็นร้อยละ 61.40 และส่วนเบี่ยงเบนมาตรฐานร้อยละ 11.78 ความเร็วและทิศทางลมในแนวตะวันออก-ตะวันตกมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 1.37 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.59 เมตรต่อวินาที ความเร็วและทิศทางลมในแนวเหนือ-ใต้มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 0.92 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.31 เมตรต่อวินาที การระเหยของน้ำมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 12.16 มิลลิเมตร และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 3.22 มิลลิเมตร อุณหภูมิอากาศสูงสุดมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 31.20°C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.72°C อุณหภูมิอากาศต่ำสุดมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 22.69°C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.18°C และอุณหภูมิอากาศเฉลี่ยมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 25.60°C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.40°C

ตารางที่ 1 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดู

ตัวแปร	ค่าต่ำสุด			ค่าสูงสุด			ค่าเฉลี่ย			ส่วนเบี่ยงเบนมาตรฐาน		
	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว
y	1.06	4.62	0.64	10.78	16.99	7.55	5.70	11.27	3.65	1.53	1.63	1.04
x ₁	20.75	22.93	23.55	83.95	82.95	85.43	61.40	61.17	61.10	11.78	12.51	12.56
x ₂	-1.62	0.26	-2.39	1.04	4.72	0.55	-0.09	1.37	-1.37	0.43	0.59	0.44
x ₃	-0.98	0.19	-2.62	1.55	2.05	1.18	0.73	0.92	-0.77	0.34	0.31	0.58
x ₄	4.77	4.20	4.80	24.67	9.86	16.13	12.16	5.43	8.99	3.22	0.87	1.94
x ₅	25.09	24.88	23.59	36.46	29.12	31.60	31.20	27.09	27.90	1.72	0.73	1.22
x ₆	15.62	19.96	13.24	25.34	26.21	25.20	21.04	22.69	18.67	1.70	1.18	2.32
x ₇	19.93	22.39	18.28	28.97	27.03	26.84	25.60	24.57	22.65	1.40	0.84	1.64



2. ผลการสร้างตัวแบบ GA(New)-ANN แบ่งตามแต่ละหลักการมีดังนี้

- ผลที่ได้จากหลักการ NGR คือค่าลำดับของค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว $r = 1, 2, 3, \dots, 40$ ที่ผ่านการเรียงลำดับของค่าความเหมาะสมของโครโมโซม โดยเรียงจากค่าความเหมาะสมที่ดีที่สุดให้เป็นลำดับที่ 1 ส่วนค่าความเหมาะสมที่แย่ที่สุดเป็นลำดับที่ 40

- ผลที่ได้จากหลักการ RWS คือ ค่าความน่าจะเป็นของค่าความเหมาะสมของแต่ละโครโมโซมที่ i เมื่อ $i = 1, 2, 3, \dots, 40$ เมื่อนำผลที่ได้จากหลักการ NGR และ RWS มาคูณกันทำให้ได้ค่าความน่าจะเป็นที่แท้จริง (Real Probabilities) ของโครโมโซมทั้ง 40 ตัว จากนั้นนำค่าความน่าจะเป็นที่แท้จริงเข้าสู่การคัดเลือกแบบแข่งขัน

- ผลที่ได้จากหลักการ TS คือ โครโมโซมที่ดีหรือค่าน้ำหนักที่เหมาะสมของแต่ละเส้นเชื่อมที่ได้จากการคัดเลือกแบบแข่งขันเพื่อใช้ในกระบวนการการสลับสายพันธุ์และการกลายพันธุ์ในขั้นตอนต่อไปของ GA ดังนั้นผลลัพธ์สุดท้ายเมื่อการดำเนินการทางพันธุกรรมของการหาคำตอบในหนึ่งรุ่นจำนวน 50 รอบ (Wang et al., 2017) ทำให้ได้โครโมโซมที่ดีหรือค่าน้ำหนักที่เหมาะสมของแต่ละเส้นเชื่อมที่พร้อมนำไปใช้ในขั้นตอนวิธีโครงข่ายประสาทเทียมเพื่อสร้างตัวแบบพยากรณ์ต่อไป

3. ผลการตรวจสอบประสิทธิภาพการพยากรณ์ระหว่างตัวแบบ GA-ANN และตัวแบบ GA(New)-ANN ของข้อมูลจริงแยกตามฤดูกาลมีดังนี้

3.1 การตรวจสอบประสิทธิภาพการพยากรณ์ในฤดูร้อนแสดงดังตารางที่ 2 ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ GA(New)-ANN มีความแม่นยำมากกว่าตัวแบบ GA-ANN โดยให้ค่า MAE เท่ากับ 0.52676 ค่า MAPE เท่ากับ 0.10539 และค่า RMSE เท่ากับ 0.67935 และ R^2 เท่ากับ 0.81509 ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ GA(New)-ANN มีความแม่นยำมากกว่าตัวแบบ GA-ANN โดยให้ค่า MAE เท่ากับ 0.57050 ค่า MAPE เท่ากับ 0.09638 และค่า RMSE เท่ากับ 0.73380 และ R^2 เท่ากับ 0.67987

3.2 การตรวจสอบประสิทธิภาพการพยากรณ์ในฤดูฝนแสดงดังตารางที่ 3 ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ GA(New)-ANN มีความแม่นยำมากกว่าตัวแบบ GA-ANN โดยให้ค่า MAE เท่ากับ 0.59257 ค่า MAPE เท่ากับ 0.05307 และค่า RMSE เท่ากับ 0.75706 และ R^2 เท่ากับ 0.78818 ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ GA(New)-ANN มีความแม่นยำมากกว่าตัวแบบ GA-ANN โดยให้ค่า MAE เท่ากับ 0.92739 ค่า MAPE เท่ากับ 0.08746 และค่า RMSE เท่ากับ 1.23060 และ R^2 เท่ากับ 0.39384

3.3 การตรวจสอบประสิทธิภาพการพยากรณ์ในฤดูหนาวแสดงดังตารางที่ 4 ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ GA(New)-ANN มีความแม่นยำมากกว่าตัวแบบ GA-ANN โดยให้ค่า



MAE เท่ากับ 0.36905 ค่า MAPE เท่ากับ 0.11238 และค่า RMSE เท่ากับ 0.47533 และ R^2 เท่ากับ 0.81162 ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ GA(New)-ANN มีความแม่นยำมากกว่าตัวแบบ GA-ANN โดยให้ค่า MAE เท่ากับ 0.42410 ค่า MAPE เท่ากับ 0.12034 และค่า RMSE เท่ากับ 0.53706 และ R^2 เท่ากับ 0.59087

ตารางที่ 2 การเปรียบเทียบค่า MAE MAPE RMSE และ R^2 ในฤดูร้อน

ประสิทธิภาพการพยากรณ์	ตัวแบบ GA-ANN		ตัวแบบ GA(New)-ANN	
	ชุดการเรียนรู้	ชุดการทดสอบ	ชุดการเรียนรู้	ชุดการทดสอบ
ค่า MAE	0.52684	0.59314	0.52676	0.57050
ค่า MAPE	0.10641	0.09891	0.10539	0.09638
ค่า RMSE	0.68372	0.75776	0.67935	0.73380
ค่า R^2	0.81271	0.65863	0.81509	0.67987

ตารางที่ 3 การเปรียบเทียบค่า MAE MAPE RMSE และ R^2 ในฤดูฝน

ประสิทธิภาพการพยากรณ์	ตัวแบบ GA-ANN		ตัวแบบ GA(New)-ANN	
	ชุดการเรียนรู้	ชุดการทดสอบ	ชุดการเรียนรู้	ชุดการทดสอบ
ค่า MAE	0.60047	1.00580	0.59257	0.92739
ค่า MAPE	0.05381	0.09302	0.05307	0.08746
ค่า RMSE	0.76911	1.39330	0.75706	1.23060
ค่า R^2	0.78138	0.22289	0.78818	0.39384

ตารางที่ 4 การเปรียบเทียบค่า MAE MAPE RMSE และ R^2 ในฤดูหนาว

ประสิทธิภาพการพยากรณ์	ตัวแบบ GA-ANN		ตัวแบบ GA(New)-ANN	
	ชุดการเรียนรู้	ชุดการทดสอบ	ชุดการเรียนรู้	ชุดการทดสอบ
ค่า MAE	0.38074	0.43167	0.36905	0.42410
ค่า MAPE	0.11663	0.12233	0.11238	0.12034
ค่า RMSE	0.49148	0.56244	0.47533	0.53706
ค่า R^2	0.79860	0.55129	0.81162	0.59087

อภิปรายผล

จากการเปรียบเทียบประสิทธิภาพการพยากรณ์ปริมาณน้ำฝนของภาคกลางในประเทศไทยแยกตามฤดูกาล (ฤดูร้อน ฤดูฝน และฤดูหนาว) ระหว่างตัวแบบโครงข่ายประสาทเทียมที่พัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมหรือตัวแบบ GA(New)-ANN และตัวแบบของ Wang et al. (2017) ที่ใช้การคัดเลือกแบบเดิมของขั้นตอนวิธีทางพันธุกรรมหรือตัวแบบ GA-ANN ผลการวิจัยแสดง



ชัดเจนว่า ตัวแบบ GA(New)-ANN มีประสิทธิภาพการพยากรณ์ดีกว่าตัวแบบ GA-ANN ของทุกฤดูกาล ทั้งในส่วนของการนำขั้นตอนวิธีทางพันธุกรรมมากำหนดค่าน้ำหนักเริ่มต้นและความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดในโครงข่ายประสาทเทียม อีกทั้งยังมีการปรับค่าน้ำหนักและความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้มีความเหมาะสมมากยิ่งขึ้น ดังนั้นการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นดีกว่าการคัดเลือกแบบเดิม ซึ่งชุดการเรียนรู้มีค่า MAE น้อยที่สุดในฤดูหนาวเท่ากับ 0.36905 ค่า MAPE น้อยที่สุดในฤดูฝนเท่ากับ 0.05307 ค่า RMSE น้อยที่สุดในฤดูหนาวเท่ากับ 0.47533 และ R^2 มากที่สุดในฤดูร้อนเท่ากับ 0.81509 และชุดการทดสอบมีค่า MAE น้อยที่สุดในฤดูหนาวเท่ากับ 0.42410 ค่า MAPE น้อยที่สุดในฤดูฝนเท่ากับ 0.08746 ค่า RMSE น้อยที่สุดในฤดูหนาวเท่ากับ 0.53706 และ R^2 มากที่สุดในฤดูร้อนเท่ากับ 0.67987 นั่นคือสามารถนำตัวแบบ GA(New)-ANN ไปพยากรณ์ปริมาณน้ำฝนของภาคกลางในประเทศไทยแยกตามฤดูกาลได้อย่างมีประสิทธิภาพ

สรุป

การพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (GA) ใช้หลักการ NGR (Joines & Houck, 1994 อ้างโดย Houck et al., 1995) หลักการ RWS (Yu et al., 2016) และหลักการ TS (Goldberg & Deb, 1991 อ้างโดย Oladele & Sadiku, 2013) ทำให้ได้วิธีการคัดเลือกแบบใหม่ของ GA เพื่อสร้างตัวแบบพยากรณ์ปริมาณน้ำฝนร่วมกับโครงข่ายประสาทเทียม (GA(New)-ANN) จากนั้นนำตัวแบบ GA(New)-ANN มาเปรียบเทียบกับความแม่นยำกับตัวแบบโครงข่ายประสาทเทียมของ Wang et al. (2017) ที่ใช้การคัดเลือกแบบเดิมของขั้นตอนวิธีทางพันธุกรรมหรือตัวแบบ GA-ANN พิจารณาความแม่นยำจากค่า MAE MAPE RMSE และ R^2 ปรากฏว่าตัวแบบ GA(New)-ANN มีความแม่นยำมากกว่าตัวแบบ GA-ANN สำหรับการพยากรณ์ปริมาณน้ำฝนแบบรายฤดูกาลในภาคกลางของประเทศไทย

ข้อเสนอแนะ

การวิจัยนี้เป็นการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (GA) สำหรับการพยากรณ์ปริมาณน้ำฝนด้วยโครงข่ายประสาทเทียมหรือตัวแบบ GA(New)-ANN สำหรับการวิจัยครั้งต่อไปควรมีการศึกษาการนำตัวแบบ GA(New)-ANN ไปพยากรณ์ในด้านอื่นๆ เช่น ด้านการแพทย์ ด้านอุตสาหกรรม หรือด้านธุรกิจ เป็นต้น รวมถึงควรมีการนำการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของขั้นตอนวิธีทางพันธุกรรมมาใช้ร่วมกับวิธีการอื่นในการสร้างตัวแบบพยากรณ์ เพื่อให้ตัวแบบมีประสิทธิภาพการพยากรณ์เพิ่มมากขึ้น



รายการอ้างอิง (References)

- Asadi, S., Shahrabi, J., Abbaszadeh, P., & Tabanmehr, S. (2013). A new hybrid artificial neural networks for rainfall-runoff process modeling. *Neurocomputing*, 121(1), 470-480.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Massachusetts: Addison-Wesley Longman, Inc.
- Goldberg, D. E., & Deb, K. (1991). A comparative analysis of selection schemes used in genetic algorithms. In *Foundations of genetic algorithms*. Elsevier, 1(1), 69-93.
- Golic, K. (2013). Application of a Neural Network Model for Solving Prediction Problems in Business Management. *Journal of Economics, Business and Management*, 1(1), 146-149.
- Gupta, D., Vasudev, K., & Bhattacharyya, S. (2018). Genetic algorithm optimization based nonlinear ship maneuvering control. *Applied Ocean Research*, 74(1), 142-153.
- Houck, C. R., Joines, J., & Kay, M. G. (1995). A genetic algorithm for function optimization: a Matlab implementation. *Ncsu-ie tr*, 95(9), 1-10.
- Joines, J. A., & Houck, C. R. (1994). On the use of non-stationary penalty functions to solve nonlinear constrained optimization problems with GA's. In *Proceedings of the First IEEE Conference on Evolutionary Computation. IEEE World Congress on Computational Intelligence*: 579-584. Orlando: IEEE.
- Kantanantha, N. (2012). Forecasting by Causal Methods. *Engineering Journal*, 4(1), 33-48.
- Khadwilard, A. (2011). Application of Genetic Algorithm for Optimisation Problems. *RMUTP Research Journal*, 5(2), 153-163.
- Meesad, P. (2012). *Fuzzy Systems and Neural Network*. Bangkok: Faculty of Information Technology KMUTNB.
- Mekpariyup, J., & Saithanu, K. (2011). Performance of Neural Networks, Multi-Layer Perceptron and Radial Basis Function, for Multivariate Quality Control Charts. *Burapha Science Journal*, 16(2), 97-106.
- Mislan, Haviluddin, Hardwinarto, S., Sumaryono, & Aipassa, M. (2015). Rainfall Monthly Prediction Based on Artificial Neural Network: A Case Study in Tenggarong Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59(1), 142-151.



- Mohammadi, M., Lakestani, M., & Mohamed, M. (2018). Intelligent parameter optimization of Savonius rotor using Artificial Neural Network and Genetic Algorithm. *Energy*, 143(1), 56-68.
- NOAA NCEP-NCAR. (2019). International Research Institute for Climate and Society. [Data file]. Available from International Research Institute for Climate and Society Web site, <http://iridl.ldeo.columbia.edu/SOURCES/.NOAA/.NCEP-NCAR/>
- Nontasud, K., & Wessapan, T. (2017). A Prediction Model of Electricity Consumption as Applied to Development Planning of Chiang Mai International Airport. *EAU Heritage Journal Science and Technology*, 11(3), 124-136.
- Oladele, R., & Sadiku, J. (2013). Genetic algorithm performance with different selection methods in solving multi-objective network design problem. *International Journal of Computer Applications*, 70(12), 5-9.
- Phatcharopaswatnagul, A., Satienspirakul, K., Sittbisuntikul, K., & Sinnarong, N. (2017). Impact of climate change to cassava production in The northeast region. *Veridian E-Journal, Silpakorn University*, 10(3), 2528-2540.
- Phiwma, N. (2015). Developing A Model for Forecasting Trends of Matching between A Job Applications and A Computer Degree Using Artificial Neural Network. *Panyapiwat Journal*, 7(2), 1-16.
- Prakobphol, T. (2009). Artificial Neural Networks. *HCU Journal*, 12(24), 73-87.
- Raeisi-Vanani, H., Shayannejad, M., Soltani-Toudeshki, A.-R., Arab, M.-A., Eslamian, S., Amoushahi-Khouzani, M., Marani-Barzani, M., & Ostad-Ali-Askari, K. (2017). A Simple Method for Land Grading Computations and its Comparison with Genetic Algorithm (GA) Method. *International Journal of Research Studies in Agricultural Sciences (IJRSAS)*, 3(8), 26-38.
- Saengsawang, S. (2016). Applying of Artificial Neural Network in The Agriculture. *The Journal of KMUTNB*, 26(2), 319-331.
- Saxena, A., Verma, N., & Tripathi, K. (2014). Neuro-genetic hybrid approach for rainfall forecasting. *Int J Comput Sci Inf Technol*, 5(2), 1291-1295.
- Shaikh, L., & Sawlani, K. (2017). A rainfall prediction model using artificial neural network. *International Journal of Technical Research and Applications*, 5(2), 45-48.



- Sihananto, A. N., & Mahmudy, W. F. (2017). Rainfall Forecasting Using Backpropagation Neural Network. *Journal of Information Technology and Computer Science*, 2(2), 66-76.
- Wang, Z.-H., Gong, D.-Y., Li, X., Li, G.-T., & Zhang, D.-H. (2017). Prediction of bending force in the hot strip rolling process using artificial neural network and genetic algorithm (ANN-GA). *The International Journal of Advanced Manufacturing Technology*, 93(9-12), 3325-3338.
- Whitley, D. (1994). A Genetic Algorithm Tutorial. *Statistics and Computing*, 4(2), 65–85.
- Yu, F., Fu, X., Li, H., & Dong, G. (2016). Improved Roulette Wheel Selection-Based Genetic Algorithm for TSP. Paper presented at the Network and Information Systems for Computers (ICNISC). *2016 International Conference on Network and Information Systems for Computers*: 136-140. Shenzhen: Atlantis Press.