

การคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม
สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม

ปิยธิดา ต.ไชยสุวรรณ

ดุษฎีนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปรัชญาดุษฎีบัณฑิต
สาขาวิชาการวิจัยและสถิติทางวิทยาการปัญญา
วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา มหาวิทยาลัยบูรพา
พฤษภาคม 2563
ลิขสิทธิ์เป็นของมหาวิทยาลัยบูรพา

คณะกรรมการควบคุมดัชนีพนธ์และคณะกรรมการสอบดัชนีพนธ์ ได้พิจารณา
ดัชนีพนธ์ของ ปิยธิดา ต.ไชยสุวรรณ ฉบับนี้แล้ว เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตาม
หลักสูตรปรัชญาดุษฎีบัณฑิต สาขาวิชาการวิจัยและสถิติทางวิทยาการปัญญา ของมหาวิทยาลัยบูรพา
ได้

คณะกรรมการควบคุมดัชนีพนธ์

..... *M. H.* อาจารย์ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.พูลพงศ์ สุขสว่าง)
..... *จ.พ.* อาจารย์ที่ปรึกษาร่วม
(ผู้ช่วยศาสตราจารย์ ดร.จตุภัทร เมฆพ่ายัพ)

คณะกรรมการสอบดัชนีพนธ์

..... *ส.พ.* ประธาน
(รองศาสตราจารย์ ดร.สุบิน ยุระรัช)
..... *M. H.* กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.พูลพงศ์ สุขสว่าง)
..... *จ.พ.* กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.จตุภัทร เมฆพ่ายัพ)
..... *ป.ร.ท. แก้วแก่น* กรรมการ
(ดร.ปรัชญา แก้วแก่น)
..... *ส.ท. ทศสิทธิ์ภรณ์* กรรมการ
(ดร.ศราวิน เทพสถิตย์ภรณ์)

วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญาอนุมัติให้รับดัชนีพนธ์ฉบับนี้ เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปรัชญาดุษฎีบัณฑิต สาขาวิชาการวิจัยและสถิติทางวิทยาการปัญญา
ของมหาวิทยาลัยบูรพา

..... *จ.ท.ว.* คณบดีวิทยาลัยวิทยาการวิจัย
(รองศาสตราจารย์ ดร. ภัทราวดี มากมี) และวิทยาการปัญญา
วันที่ 29 เดือน พฤษภาคม พ.ศ. 2563

ประกาศคุณูปการ

คุณุภินิพนธ์ฉบับนี้สำเร็จได้ด้วยความกรุณาจากคณะกรรมการควบคุมคุณุภินิพนธ์ ผู้ช่วยศาสตราจารย์ ดร.พูนพงศ์ สุขสว่าง อาจารย์ที่ปรึกษาหลัก และ ผู้ช่วยศาสตราจารย์ ดร.จตุภัทร เมฆพ่าย อาจารย์ที่ปรึกษาร่วม ตลอดจนคณะกรรมการสอบคุณุภินิพนธ์ทุกท่าน ที่กรุณาให้ คำปรึกษาแนะนำแนวทางที่ถูกต้อง แก้ไขข้อบกพร่องต่าง ๆ ด้วยความละเอียดถี่ถ้วน เอาใจใส่ด้วยดี เสมอมา ผู้วิจัยรู้สึกซาบซึ้งเป็นอย่างยิ่ง จึงขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้

ผู้วิจัยขอขอบพระคุณ ประธานและกรรมการสอบคุณุภินิพนธ์ทุกท่าน ที่ให้คำแนะนำพร้อม ทั้งแนวทางที่ถูกต้อง ทำให้คุณุภินิพนธ์ฉบับนี้มีความสมบูรณ์ยิ่งขึ้น

ผู้วิจัยขอขอบคุณ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออกที่สนับสนุนทุนการศึกษา และ ขอขอบคุณกรมอุตุนิยมวิทยาแห่งประเทศไทย ที่ให้คำแนะนำที่เป็นความรู้เกี่ยวกับข้อมูล อุตุนิยมวิทยาที่สำคัญและเป็นประโยชน์ต่อการวิจัยนี้

สุดท้ายนี้ ขอกราบขอบพระคุณ คุณพ่อเลิศพงศ์ คุณแม่กาญจนา ที่เป็นกำลังใจสำคัญ ที่ทำให้คุณุภินิพนธ์ฉบับนี้สำเร็จได้ด้วยดี และขอขอบคุณสมาชิกในครอบครัวทุกคน ที่คอยให้กำลังใจ ห่วงใย รวมทั้งยังให้การสนับสนุนแก่ผู้วิจัยด้วยดีตลอดมา ประโยชน์อันเกิดจากคุณุภินิพนธ์ฉบับนี้ ผู้วิจัยขอมอบเป็นเครื่องบูชาพระคุณพ่อ แม่ ครูบาอาจารย์ ตลอดจนผู้มีพระคุณทุกท่านที่ได้อบรม เลี้ยงดู ส่งเสริม ประสิทธิประสาทวิชาความรู้ และปรารถนาดีต่อผู้วิจัยเสมอมา

ปิยธิดา ต.ไชยสุวรรณ

57810017: สาขาวิชา: การวิจัยและสถิติทางวิทยาการปัญญา;

ปร.ด. (การวิจัยและสถิติทางวิทยาการปัญญา)

คำสำคัญ: การคัดเลือกแบบแข่งขัน/ ขั้นตอนวิธีทางพันธุกรรม/ โครงข่ายประสาทเทียม/
การพยากรณ์

ปิยธิดา ต.ไชยสุวรรณ: การคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมสำหรับ
พยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม (TOURNAMENT SELECTION OF GENETIC
ALGORITHM FOR FORECASTING RAINFALL USING ARTIFICIAL NEURAL NETWORK)

คณะกรรมการควบคุมดัชนีพนธ์: พูลพงศ์ สุขสว่าง, ค.ด., จตุภัทร เมฆพ่าย, ปร.ด. 332 หน้า.
ปี พ.ศ.2563.

การวิจัยนี้มีวัตถุประสงค์เพื่อ 1) พัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธี
ทางพันธุกรรม สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม 2) เปรียบเทียบความแม่นยำของ
ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้
การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์ และ 3) พยากรณ์ปริมาณน้ำฝนในภาคกลางของ
ประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขัน
ที่พัฒนาขึ้นของขั้นตอนวิธีทางพันธุกรรม ข้อมูลที่ใช้เป็นข้อมูลหตุยภูมิจาก NCEP-NOAA ตั้งแต่
1 มกราคม พ.ศ. 2503 ถึง 31 มกราคม พ.ศ. 2561 แบบรายฤดูกาล สร้างตัวแบบพยากรณ์โดยใช้
โปรแกรม Matlab

ผลการวิจัยปรากฏว่า 1) ได้หลักการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม
ที่พัฒนาขึ้น ประกอบด้วย 2 ขั้นตอน ได้แก่ ขั้นตอนการหาค่าความน่าจะเป็นที่แท้จริง (จากหลักการ
Normalized Geometric Ranking ร่วมกับหลักการคัดเลือกแบบวงล้อรูเล็ต) และขั้นตอน
การคัดเลือกแบบแข่งขัน 2) ได้ตัวแบบพยากรณ์ใหม่ 4 ตัวแบบ ที่มีความแม่นยำมากกว่าตัวแบบเดิม
ของ Asadi และตัวแบบเดิมของ Wang และ 3) ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของ
ประเทศไทยตั้งแต่ปี พ.ศ. 2562-2566 แบบรายฤดูกาล มีค่าสัมประสิทธิ์ตัวกำหนดมากกว่า 0.7
แสดงว่าการพยากรณ์มีความแม่นยำสูง ดังนั้นตัวแบบนี้สามารถนำไปใช้พยากรณ์ปริมาณน้ำฝนใน
ภาคกลางของประเทศไทยได้อย่างมีประสิทธิภาพ

57810017: MAJOR: RESEARCH AND STATISTICS IN COGNITIVE SCIENCE;
Ph.D. (RESEARCH AND STATISTICS IN COGNITIVE SCIENCE)

KEYWORDS: TOURNAMENT SELECTION/ GENETIC ALGORITHM/ ARTIFICIAL NEURAL
NETWORK/ FORECASTING

PIYATIDA T.CHAISUWAN: TOURNAMENT SELECTION OF GENETIC ALGORITHM
FOR FORECASTING RAINFALL USING ARTIFICIAL NEURAL NETWORK.

ADVISORY COMMITTEE: POONPONG SUKSAWANG, Ph.D., JATUPAT MEKPARYUP, Ph.D.
332 P. 2020.

The purposes of this research were 1) to develop the tournament selection of genetic algorithm for forecasting with artificial neural network, 2) to compare the accuracy of forecasting between the artificial neural network models with the developed tournament selection of genetic algorithm and the artificial neural network with the original selection within simulated data 5 situations, and 3) to forecast rainfall in the Central Thailand by using forecasting model using developed tournament selection of genetic algorithm with artificial neural network. Secondary data from NCEP-NOAA for the period 1 January 1960 to 31 January 2018 were used, and a seasonal forecasting model was created using the Matlab computer program.

It was found that 1) obtained tournament selection principle of genetic algorithm. The developed process consists of 2 steps, namely the process of determining the Real Probabilities (based on the normalized geometric ranking together with the roulette wheel selection) and the tournament selection process. 2) obtained 4 new forecasting models that are more accurate than original model of Asadi and original model of Wang, and 3) the rainfall forecast in the Central Thailand from the year 2019-2023 by season, it is found that the forecasting results has a coefficient of determination greater than 0.7 , indicating that the forecasting is highly accurate. Therefore, this model can be used to forecast rainfall in the Central Thailand effectively.

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญภาพ.....	ด
บทที่	
1 บทนำ.....	1
ความเป็นมาและความสำคัญของปัญหา.....	1
วัตถุประสงค์ของการวิจัย.....	6
กรอบแนวคิดในการวิจัย.....	6
สมมติฐานในการวิจัย.....	8
ประโยชน์ที่คาดว่าจะได้รับวิจัย.....	8
ขอบเขตของการวิจัย.....	8
นิยามศัพท์เฉพาะ.....	13
2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	16
ตอนที่ 1 การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์ปริมาณน้ำฝน โดยใช้โครงข่ายประสาทเทียมและงานวิจัยที่เกี่ยวข้อง.....	16
ตอนที่ 2 การวิเคราะห์ถดถอยพหุคูณ (Multiple Regression Analysis: MRA) และงานวิจัยที่เกี่ยวข้อง.....	31
ตอนที่ 3 วิธีโครงข่ายประสาทเทียม (Artificial Neural Network) และงานวิจัยที่เกี่ยวข้อง.....	35
ตอนที่ 4 ข้อมูลปริมาณน้ำฝน การพยากรณ์ปริมาณน้ำฝนและงานวิจัยที่เกี่ยวข้อง.....	62
ตอนที่ 5 ข้อมูลอุตุนิยมวิทยาที่เกี่ยวข้องกับปริมาณน้ำฝน.....	93
3 วิธีดำเนินการวิจัย.....	97
ตอนที่ 1 การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์ โดยใช้โครงข่ายประสาทเทียม.....	99

สารบัญ (ต่อ)

บทที่	หน้า
3 วิธีดำเนินการวิจัย (ต่อ)	
ตอนที่ 2 การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมจากข้อมูลจำลอง 5 สถานการณ์.....	102
ตอนที่ 3 การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA.....	108
4 ผลการวิจัย.....	110
ตอนที่ 1 ผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม.....	111
ตอนที่ 2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมจากข้อมูลจำลอง 5 สถานการณ์.....	113
ตอนที่ 3 ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA.....	196
5 สรุปและอภิปรายผล.....	207
สรุปผลการวิจัย.....	208
อภิปรายผล.....	211
ข้อเสนอแนะ.....	215
บรรณานุกรม.....	218
ภาคผนวก.....	233
ภาคผนวก ก ผลการวิเคราะห์ความแม่นยำของสถานการณ์ทั้ง 5 ของตัวแบบพยากรณ์ทั้ง 6 แบบ แยกตามฤดูกาล.....	234

สารบัญ (ต่อ)

บทที่	หน้า
ภาคผนวก (ต่อ)	
ภาคผนวก ข ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย โดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียม ที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA (ตัวแบบพยากรณ์ Wang-GA(New)-ANN).....	325
ภาคผนวก ค เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์.....	329
ประวัติย่อของผู้วิจัย.....	331

สารบัญตาราง

ตารางที่	หน้า
2-1 ฟังก์ชันการแปลงของโครงข่ายประสาทเทียม.....	38
2-2 เกณฑ์การรายงานปริมาณน้ำฝนในระยะเวลา 24 ชั่วโมง.....	66
2-3 เกณฑ์การรายงานการกระจายของน้ำฝนในระยะเวลา 24 ชั่วโมง.....	66
3-1 รูปแบบการทำงานของตัวแบบ Asadi-GA-ANN Asadi-GA(New)-ANN และ Asadi-GA-BPNN.....	104
3-2 รูปแบบการทำงานของตัวแบบ Wang-GA-ANN Wang-GA(New)-ANN และ Wang-GA-BPNN.....	105
4-1 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูของข้อมูลขนาด 300 จำนวน.....	115
4-2 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน.....	116
4-3 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน.....	117
4-4 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน.....	118
4-5 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน.....	119
4-6 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว.....	121
4-7 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว.....	122
4-8 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน.....	123
4-9 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน.....	124

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4-10 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน.....	125
4-11 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน.....	126
4-12 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว.....	127
4-13 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว.....	128
4-14 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูของข้อมูลขนาด 400 จำนวน.....	129
4-15 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน.....	130
4-16 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน.....	131
4-17 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน.....	132
4-18 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน.....	133
4-19 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว.....	135
4-20 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว.....	136

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4-21 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน.....	137
4-22 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน.....	138
4-23 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน.....	139
4-24 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน.....	140
4-25 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว.....	141
4-26 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว.....	142
4-27 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูของข้อมูลขนาด 500 จำนวน.....	143
4-28 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน.....	144
4-29 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน.....	145
4-30 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน.....	146
4-31 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน.....	147

สารบัญตาราง (ต่อ)

ตารางที่	หน้า	
4-32	ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว.....	149
4-33	ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว.....	150
4-34	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน.....	151
4-35	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน.....	152
4-36	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน.....	153
4-37	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน.....	154
4-38	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว.....	155
4-39	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว.....	156
4-40	ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูของข้อมูลขนาด 1000 จำนวน.....	157
4-41	ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน.....	158
4-42	ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน.....	159

สารบัญตาราง (ต่อ)

ตารางที่	หน้า	
4-43	ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน.....	160
4-44	ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน.....	161
4-45	ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว.....	163
4-46	ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว.....	164
4-47	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน.....	165
4-48	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน.....	166
4-49	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน.....	167
4-50	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน.....	168
4-51	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว.....	169
4-52	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว.....	170

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4-53	ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูของข้อมูลขนาด 1100 จำนวน.....171
4-54	ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน.....172
4-55	ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน.....173
4-56	ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน.....174
4-57	ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน.....175
4-58	ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้การจำลองข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว.....177
4-59	ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว.....178
4-60	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน.....179
4-61	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน.....180
4-62	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน.....181
4-63	ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน.....182

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4-64 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว.....	183
4-65 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว.....	184
4-66 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAE สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	186
4-67 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAPE สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	187
4-68 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า RMSE สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	188
4-69 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า R^2 สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	189
4-70 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	190
4-71 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAE สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	191
4-72 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAPE สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	192
4-73 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า RMSE สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	193
4-74 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า R^2 สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	194
4-75 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล.....	195
4-76 ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัวจำแนกตามฤดู.....	197

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4-77 ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปีพ.ศ. 2562-2566 แบบรายฤดูกาล.....	198
4-78 ผลการพยากรณ์ปริมาณน้ำฝนตามตำแหน่งในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปีพ.ศ. 2562-2566 แบบรายฤดูกาล.....	201

สารบัญภาพ

ภาพที่	หน้า
1-1 กรอบแนวคิดการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA.....	7
2-1 การคัดเลือกโครโมโซม.....	20
2-2 การสลับสายพันธุ.....	24
2-3 การกลายพันธุ.....	25
2-4 กระบวนการทำงานของวิธี GA.....	27
2-5 โครงข่ายประสาทเทียม.....	36
2-6 โครงข่ายแบบชั้นเดียว.....	40
2-7 โครงข่ายแบบหลายชั้น.....	41
2-8 ผลลัพธ์ในการส่งข้อมูลด้วยวิธี Hebb's Rule.....	45
2-9 เครื่องมือวัดปริมาณน้ำฝนแบบมาตรฐาน.....	64
2-10 เครื่องมือวัดปริมาณน้ำฝนแบบบันทึกแบบกาลักน้ำ.....	64
2-11 เครื่องมือวัดปริมาณน้ำฝนแบบบันทึกแบบตาชั่งวัดน้ำหนัก.....	65
2-12 เครื่องมือวัดปริมาณน้ำฝนแบบบันทึกแบบคานกระดก.....	65
2-13 ความต่างระดับของน้ำทะเลบนพื้นผิวมหาสมุทรแปซิฟิกขณะที่เกิดลานีญา-เอลนีโญ.....	80
3-1 ขั้นตอนการวิจัย.....	98
3-2 ขั้นตอนการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์ โดยใช้โครงข่ายประสาทเทียม.....	101
3-3 ขั้นตอนการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝนโดยใช้ โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์.....	107
3-4 ขั้นตอนการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA.....	109
4-1 ผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA.....	113
4-2 ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปีพ.ศ. 2562-2566 แบบรายฤดูกาล.....	199
4-3 รูปแบบการทำงานตัวแบบ Asadi-GA(New)-ANN.....	203
4-4 รูปแบบการทำงานตัวแบบ Wang-GA(New)-ANN.....	204

สารบัญญภาพ (ต่อ)

ภาพที่	หน้า
4-5 รูปแบบการทำงานตัวแบบ Asadi-GA-BPNN.....	205
4-6 รูปแบบการทำงานตัวแบบ Wang-GA-BPNN.....	206

บทที่ 1

บทนำ

ความเป็นมาและความสำคัญของปัญหา

การเปลี่ยนแปลงของสภาพภูมิอากาศ (Climate Change) ส่งผลกระทบต่อทั่วโลกและ ส่งผลกระทบต่อปริมาณน้ำฝน ทำให้รูปแบบการตกของฝนและการกระจายตัวของฝนเปลี่ยนแปลงไป จากเดิม ปริมาณน้ำฝนที่ตกลงมาเปลี่ยนไป พื้นที่ที่ไม่เคยมีฝนตกก็ตก พื้นที่ที่ตกอยู่แล้วก็ตกหนักขึ้น บางพื้นที่ปริมาณน้ำฝนหายไปเลยก็มี (Singh, Lo, & Qin, 2017) ปริมาณน้ำฝนเป็นสิ่งสำคัญยิ่งสิ่ง หนึ่งในอุตุวิทยามหาวิทยาลัย เป็นองค์ประกอบที่สำคัญของลมฟ้าอากาศที่ต้องการเก็บข้อมูลและมีการ เฝ้าระวัง ถ้าปริมาณน้ำฝนมากเกินไปจะส่งผลถึงการเกิดอุทกภัย ดินถล่ม น้ำป่าไหลหลาก แต่ถ้า ปริมาณน้ำฝนน้อยเกินไปก็จะส่งผลถึงการเกิดภัยแล้ง เกิดความขาดแคลนน้ำ ดังนั้นปริมาณน้ำฝนจึง กลายเป็นประเด็นสำคัญที่มีการศึกษามากมาย เนื่องจากส่งผลกระทบต่อชีวิตทางสังคมทั้งในชนบท และในเขตเมือง (Sihananto & Mahmudy, 2017) การติดตามสถานการณ์น้ำฝน ลักษณะการผัน แปรและแนวโน้มเป็นสิ่งจำเป็น และมีประโยชน์ในการใช้เป็นข้อมูลพื้นฐานเพื่อประกอบการพิจารณา หรือวางแผนรับมือกับปัญหาและผลกระทบที่อาจเกิดขึ้น (อภิรัตน์ พืชโรภาสวัฒนกุล, ขนิษฐา เสถียร พิระกุล, เกศสุดา สิทธิสันติกุล และนิโรจน์ สันณรงค์, 2560) ปริมาณน้ำฝนมีความสำคัญใน หลากหลายด้านไม่ว่าจะเป็น ด้านการเกษตรกรรม (Samhitha & Srikanth, 2017; Tafoughalti, El Faleh, Moujahid, & Ouargaga, 2018; Wahyuni, Fauzan, Abriyani, Muchlis, & Ulfa, 2018) ด้านการพยากรณ์ที่นำปริมาณน้ำฝนมาใช้เป็นตัวแปรพยากรณ์ เช่น การพยากรณ์ปริมาณน้ำฝน (Arya & Pai, 2018; Chanklan, Suksut, Chaiyakhon, Kaoungku, Kerdprasop, & Kerdprasop, 2017; Purnomo, Hartomo, & Prasetyo, 2017; Shaikh & Sawlani, 2017; Wahyuni et al., 2018) ระดับน้ำ (ยุพิน ไชยสมภาร และทวี ชัยพิมลผลิน, 2560; ศุภมิตร บุญญา และจิระนันต์ เจริญรัตน์, 2559) อัตราการไหลของน้ำสูงสุด (อนุชา กาญจนารักษ์ และวรรณดี ไทย สยาม, 2561) รวมถึงการพยากรณ์เกี่ยวกับภัย (Lee, Chung, & Hwang, 2016) ด้านการ เตือนภัยพิบัติ ด้านการกักเก็บน้ำ และด้านการท่องเที่ยว

จะเห็นว่าปริมาณน้ำฝนเข้ามามีบทบาทอย่างมากในปัจจุบัน ดังนั้นการพยากรณ์เพื่อ คาดคะเนหรือทำนายปริมาณน้ำฝนในอนาคต รวมทั้งปรากฏการณ์ทางธรรมชาติที่เกิดขึ้นเป็นเรื่องที่ จำเป็น ซึ่งในการพยากรณ์สามารถพยากรณ์ด้วยวิธีการทางสถิติที่มีหลายวิธีขึ้นอยู่กับปัจจัยในหลาย ๆ ด้าน เช่น การแจกแจงของข้อมูล ลักษณะของตัวแปร เป็นต้น วิธีที่นิยมนำมาใช้ ได้แก่ การวิเคราะห์ สหสัมพันธ์ (Correlation Analysis) การวิเคราะห์ถดถอยพหุคูณ (Multiple Regression Analysis: MRA) โดยวิธีเหล่านี้ใช้ในการพยากรณ์ความสัมพันธ์ นอกจากนี้ในปัจจุบันยังมีอีกหนึ่งวิธีที่นิยม นำมาใช้คือ การใช้โครงข่ายประสาทเทียม (Artificial Neural Network) เป็นการพยากรณ์ที่ใช้ข้อมูล

อนุกรมเวลา ซึ่งวิธีนี้เป็นวิธีที่มีประสิทธิภาพสามารถนำมาประยุกต์ใช้ในงานต่าง ๆ โดยไม่สนใจว่าข้อมูลมีการแจกแจงแบบใด สามารถวิเคราะห์ได้เมื่อมีค่านอกกลุ่ม และที่สำคัญจะไม่มีข้อตกลงเบื้องต้นเหมือนวิธีทางสถิติทั่วไป (จงจรัส แสงอรุณ และอรลภา แสงอรุณ, 2558) สามารถพยากรณ์จากข้อมูลในอดีตที่มีความไม่สมบูรณ์ และมีความซับซ้อนได้ดีกว่าวิธีการพยากรณ์แบบดั้งเดิม ประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมขึ้นอยู่กับ 2 ปัจจัยได้แก่ ปัจจัยภายในคือ ปัจจัยต่าง ๆ ที่เกี่ยวข้องในกระบวนการเรียนรู้ จุดจำของตัวแบบโครงข่ายประสาทเทียม เช่น ประเภทของวิธีการที่ใช้ในการเรียนรู้ (Learning Algorithms) การกำหนดจำนวนโหนดในชั้นซ่อน (Hidden Nodes) การกำหนดอัตราการเรียนรู้ (Learning Rates) เป็นต้น และปัจจัยภายนอกคือ ประเภทของข้อมูลตัวแปรนำเข้า (Input Variables) ประเภทของข้อมูลตัวแปรส่งออก (ผลลัพธ์) (Output Variables) รวมถึงคุณภาพและปริมาณของข้อมูลด้วย (ทวี ชัยพิมผลลิน, 2557) ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมถูกนำมาใช้อย่างกว้างขวางในทุกสาขาอาชีพ เช่น การพยากรณ์ปริมาณผลผลิตข้าว (อัทพล คุณเลิศ และพุทธิ ศิริแสงตระกูล, 2557) การพยากรณ์อัตราแลกเปลี่ยนสกุลเงินต่างประเทศ (พิชญากร เลค, 2561) การพยากรณ์รายได้จากการขายตัวเครื่องบิน (Huang & Hou, 2017) การพยากรณ์แรงงอ (Bending Force) (Wang, Gong, X. Li, Li, & Zhang, 2017) การพยากรณ์เกี่ยวกับยุง (Lee et al., 2016) การพยากรณ์ผลผลิตของน้ำมันหอมระเหย (Akbar, Kuanar, Patnaik, Mishra, & Nayak, 2018) การพยากรณ์ปริมาณน้ำฝน (เปรม รังสิวณิชพงศ์, ชัยวัฒน์ เอกวัฒน์พานิชย์, และดวงฤดี โฆษิตกิตติวงศ์, 2558; Arya & Pai, 2018; Asadi, Shahrabi, Abbaszadeh, & Tabanmehr, 2013; Dubey, 2015; Purnomo et al., 2017; Rasel & Imteaz, 2016; Samhitha & Srikanth, 2017; Wahyuni et al., 2018) เป็นต้น ซึ่งการพยากรณ์เรื่องเหล่านี้มีความซับซ้อนและยุ่งยาก แต่การนำโครงข่ายประสาทเทียมมาใช้ในการพยากรณ์ ทำให้ตัวแบบพยากรณ์มีความแม่นยำสูง

โครงข่ายประสาทเทียมเป็นเทคนิคที่นิยมใช้ในการพยากรณ์ข้อมูลในอนาคต เนื่องจากสามารถวิเคราะห์เรื่องที่ซับซ้อนได้ สะดวกและง่ายที่จะระบุความสัมพันธ์แบบไม่เชิงเส้นระหว่างข้อมูลนำเข้า (Input Data) และข้อมูลส่งออก (Output Data) ความสามารถเหล่านี้จึงทำให้โครงข่ายประสาทเทียมถูกนำมาใช้อย่างกว้างขวาง (Hussain, Usmani, Verma, Jamal, & Khan, 2017) โดยเฉพาะอย่างยิ่งการพยากรณ์ปริมาณน้ำฝน ประโยชน์ที่ได้จากการพยากรณ์ปริมาณน้ำฝนมีมากมาย เช่น นำมาคำนวณการกักเก็บน้ำ นำมาคำนวณขนาดของท่อระบายน้ำ วางแผนด้านการเกษตร วางแผนการจัดการด้านแหล่งทรัพยากรไฟฟ้าพลังงานน้ำ วางแผนการจัดการสาธารณสุขภาคด้านการใช้น้ำ วางแผนรับมือการระบายน้ำ วางแผนรับมือดินถล่ม ฝ้าระวังการเกิดความแห้งแล้ง สำหรับเตือนภัยพิบัติให้ระวังภัยพิบัติที่จะเกิดขึ้น เป็นต้น ทั้งหมดขึ้นอยู่กับความสามารถในการพยากรณ์ปริมาณน้ำฝน ดังนั้นการพยากรณ์ปริมาณน้ำฝนให้มีความแม่นยำเป็น

สิ่งที่สำคัญมาก (Mislán, Haviluddin, Hardwinarto, Sumaryono, & Aipassa, 2015) แต่การพยากรณ์ปริมาณน้ำฝนเป็นเรื่องค่อนข้างลำบากเนื่องจากข้อมูลที่นำมาวิเคราะห์มีความซับซ้อน หากพยากรณ์ได้แม่นยำก็จะส่งผลดีต่อประเทศอย่างแน่นอน การพยากรณ์ปริมาณน้ำฝนมีการศึกษาทั้งในประเทศและต่างประเทศ ตัวอย่างเช่น

การสร้างตัวแบบพยากรณ์ที่เหมาะสมที่สุดของปริมาณน้ำฝนจังหวัดสงขลาโดยใช้ออนุกรมเวลา ด้วยวิธีการทำให้เรียบแบบเอกซ์โพเนนเชียล (Exponential) ที่มีฤดูกาลอย่างง่าย วิธีบ็อกซ์-เจนกินส์ (Box and Jenkins) และวิธีการแยกส่วนประกอบ (Decomposition Method) ของอนุกรมเวลา เปรียบเทียบความถูกต้องของค่าพยากรณ์ โดยใช้เกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ที่ต่ำที่สุด (วรางคณา กิรติวิบูลย์, 2557) การพยากรณ์ปริมาณน้ำฝนรายฤดูกาลในลุ่มน้ำเจ้าพระยาโดยใช้โครงข่ายประสาทเทียม พิจารณาความแม่นยำจากค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณ (Multiple Correlation Coefficient: R) และค่า RMSE (เปรมรังสิวณิชพงษ์ และคณะ, 2558) การพยากรณ์ปริมาณน้ำฝนด้วยตัวแบบพยากรณ์ที่ใช้วิธีใหม่ในการสร้างตัวแบบ วิธีที่ใช้ได้แก่วิธีโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feed Forward Neural Network: FFNN) ใช้วิธีการเรียนรู้แบบ Lavenberg Marquardt (LM) ร่วมกับขั้นตอนวิธีทางพันธุกรรมหรือเจเนติกอัลกอริธึม (Genetic Algorithm: GA) วิธีการวิเคราะห์การถดถอย (Regression Analysis: RA) ที่ใช้วิธี Stepwise และการแบ่งชุดข้อมูลแบบเคมีน (K-Means Clustering) พิจารณาความแม่นยำจากค่า RMSE และค่าสัมประสิทธิ์ตัวกำหนด (Coefficient of Determination: R^2) และเปรียบเทียบกับระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS) ที่ใช้โครงข่ายประสาทเทียมร่วมกับวิธีฟัซซีลอจิก (Fuzzy Logic) (Asadi et al., 2013) เหมือนข้อมูลอนุกรมเวลาพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer Perceptron) ด้วยวิธีการเรียนรู้แบบแพร่ย้อนกลับ (Back-propagation Algorithms) และเปรียบเทียบกับตัวแบบพยากรณ์ด้วยวิธีการวิเคราะห์การถดถอยเชิงเส้น (Linear Regression) พิจารณาความแม่นยำจากค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Square Error: MSE) และค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient: R) (Gupta, Mishra, & Pandey, 2014) การพยากรณ์ปริมาณน้ำฝนโดยใช้วิธีโครงข่ายประสาทเทียมร่วมกับวิธี GA ซึ่งวิธี GA นำมาใช้สำหรับกำหนดโครงสร้างที่เหมาะสมของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation Neural Network: BPNN) และปรับค่าน้ำหนัก (Weight) และค่าความเอนเอียง (Bias) ของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับ (Backpropagation) มีความแม่นยำมากกว่าวิธีโครงข่ายประสาทเทียมแบบ FFNN และสามารถแก้ปัญหาความล่าช้าในการลู่เข้าหาคำตอบได้ (Saxena, Verma, & Tripathi, 2014)

การเปรียบเทียบการพยากรณ์ปริมาณน้ำฝนรายเดือนโดยใช้โครงข่ายประสาทเทียมแบบ FFNN กับวิธี MRA พิจารณาความแม่นยำจากค่า R และค่า MSE (Yashwant & Sananse, 2015) การพยากรณ์ปริมาณน้ำฝนจากตัวแปรทางด้านสภาพอากาศโดยใช้โครงข่ายประสาทเทียมแบบหลายชั้นที่ถูกนำมาเรียนรู้ด้วยวิธีการเรียนรู้แบบ LM และแบบแพร่ย้อนกลับ (Hashim, Nik Daud, Admad, Adnan, & Rizman, 2017) การพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมแบบ BPNN ร่วมกับการใช้วิธี Nguyen-Windrow ในการกำหนดค่าน้ำหนักเริ่มต้นของโครงข่ายประสาทเทียม การวัดประสิทธิภาพของตัวแบบพิจารณาจากค่า MSE (Sihananto & Mahmudy, 2017) และการพยากรณ์ปริมาณน้ำฝนโดยใช้วิธีการวิเคราะห์ถดถอยพหุคูณ (Multiple Linear Regression: MLR) พิจารณาความแม่นยำของการพยากรณ์จากค่า R (Navid & Niloy, 2018) เป็นต้น

จากการศึกษาส่วนใหญ่แสดงให้เห็นว่าตัวแบบพยากรณ์ปริมาณน้ำฝนที่ใช้โครงข่ายประสาทเทียมมีความแม่นยำในการพยากรณ์มากกว่าวิธีอื่น ๆ เพราะข้อมูลที่นำมาวิเคราะห์มีความซับซ้อน (เปรม รังสิวณิชพงศ์ และคณะ, 2558; Arya & Pai, 2018; Purnomo et al., 2017) อย่างไรก็ตามตัวแบบพยากรณ์ปริมาณน้ำฝนที่ใช้โครงข่ายประสาทเทียมยังมีจุดที่สามารถพัฒนาให้ดีขึ้นอีกได้ เพื่อให้การพยากรณ์มีความแม่นยำเพิ่มมากขึ้น เช่น การคัดเลือกตัวแปรนำเข้า เพราะถ้าตัวแปรนำเข้าไม่มีความสัมพันธ์หรือสัมพันธ์กันน้อย ๆ กับตัวแปรส่งออก ผลลัพธ์ที่ได้จากการพยากรณ์จะไม่ใช่อผลลัพธ์ที่ดีที่สุด (ณัฐพงษ์ วาริประเสริฐ, 2552, หน้า 260) การกำหนดค่าน้ำหนักเริ่มต้นของโครงข่าย การปรับค่าความคลาดเคลื่อนของค่าพยากรณ์ และการนำวิธีต่าง ๆ มาใช้ร่วมกับโครงข่ายในการพยากรณ์ เป็นต้น

ดังนั้นการวิจัยนี้สนใจการพัฒนาการคัดเลือกแบบแข่งขัน (Tournament Selection) ของวิธี GA สำหรับพยากรณ์ร่วมกับโครงข่ายประสาทเทียม เพื่อให้ตัวแบบพยากรณ์มีความแม่นยำ ความคลาดเคลื่อนต่ำและรวดเร็วมากขึ้น ซึ่งในด้านการพยากรณ์นั้น วิธี GA ไม่ถูกนำมาใช้ในการพยากรณ์โดยตรง แต่มักนำไปผสมหรือร่วมกับวิธีการพยากรณ์อื่น ๆ เพื่อเลือกโครงสร้างหรือหาค่าพารามิเตอร์ของวิธีการพยากรณ์นั้น ๆ ทำให้ประสิทธิภาพในการพยากรณ์ดีขึ้น (นันทชัย กานตานันทะ, 2555) ตัวอย่างเช่น

Asadi et al. (2013) ใช้วิธี GA ในการหาค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงในแต่ละเส้นเชื่อมของโครงข่ายประสาทเทียมแบบ FFNN ด้วยวิธีการเรียนรู้แบบ LM ซึ่งโดยทั่วไปค่าน้ำหนักเริ่มต้นของโครงข่ายประสาทเทียมจะกำหนดจากการสุ่มที่มีค่าน้อย ๆ (สายชล สินสมบุรณ์ทอง, 2558, หน้า 216; Gardner & Dorling, 1998; Gupta et al., 2014; Hung, Babel, Weesakul, & Tripathi, 2009) ทำให้เสียเวลาและอาจทำให้ค่าความคลาดเคลื่อนเพิ่มขึ้นได้ Saxena et al. (2014) ใช้วิธี GA กำหนดโครงสร้างที่เหมาะสมของโครงข่ายประสาทเทียมแบบ BPNN ปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสม การปรับค่าน้ำหนักจะขึ้นอยู่กับ

ความแตกต่างของค่าผลลัพธ์ที่เป็นค่าส่งออกของตัวแบบ (ค่าพยากรณ์) กับค่าผลลัพธ์จริง (นิภาพร ชนะมาร และพรธณี สิริเดช, 2557) Wang et al. (2017) ใช้วิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้น และค่าความเอนเอียงในแต่ละเส้นเชื่อมของโครงข่ายประสาทเทียมแบบ BPNN เป็นต้น สำหรับ กระบวนการที่สำคัญอย่างหนึ่งของวิธี GA คือการคัดเลือก (Selection) โครโมโซม (Chromosome) เป็นการคัดเลือกโครโมโซมต้นกำเนิดสายพันธุ์หรือโครโมโซมพ่อแม่สำหรับการสืบสายพันธุ์เพื่อให้ กำเนิดเป็นประชากรลูกหลานในรุ่นถัดไป โดยปกติแล้วถ้าต้องการที่จะได้สายพันธุ์ที่ดี ต้นกำเนิดสายพันธุ์ที่ดีด้วย จะเห็นได้ว่าการคัดเลือกจัดเป็นกระบวนการที่สำคัญมากซึ่งส่งผลต่อกระบวนการ ต่อไป เพราะถ้าคัดเลือกต้นกำเนิดสายพันธุ์ไม่ดี อาจทำให้ได้ประชากรลูกหลานในรุ่นถัดไปที่ไม่ดีไป ด้วย นอกจากนี้ยังพบปัญหาการลู่เข้าค่าตอบที่ดีเฉพาะที่ (Local Maxima) แต่อาจจะไม่ใช่ค่าตอบที่ ถูกต้อง และความหลากหลายทางสายพันธุ์ก็ยังคงต้องอยู่ในกระบวนการคัดเลือกอีกด้วย โดยการวิจัย นี้โครโมโซมคือ ค่าน้ำหนักของแต่ละเส้นเชื่อมต่อระหว่างโหนดของโครงข่ายประสาทเทียม ดังนั้นการ วิจัยนี้จึงสนใจการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA เพื่อให้การคัดเลือกมีประสิทธิภาพที่ดีขึ้น หรือเป็นการลดปัญหาต่าง ๆ ที่เกิดขึ้น และเมื่อนำการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA ไป ใช้ในการพยากรณ์ร่วมกับวิธีอื่น ๆ จะทำให้มีความแม่นยำในการพยากรณ์เพิ่มมากขึ้นด้วย

การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA นี้ใช้หลักการร่วมกัน 3 หลักการได้แก่ หลักการ Normalized Geometric Ranking (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อ รูเล็ต (Roulette Wheel Selection) (Yu, Fu, Li, & Dong, 2016) และหลักการคัดเลือกแบบ แข่งขัน (Goldberg & Deb, 1991) นอกจากนี้การวิจัยนี้ยังนำการคัดเลือกแบบแข่งขันที่พัฒนาขึ้น ของวิธี GA มาใช้ร่วมกับโครงข่ายประสาทเทียม เพื่อพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย โดยโครงข่ายประสาทเทียมจัดอยู่ในประเภทของการพยากรณ์ที่ใช้ข้อมูลนำเข้า เพื่อพยากรณ์ ผลลัพธ์ที่เป็นค่าส่งออก (Anderson & McNeill, 1992) ร่วมกับการคัดเลือกตัวแปรนำเข้าโดยใช้วิธี MRA (ทวี ชัยพิมลพลิน, 2557; บุญชม ศรีสะอาด, 2556, หน้า 110-111; พูลพงศ์ สุขสว่าง, 2561, หน้า 95; อรณรงค์ บุเกตุ และพฤษดี ศิริแสงตระกูล, 2556; อัตพล คุณเลิศ และพฤษดี ศิริแสงตระกูล, 2557; Larasati, DeYong, & Slevitch, 2011) เพื่อให้ได้ตัวแปรพยากรณ์หรือตัวแปรอิสระที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุด ความเป็นไปได้อีกอย่างหนึ่งในการคัดเลือกตัวแปรนำเข้าคือ การตรวจสอบน้ำหนักการเชื่อมต่อของโครงข่ายประสาทเทียม โดยตัวแปรที่มีน้ำหนักการเชื่อมต่อต่ำมี โอกาสที่จะถูกกำจัดออกไป (Larasati et al., 2011) ข้อดีคือ เป็นการลดมิติของตัวแปรนำเข้า ทำให้ จำนวนตัวแปรนำเข้าและจำนวนข้อมูลนำเข้าลดน้อยลง (West, Brockett, & Golden, 1997) ทำให้ เพิ่มความเร็วในการพยากรณ์ได้ และร่วมกับการใช้วิธี GA ซึ่งมีการแบ่งชุดข้อมูลออกเป็น ชุดการ เรียนรู้ (Training) เพื่อสอนโครงข่ายประสาทเทียม และชุดการทดสอบ (Testing) เพื่อทดสอบความ แม่นยำของตัวแบบพยากรณ์ พิจารณาความแม่นยำของตัวแบบจากค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย

(Mean Absolute Error: MAE) ค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ที่ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามี ความแม่นยำในการพยากรณ์ และค่าสัมประสิทธิ์ตัวกำหนด (Coefficient of Determination: R²) ที่ต้องมีค่ามาก ๆ เข้าใกล้ 1 จึงถือว่ามี ความแม่นยำในการพยากรณ์

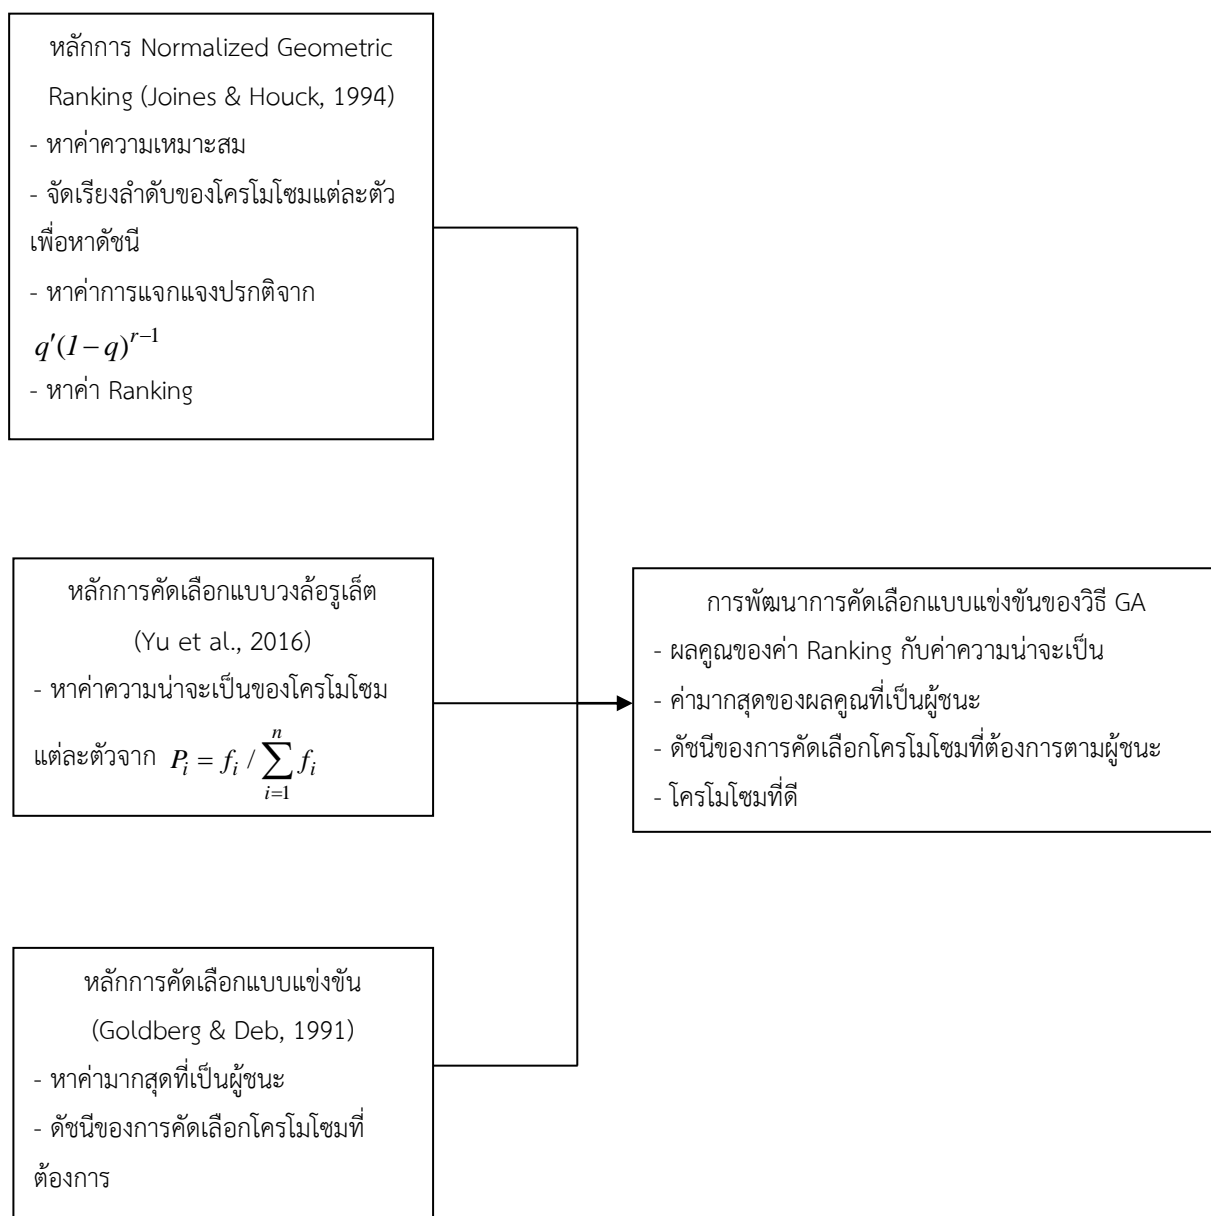
วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม
2. เพื่อเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์
3. เพื่อพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA

กรอบแนวคิดในการวิจัย

การวิจัยนี้เป็นการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA เพื่อให้การคัดเลือกมีประสิทธิภาพที่ดีขึ้นหรือเป็นการลดปัญหาต่าง ๆ ที่เกิดขึ้น และเมื่อนำการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA ไปใช้ในการพยากรณ์ร่วมกับวิธีอื่น ๆ จะทำให้มีความแม่นยำในการพยากรณ์มากขึ้น การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ใช้หลักการ Normalized Geometric Ranking (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) และหลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991) โดยหลักการ Normalized Geometric Ranking (Joines & Houck, 1994) เริ่มจากการประเมินหาค่าความเหมาะสม (Fitness Function) นำค่าความเหมาะสมมาจัดเรียง (Sort) ลำดับ (Rank) ของโครโมโซมแต่ละตัว เพื่อหาดัชนี (Index) ของลำดับของการจัดเรียง จากนั้นหาค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัวจาก $q'(1-q)^{r-1}$ แล้วนำค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัวแทนตามตำแหน่งดัชนีของลำดับของการจัดเรียง จะได้เป็นค่า Ranking หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) หาค่าความน่าจะเป็น (Probabilities) ของแต่ละโครโมโซมจากค่าความเหมาะสม (Fitness Value) จาก $p_i = f_i / \sum_{i=1}^n f_i$ แล้วนำค่าความน่าจะเป็นมาคูณกับค่า Ranking ของแต่ละโครโมโซม เพื่อเข้าสู่กระบวนการคัดเลือกแบบแข่งขัน ตามหลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991) โดยหาค่ามากที่สุด (Max) ของแต่ละแถว ซึ่งจะเป็นผู้ชนะ (Winner) ของ

Tournament ทำให้ได้ดัชนีของการคัดเลือกโครโมโซมที่ต้องการ และได้โครโมโซมที่ดีที่สุดสำหรับใช้ในกระบวนการต่อไป ดังนั้นกรอบแนวคิดการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ดังภาพที่ 1-1



ภาพที่ 1-1 กรอบแนวคิดการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA

สมมติฐานในการวิจัย

1. ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมร่วมกับการคัดเลือกแบบแข่งขันของวิธี GA ที่พัฒนาขึ้นมีความแม่นยำสูงกว่า Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้อข้อมูล 5 สถานการณ์
2. การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA สามารถพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยที่มีค่า R^2 มากกว่า 0.7

ประโยชน์ที่คาดว่าจะได้รับ

1. ได้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA
2. ได้วิธีการพยากรณ์ปริมาณน้ำฝนที่มีความแม่นยำ มีความคลาดเคลื่อนต่ำและรวดเร็ว
3. เป็นแนวทางในการนำตัวแบบพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA มาประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำฝนกับข้อมูลจริง

ขอบเขตของการวิจัย

การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA (วัตถุประสงค์ข้อ 1) มีรายละเอียดดังนี้

1. หลักการที่นำมาใช้คือ หลักการ Normalized Geometric Ranking (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) และหลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991)

การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์ (วัตถุประสงค์ข้อ 2) มีรายละเอียดดังนี้

1. ตัวแบบพยากรณ์เป็นแบบที่ใช้โครงข่ายประสาทเทียมร่วมกับวิธี GA ที่มีการนำวิธี GA มากำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม และที่มีการนำวิธี GA มาปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับ

2. ข้อมูลที่ใช้เป็นข้อมูลจริงเก็บรวบรวมจาก National Centers for Environmental Prediction (NCEP)–NOAA (NOAA NCEP-NCAR, 2019) เป็นข้อมูลจังหวัดในภาคกลางของประเทศไทยตั้งแต่ 1 มกราคม พ.ศ. 2503 ถึง 31 มกราคม พ.ศ. 2561 เพื่อใช้เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) และ Wang et

al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA กับที่ใช้การคัดเลือกแบบเดิมของวิธี GA โดยใช้โปรแกรม Matlab ในการสร้างตัวแบบทั้ง 6 แบบ ภายใต้ข้อมูล 5 สถานการณ์ตามขนาดของข้อมูลเป็น 5 แบบดังนี้ 300 400 500 1000 และ 1100 จำนวน ซึ่งตัวแบบพยากรณ์เดิมนั้นใช้วิธี GA ร่วมกับโครงข่ายประสาทเทียม โดยของ Asadi et al. (2013) ใช้วิธี GA ในการหาค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงในแต่ละเส้นเชื่อมของโครงข่ายประสาทเทียมแบบ FFNN และของ Wang et al. (2017) ใช้วิธี GA กำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียมแบบ BPNN ซึ่งการสร้างตัวแบบพยากรณ์สำหรับนำมาเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ของ Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ใช้รูปแบบโครงสร้างของ Asadi et al. (2013) และ Wang et al. (2017) ตามลำดับ การวิจัยนี้ยังมีการศึกษาเพิ่มเติมโดยการนำรูปแบบโครงสร้างมาปรับเปลี่ยนตำแหน่งของวิธี GA โดยใช้วิธี GA ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมาปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียมทั้งของ Asadi et al. (2013) และ Wang et al. (2017) เพื่อนำมาใช้ในการเปรียบเทียบประสิทธิภาพด้วย

3. ตัวแปรพยากรณ์คือ วิธีการพยากรณ์ 6 วิธีคือ ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA กับที่ใช้การคัดเลือกแบบเดิมของวิธี GA

4. ตัวแปรเกณฑ์คือ ความแม่นยำของการพยากรณ์โดยพิจารณาจากค่า MAE MAPE RMSE และ R^2

5. การสังเคราะห์ตัวแปรที่ส่งผลต่อปริมาณน้ำฝนในภาคกลางของประเทศไทย โดยใช้วิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าสู่สำหรับตัวแบบ Asadi et al. (2013) ศึกษาภายใต้เงื่อนไขดังนี้

5.1 ข้อมูลประกอบด้วย ข้อมูลชุดของตัวแปรพยากรณ์ (Predictor Variables) หรือตัวแปรอิสระ (Independent Variables) (x_i) และตัวแปรเกณฑ์ (Criterion Variable) (Y')

5.2 ข้อมูลตัวแปรพยากรณ์จำนวน 7 ตัวแปรได้แก่ ความชื้นสัมพัทธ์ของอากาศ (Relative Humidity) (x_1) ความเร็วลม (Wind Speed) และทิศทางลม (Wind Direction) ในแนวตะวันออก-ตะวันตก (Zonal Wind) (ความเร็วลมตามแนวแกน x) (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (Meridional Wind) (ความเร็วลมตามแนวแกน y) (x_3) การระเหย (Evaporation) ของน้ำ (x_4) อุณหภูมิอากาศ (Air Temperature) สูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และอุณหภูมิอากาศเฉลี่ย (x_7)

5.3 ข้อมูลตัวแปรเกณฑ์จำนวน 1 ตัวแปรคือ ปริมาณน้ำฝนในภาคกลางของประเทศไทย (Y')

5.4 ตรวจสอบข้อตกลงเบื้องต้นในการวิเคราะห์ MRA (Hair, Black, Babin, & Anderson, 2010, pp. 181-186) ดังนี้

5.4.1 ตรวจสอบ Normality หมายถึงการแจกแจงของตัวแปรเกณฑ์จะต้องมีลักษณะเป็นโค้งปกติ

5.4.2 ตรวจสอบ Linearity หมายถึงตัวแปรพยากรณ์แต่ละตัวและตัวแปรเกณฑ์จะต้องมีความสัมพันธ์กันในลักษณะของเส้นตรง

5.4.3 ตรวจสอบ Homoscedasticity หมายถึงการแจกแจงทุก ๆ ค่าของตัวแปรพยากรณ์บนตัวแปรเกณฑ์มีค่าใกล้เคียงกัน

5.4.4 ตรวจสอบ Independence of the Error Terms หมายถึงความคลาดเคลื่อนจากการวัดตัวแปรพยากรณ์แต่ละตัวจะต้องเป็นอิสระต่อกัน

5.5 กำหนดความสัมพันธ์ของตัวแปรพยากรณ์กับตัวแปรเกณฑ์ เป็นสมการพยากรณ์เชิงเส้นตรงในรูปคะแนนดิบดังนี้ (บุญชม ศรีสะอาด, 2556, หน้า 110-111)

$$Y' = a + b_1x_1 + b_2x_2 + \dots + b_kx_k$$

โดยที่ Y' แทนคะแนนพยากรณ์ของตัวแปรเกณฑ์

a แทนค่าคงที่ของสมการพยากรณ์ในรูปคะแนนดิบ

b_1, b_2, \dots, b_k แทนค่าน้ำหนักหรือสัมประสิทธิ์ถดถอย (Regression Coefficient) ของตัวแปรพยากรณ์ตัวที่ 1 ถึงตัวที่ k

x_1, x_2, \dots, x_k แทนคะแนนของตัวแปรพยากรณ์ตัวที่ 1 ถึงตัวที่ k

k แทนจำนวนตัวแปรพยากรณ์

5.6 กำหนดค่า $k = 7$

5.7 พิจารณาความสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์กับตัวแปรเกณฑ์จากค่า R มีค่าอยู่ระหว่าง .00 ถึง 1.00 ไม่มีค่าที่เป็นลบ และพิจารณาค่า b ของตัวแปรพยากรณ์แต่ละตัวจากสมการพยากรณ์ตัวแปรเกณฑ์ด้วยชุดของตัวแปรพยากรณ์

6. ข้อมูลนำเข้าของตัวแบบ Asadi et al. (2013) เป็นข้อมูลของตัวแปรพยากรณ์ที่ได้จากการสังเคราะห์ตัวแปรที่ส่งผลต่อปริมาณน้ำฝนในภาคกลางของประเทศไทยด้วยวิธี MRA แบบ Stepwise (จากข้อ 5) และปริมาณน้ำฝนในภาคกลางเป็นข้อมูลส่งออก ส่วนของ Wang et al. (2017) ใช้ข้อมูลนำเข้าของตัวแปรทุกตัว แบ่งข้อมูลนำเข้าเป็น 2 ชุดได้แก่ ชุดการเรียนรู้ 77% และชุดการทดสอบ 23% (Wang et al., 2017)

7. สถาปัตยกรรมของโครงข่ายประสาทเทียมของตัวแบบ Asadi et al. (2013)

ประกอบด้วยจำนวนชั้นรับข้อมูลเข้า (Input Layer) จำนวน 1 ชั้น n โหนด (จำนวนตัวแปรที่ผ่านการคัดเลือก n ตัว) ชั้นซ่อน (Hidden Layer) จำนวน 2 ชั้น ชั้นละ 4 โหนด และชั้นส่งข้อมูลออก (Output Layer) จำนวน 1 ชั้น 1 โหนด โดยกำหนดฟังก์ชัน (Transformation Function) ชั้นรับข้อมูลออก คือ ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent Function: Tanh) และชั้นซ่อนแต่ละชั้น คือ ฟังก์ชันล็อก-ซิกมอยด์ (Log-sigmoid Function: Log-sig) ขั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ Lavenberg Marquardt (LM) ใช้การคัดเลือกแบบแบ่งเป็นช่วง (Truncation Selection) มีการสลับสายพันธุ์แบบสองตำแหน่ง (Two-point Crossover) โดยกำหนดความน่าจะเป็นในการสลับสายพันธุ์เท่ากับ 0.85 และการกลายพันธุ์แบบหนึ่งตำแหน่ง (One-point Mutation) โดยกำหนดความน่าจะเป็นในการกลายพันธุ์เท่ากับ 0.05

8. สถาปัตยกรรมของโครงข่ายประสาทเทียมของตัวแบบ Wang et al. (2017)

ประกอบด้วยจำนวนชั้นรับข้อมูลเข้าจำนวน 1 ชั้น 7 โหนด ชั้นซ่อนจำนวน 1 ชั้น 11 โหนด และชั้นส่งข้อมูลออกจำนวน 1 ชั้น 1 โหนด โดยกำหนดฟังก์ชันชั้นรับข้อมูลออก คือ ฟังก์ชันเพียวลิน (Purelin Function: Purelin) และชั้นซ่อน คือ ฟังก์ชัน Log-sig ขั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ Bayesian Regularization (BR) ใช้การคัดเลือกแบบวงล้อรูเล็ต มีการสลับสายพันธุ์แบบ Arithmetic Crossover โดยกำหนดความน่าจะเป็นในการสลับสายพันธุ์เท่ากับ 0.7 และการกลายพันธุ์แบบนอนยูนิฟอร์ม (Non-uniform Mutation) โดยกำหนดความน่าจะเป็นในการกลายพันธุ์เท่ากับ 0.05

9. เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมร่วมกับการคัดเลือกแบบแข่งขันของวิธี GA ที่พัฒนาขึ้น เมื่อใช้วิธี GA กำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียมและใช้วิธี GA ปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับ เปรียบเทียบความแม่นยำกับของ Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบเดิมของวิธี GA ว่าวิธีการใดให้ความแม่นยำในการพยากรณ์มากที่สุด

10. พิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE MAPE RMSE และ R^2 ดังนี้

$$MAE = \frac{\sum_{i=1}^n |T_i - O_i|}{n}$$

$$MAPE = \frac{\sum_{i=1}^n |T_i - O_i| / T_i}{n} \times 100$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - O_i)^2}{n}}$$

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST}; SSR = SST - SSE, SST = \sum_{i=1}^n (T_i - \bar{T})^2, SSE = \sum_{i=1}^n (T_i - O_i)^2$$

โดยที่ n คือจำนวนข้อมูลนำเข้า

T_i คือข้อมูลที่เป็นผลลัพธ์จริง

\bar{T} คือค่าเฉลี่ยของข้อมูลที่เป็นผลลัพธ์จริง

O_i คือข้อมูลของค่าพยากรณ์

SSR คือผลรวมกำลังสองของการถดถอย (Sum of Squares Regression) เป็นการผันแปรที่สามารถอธิบายได้

SST คือผลบวกของกำลังสองรวม (Sum of Squares Total)

SSE คือผลรวมของค่าความคลาดเคลื่อนกำลังสอง (Sum of Squares Error) เป็นการผันแปรที่ไม่สามารถอธิบายได้

11. กำหนดจำนวนการทำซ้ำในแต่ละรอบเท่ากับ 3000 สำหรับตัวแบบที่ใช้เปรียบเทียบกับของ Asadi et al. (2013) และ 1000 สำหรับตัวแบบที่ใช้เปรียบเทียบกับ Wang et al. (2017)
12. ค่าความเหมาะสมของโครโมโซมแต่ละตัวคำนวณได้จากสูตร

$$f_i = \frac{1}{SSE_i}$$

โดยที่ f_i คือค่าความเหมาะสมของโครโมโซมตัวที่ i

SSE_i คือผลรวมของค่าความคลาดเคลื่อนกำลังสองของโครโมโซมตัวที่ i

13. โครโมโซมแต่ละตัวคือ ค่าน้ำหนักของแต่ละเส้นเชื่อมต่อระหว่างโหนดของโครงข่ายประสาทเทียม

การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA (วัตถุประสงค์ข้อ 3) มีรายละเอียดดังนี้

1. ข้อมูลที่ใช้สำหรับพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย เป็นข้อมูลจริงของจังหวัดในภาคกลางเก็บรวบรวมจาก NCEP-NOAA (NOAA NCEP-NCAR, 2019) ตั้งแต่ปี พ.ศ. 2532-2561 ประกอบด้วยข้อมูลนำเข้าจำนวน 7 ตัวแปร (x_i) และข้อมูลส่งออกจำนวน 1 ตัวแปร (y) เพื่อพยากรณ์ปริมาณน้ำฝนในภาคกลางจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566

2. ข้อมูลนำเข้าจำนวน 7 ตัวแปรได้แก่ ความชื้นสัมพัทธ์ของอากาศ (Relative Humidity) (x_1) ความเร็วลม (Wind Speed) และทิศทางลม (Wind Direction) ในแนวตะวันออก-ตะวันตก

(Zonal Wind) (ความเร็วลมตามแนวแกน x) (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (Meridional Wind) (ความเร็วลมตามแนวแกน y) (x_3) การระเหย (Evaporation) ของน้ำ (x_4) อุณหภูมิอากาศ (Air Temperature) สูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และอุณหภูมิอากาศเฉลี่ย (x_7)

3. ข้อมูลส่งออกจำนวน 1 ตัวแปรคือ ปริมาณน้ำฝนในภาคกลางของประเทศไทย (y)

4. นำตัวแบบพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA มาใช้สำหรับพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยแบบรายฤดูกาล 3 ฤดูกาลได้แก่ 1) ฤดูร้อนคือ เดือนกุมภาพันธ์ มีนาคม เมษายน และพฤษภาคม 2) ฤดูฝนคือ เดือนมิถุนายน กรกฎาคม สิงหาคม และกันยายน 3) ฤดูหนาวคือ เดือนตุลาคม พฤศจิกายน ธันวาคม และมกราคม ด้วยโปรแกรม Matlab

5. รายงานผลการพยากรณ์ และพิจารณาความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA จากค่า MAE MAPE RMSE และ R^2

นิยามศัพท์เฉพาะ

ตัวแบบ (Model) หมายถึงการใช้คณิตศาสตร์ในการอธิบายความสัมพันธ์ขององค์ประกอบหรือตัวแปรต่าง ๆ โดยใช้สัญลักษณ์ทางคณิตศาสตร์ สามารถแสดงผลของส่วนสำคัญของระบบที่มีอยู่หรือระบบที่กำลังจะถูกสร้างขึ้น เพื่อแสดงความรู้ของระบบในรูปแบบที่สามารถนำไปใช้งานได้

ค่าความคลาดเคลื่อนของการพยากรณ์ (Forecast Error) หมายถึงความแตกต่างระหว่างค่าจริงกับค่าที่ได้จากการพยากรณ์

ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) หมายถึงค่าเฉลี่ยของค่าสัมบูรณ์ของผลต่างระหว่างค่าจริงกับค่าที่ได้จากการพยากรณ์ ถ้าค่า MAE มีค่าน้อย แสดงว่าตัวแบบพยากรณ์สามารถประมาณค่าได้ใกล้เคียงกับค่าจริง ดังนั้นการพยากรณ์มีความแม่นยำสูง

ค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) หมายถึงค่าที่ได้จากผลรวมของค่าสัมบูรณ์ของผลต่างระหว่างค่าจริงกับค่าที่ได้จากการพยากรณ์หารด้วยค่าจริง จากนั้นหารด้วยจำนวนข้อมูลทั้งหมดและคูณด้วย 100 ถ้าค่า MAPE มีค่าน้อย แสดงว่าตัวแบบพยากรณ์สามารถประมาณค่าได้ใกล้เคียงกับค่าจริง ดังนั้นการพยากรณ์มีความแม่นยำสูง

รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) หมายถึงค่าที่ได้จากรากที่สอง (Square Root) ของผลต่างระหว่างค่าจริงกับค่าที่ได้จากการพยากรณ์ยกกำลังสองหารด้วยจำนวนข้อมูลทั้งหมด ก็คือ \sqrt{MSE} โดยที่ MSE คือค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง

(Mean Square Error) ถ้าค่า RMSE มีค่าน้อย แสดงว่าตัวแบบพยากรณ์สามารถประมาณค่าได้ใกล้เคียงกับค่าจริง ดังนั้นการพยากรณ์มีความแม่นยำสูง

ค่าสัมประสิทธิ์ตัวกำหนด (Coefficient of Determination: R^2) หมายถึงค่าสัดส่วนของผลบวกกำลังสองของการถดถอยซึ่งการผันแปรที่สามารถอธิบายได้กับผลบวกกำลังสองของผลรวม R^2 เป็นค่าที่แสดงความแม่นยำของการพยากรณ์ถ้าค่าสัมประสิทธิ์ตัวกำหนดมีค่าเข้าใกล้ 1 เท่าไรยิ่งมีความแม่นยำมากขึ้นเท่านั้น

ความแม่นยำ (Accuracy) หมายถึงประสิทธิภาพการพยากรณ์ของตัวแบบ ถ้าผลลัพธ์ที่ได้จากตัวแบบพยากรณ์มีค่าการพยากรณ์ใกล้เคียงค่าผลลัพธ์จริงจะมีความแม่นยำสูง ถ้าเท่ากับผลลัพธ์จริงจะมีความแม่นยำสูงสุด การพิจารณาความแม่นยำของตัวแบบในงานวิจัยนี้ พิจารณาจากค่า MAE MAPE RMSE และ R^2

สัมประสิทธิ์ถดถอย (Regression Coefficient: b) หมายถึงค่าที่แสดงว่าเมื่อตัวแปรพยากรณ์ (x_i) ตัวนั้นเปลี่ยนแปลงไป 1 หน่วยจะทำให้ตัวแปรตัวเกณฑ์ (Y') เปลี่ยนแปลงไป b หน่วย

ค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณ (Multiple Correlation Coefficient: R) หมายถึงค่าที่แสดงความสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์กับตัวแปรเกณฑ์

ปริมาณน้ำฝน (Rainfall) หมายถึงระดับน้ำฝนในภาชนะที่รองรับน้ำฝน ที่ตั้งอยู่ในแนวระดับและวัดในช่วงเวลาที่กำหนด โดยปริมาณน้ำฝนจะคำนวณเป็นมิลลิเมตรต่อวัน งานวิจัยนี้ใช้หน่วยเป็นมิลลิเมตร (มม.) (Millimeter: mm)

ความชื้นสัมพัทธ์ของอากาศ (Relative Humidity) หมายถึงอัตราส่วนของปริมาณไอน้ำที่มีอยู่จริงในอากาศต่อปริมาณไอน้ำที่จะทำให้อากาศอิ่มตัว ณ อุณหภูมิเดียวกันหรืออัตราส่วนของความดันไอน้ำที่มีอยู่จริงต่อความดันไอน้ำอิ่มตัว ถ้ามีไอน้ำอยู่ในอากาศน้อยเรียกว่าอากาศแห้ง แต่ถ้ามีไอน้ำอยู่ในอากาศมากเรียกว่าอากาศชื้น ความชื้นสัมพัทธ์ของอากาศมีหน่วยเป็นร้อยละหรือเปอร์เซ็นต์ (%)

ความเร็วลม (Wind Speed) หมายถึงอัตราเร็วของการเคลื่อนที่ของอากาศที่ทำให้เกิดแรงหรือความเร็วของอากาศที่เคลื่อนผ่านจุดที่กำหนดบนผิวโลก ทางอุตุนิยมวิทยาการวัดลมกำหนดให้มีการวัดลมชั้นบน (Upper Wind) และลมผิวพื้น (Surface Wind) ที่ระดับความสูง 850 เฮกโตปาสกาลและระดับความสูง 200 เฮกโตปาสกาล ตามลำดับ ความเร็วลมมีหน่วยเป็นเมตรต่อวินาที กิโลเมตรต่อชั่วโมง ไมล์ต่อชั่วโมง หรือน็อต (Knots) สำหรับงานวิจัยนี้ใช้ความเร็วลมผิวพื้นที่มีหน่วยเป็นเมตรต่อวินาที (Meter Per Second: m/s)

ทิศทางลม (Wind Direction) หมายถึงทิศทางการกำเนิดของลมเทียบกับจุดสังเกต การรายงานทิศทางลมมี 2 ระบบคือ ลมในแนวตะวันออก-ตะวันตก (Zonal Wind) (ลมตามแนวแกน x) และลมในแนวเหนือ-ใต้ (Meridional Wind) (ลมตามแนวแกน y) สำหรับงานวิจัยนี้ ทิศทางลมมีค่าเป็นบวกและลบ โดยลมในแนวตะวันออก-ตะวันตก จะเป็นบวกเมื่อทิศทางลมพัดจากทิศตะวันตกไปทางทิศตะวันออก (ทางขวาของแกน x) และเป็นลบเมื่อทิศทางลมพัดจากทิศตะวันออกไปทางทิศตะวันตก (ทางซ้ายของแกน x) สำหรับลมในแนวเหนือ-ใต้ จะเป็นบวกเมื่อทิศทางลมพัดจากทิศใต้ไปทางทิศเหนือ (ด้านบนของแกน y) เป็นลบเมื่อทิศทางลมพัดจากทิศเหนือไปทางทิศใต้ (ด้านล่างของแกน y)

การระเหย (Evaporation) ของน้ำ หมายถึงการที่น้ำเปลี่ยนสถานะจากของเหลวกลายเป็นไออย่างช้า ๆ และเกิดขึ้นเฉพาะผิวหน้าของน้ำเท่านั้น โดยไม่จำเป็นต้องมีอุณหภูมิถึงจุดเดือด ซึ่งเป็นกระบวนการที่ตรงกันข้ามกับการควบแน่น การระเหยจะคำนวณเป็นมิลลิเมตรต่อวัน งานวิจัยนี้ใช้หน่วยเป็นมิลลิเมตร (มม.)

อุณหภูมิอากาศ (Air Temperature) หมายถึงระดับความร้อนที่ปรากฏขึ้นของอากาศ สามารถวัดค่าอุณหภูมิอากาศได้เป็นตัวเลขที่แน่นอน อุณหภูมิอากาศมีความสัมพันธ์กับการรับและส่งถ่ายพลังงานความร้อนจากดวงอาทิตย์ ซึ่งการเปลี่ยนแปลงอุณหภูมิอากาศเกิดจากการที่โลกหมุนรอบตัวเองในแต่ละวัน การวัดอุณหภูมิอากาศมีหน่วยเป็นองศาเคลวิน ($^{\circ}\text{K}$) หรือองศาเซลเซียส ($^{\circ}\text{C}$) สำหรับงานวิจัยนี้ใช้หน่วยเป็นองศาเซลเซียส ($^{\circ}\text{C}$)

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การศึกษาการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม ผู้วิจัยนำเสนอทฤษฎีแนวคิดและงานวิจัยที่เกี่ยวข้อง ดังนี้

ตอนที่ 1 การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมและงานวิจัยที่เกี่ยวข้อง

ตอนที่ 2 การวิเคราะห์ถดถอยพหุคูณ (Multiple Regression Analysis: MRA) และงานวิจัยที่เกี่ยวข้อง

ตอนที่ 3 วิธีโครงข่ายประสาทเทียม (Artificial Neural Network) และงานวิจัยที่เกี่ยวข้อง

ตอนที่ 4 ข้อมูลปริมาณน้ำฝน การพยากรณ์ปริมาณน้ำฝนและงานวิจัยที่เกี่ยวข้อง

ตอนที่ 5 ข้อมูลอุตุวิทยามหาวิทยาลัยที่เกี่ยวข้องกับปริมาณน้ำฝน

ตอนที่ 1 การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมและงานวิจัยที่เกี่ยวข้อง

การพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) ใช้หลักการ Normalized Geometric Ranking (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) และหลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991) เพื่อให้ได้การคัดเลือกรูปแบบใหม่ของวิธี GA สำหรับนำมาสร้างตัวแบบพยากรณ์ปริมาณน้ำฝนร่วมกับวิธีโครงข่ายประสาทเทียมและวิธี MRA นิยาม ทฤษฎีและงานวิจัยที่เกี่ยวข้องกับพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ดังนี้

วิธี GA เป็นเทคนิคทางปัญญาประดิษฐ์ (Artificial Intelligence) อย่างหนึ่งที่ใช้ในการค้นหา การเพิ่มประสิทธิภาพและการเรียนรู้ด้วยการเลียนแบบทฤษฎีกระบวนการวิวัฒนาการทางธรรมชาติ (M. Mitchell, 1996, pp. 6-8) จากความสำเร็จของกระบวนการวิวัฒนาการทางธรรมชาติ ในการคัดเลือกสิ่งมีชีวิตที่เหมาะสมกับสภาพแวดล้อม การกลายพันธุ์เพื่อเปิดโอกาสในการพัฒนาสายพันธุ์ และการอยู่รอดของเผ่าพันธุ์ด้วยการปรับตัวให้เข้ากับสิ่งแวดล้อมที่เปลี่ยนแปลงไปรวมถึงการส่งต่อลักษณะทางพันธุกรรมของเผ่าพันธุ์ที่เหมาะสมในลักษณะของการถ่ายทอดและผสมยีนของรุ่นพ่อแม่ไปยังรุ่นลูกหลาน ได้กลายเป็นแรงบันดาลใจของมนุษย์ในการค้นหาคำตอบ (วิธีการ) ที่เหมาะสมที่สุดในการแก้ปัญหา (T. M. Mitchell, 1997, p. 249) วิธี GA เป็นวิธีที่ใช้หาค่าที่เหมาะสมที่สุดที่มี

ลักษณะการทำงานในรูปแบบของการค้นหาคำตอบแบบวิธีเชิงศึกษาสำนึกหรือฮิวริสติก (Heuristic) ถูกคิดค้นในปี ค.ศ. 1975 โดยจอห์น ฮอลแลนด์ (John Holland) ซึ่งได้รับแรงบันดาลใจจากทฤษฎีวิวัฒนาการทางธรรมชาติของชาร์ล ดาร์วิน (Charles Darwin) (Mohammadi, Lakestani, & Mohamed, 2018) โดยอิงแนวคิดเรื่องการอยู่รอดของผู้ที่แข็งแกร่งที่สุด (Survival Of The Fittest) คือผู้ที่แข็งแกร่งกว่าย่อมมีโอกาสในการอยู่รอดมากกว่า (Gupta, Vasudev, & Bhattacharyya, 2018; Raeisi-Vanani, Shayannejad, Soltani-Toudeshki, Arab, Eslamian, Amoushahi-Khouzani, Marani-Barzani, & Ostad-Ali-Askari, 2017) และมีโอกาสในการถ่ายทอดลักษณะที่แข็งแกร่งนั้นไปยังรุ่นถัดไป ซึ่งวิธี GA เป็นการค้นหาคำตอบที่ดีที่สุดในการแก้ปัญหาด้วยการเลียนแบบกระบวนการวิวัฒนาการทางธรรมชาติ (Holland, 1975, p. 183; Vakili, Khosrojerdi, Aghajannezhad, & Yahyaei, 2017) หลักการทำงานของวิธี GA เป็นไปในลักษณะการหาคำตอบแบบคู่ขนาน (Parallel Search) (T. M. Mitchell, 1997, p. 250) โดยคำตอบที่ได้จากการหาคำตอบในหนึ่งรุ่น (Generation) จะผ่านการแปลง (Transformation) เพื่อที่จะนำไปสู่การค้นหาคำตอบที่ดีขึ้นในรุ่นถัดไป การเปลี่ยนแปลงที่เกิดขึ้นกับคำตอบหรือสมาชิกของประชากร (Individual) ภายในกลุ่มประชากร (Population) หนึ่งรุ่นนั้นเป็นไปเพื่อการสำรวจพื้นที่ในการค้นหา (Search Space) และส่งเสริมให้มีการถ่ายทอดคุณลักษณะที่ดี (Fit Characteristics) ของคำตอบที่ค้นพบในรุ่นปัจจุบันไปยังรุ่นถัดไป (Gupta et al., 2018) สมาชิกของประชากรที่มีคุณลักษณะที่ดีหรือคำตอบที่มีคุณลักษณะที่ดีจะมีอยู่หลายคำตอบ ซึ่งจะนำไปสู่คำตอบที่มีค่าเหมาะสมที่สุด (Optimum Solution) หรือสมาชิกของประชากรที่มีลักษณะที่ดีที่สุด (Fittest Individual) วิธี GA เป็นเทคนิคการหาค่าเหมาะสมที่สุดวิธีหนึ่ง จัดอยู่ในกลุ่มของวิธีการหาค่าเหมาะสม โดยวิธีแบบประมาณค่า (Approximation Optimization Algorithms) (Whitley, 1994) ซึ่งวิธีที่หาค่าเหมาะสมที่สุดนั้นแบ่งเป็น 2 กลุ่ม คือ กลุ่มวิธีแบบดั้งเดิม (Conventional Optimization Algorithms) โดยใช้วิธีการทางคณิตศาสตร์ที่ให้ค่าผลของคำตอบแบบแม่นยำตรง (Exact Solution) และกลุ่มวิธีแบบประมาณค่าในการหาค่าคำตอบของทั้งสองกลุ่มวิธีนั้นเหมาะสมสำหรับปัญหาที่มีขนาดใหญ่และมีความซับซ้อน วิธีการหาค่าคำตอบแบบดั้งเดิมอาจจะสามารถหาค่าคำตอบได้หรือไม่ก็ได้ แต่การหาค่าตอบจะใช้ระยะเวลาอันยาวนาน ส่วนวิธีการหาค่าคำตอบแบบประมาณค่าจะใช้ระยะเวลาในการประมวลผลสั้นกว่า และให้ค่าคำตอบที่ใกล้เคียงกับค่าคำตอบที่ดีที่สุด ดังนั้นในปัจจุบันวิธีการหาค่าคำตอบแบบประมาณค่าจึงได้รับความนิยมมากขึ้น (อภิรักษ์ ชติวิลาศ, 2554) จึงมีการนำวิธี GA ไปประยุกต์ใช้ในการหาค่าที่ดีที่สุดหรือเหมาะสมที่สุดอย่างแพร่หลาย จุดเด่นของการค้นหาด้วยขั้นตอนวิธี GA คือความอ่อนตัวและความทนทานต่อการความผิดพลาดและความแตกต่างของแหล่งข้อมูลที่ใช้ในการค้นหาคำตอบ และ GA จะเก็บผลเฉลยเป็นเซตในขณะที่วิธีการอื่นจะเป็นการเก็บและเปลี่ยนแปลงที่ผลเฉลย

(Goldberg, 1989, p. 7; Raeisi-Vanani et al., 2017) กระบวนการทำงานของวิธี GA มีขั้นตอน ดังนี้


1.1 การสร้างประชากรเริ่มต้น (Initial Population) ของคำตอบ การสร้างประชากรเริ่มต้น เริ่มจากการสุ่มค่าให้ยีน (Gene) แล้วระบบจะทำการแปลงหรือเข้ารหัส (Encoding) ผลลัพธ์ที่เป็นปัญหาทางคณิตศาสตร์ให้อยู่ในรูปโครโมโซม (Chromosome) ตัวแปรที่ต้องการค้นหาหมายถึง ยีน หนึ่งยีนเมื่อนำมาประกอบกันจึงได้โครโมโซมหรือรหัสพันธุกรรม (Genotype) การเข้ารหัสของโครโมโซมเป็นขั้นตอนที่สำคัญเพราะก่อนที่จะเข้าสู่กระบวนการต่าง ๆ ของวิธี GA จำเป็นต้องผ่านการเข้ารหัสโครโมโซมก่อน จึงจะสามารถดำเนินการกระบวนการอื่นได้ รูปแบบการเข้ารหัสโครโมโซมขึ้นอยู่กับปัญหา การเข้ารหัสโครโมโซมมีหลายรูปแบบได้แก่ การเข้ารหัสโครโมโซมแบบเลขฐานสอง (Binary Encoding) และได้มีการพัฒนาเป็นการเข้ารหัสแบบจำนวนเต็ม (Integer Encoding) หรือการเข้ารหัสแบบจำนวนจริง (Real Encoding) (Davis, 1991; Janikow & Michalewicz, 1991; Sevenster & Engelbrecht, 1996) การเข้ารหัสแบบเลขฐานสองเป็นวิธีที่ง่ายที่สุดในการเข้ารหัส และใช้ได้กับปัญหาทั่วไปของการหาค่าเหมาะสมที่สุด ส่วนการเข้ารหัสแบบจำนวนเต็มจะทำให้โครโมโซมมีความยาวน้อยกว่าการเข้ารหัสแบบฐานสอง เพราะตัวเลขแต่ละตัวจะสามารถใช้แทนตัวแปรตัดสินใจได้ ซึ่งแตกต่างจากกรณีของการเข้ารหัสแบบฐานสองที่ต้องการใช้เลขฐานสองเป็นกลุ่มในการนำเสนอตัวแปรตัดสินใจหนึ่งตัว และการเข้ารหัสแบบจำนวนจริงจะใช้ตัวเลขที่เป็นจำนวนจริงแสดงถึงค่าฟีโนไทป์ (Phenotype) ของตัวแปรตัดสินใจโดยตรง แต่ต้องกำหนดช่วงการทำงานหรือช่วงค่าตัดสินใจแต่ละตัว ความแม่นยำของคำตอบสามารถกำหนดได้จากจำนวนตำแหน่งของทศนิยมที่ใช้แสดงตัวแปรตัดสินใจบนโครโมโซมได้โดยตรง ความยาวโครโมโซมจะสั้นกว่าแบบเลขฐานสอง (พยุ่ง มีสัจ, 2555, หน้า 195–196) เมื่อกำหนดการเข้ารหัสแล้วระบบจะทำการสุ่มกลุ่มโครโมโซมนี้ขึ้นมาเป็นประชากร จำนวนโครโมโซมในประชากรแต่ละรุ่นขึ้นกับพารามิเตอร์ที่กำหนด ความยาวของโครโมโซมขึ้นอยู่กับจำนวนตัวแปรที่ต้องการหาค่าในระบบและมีผลต่อการกำหนดพารามิเตอร์จำนวนประชากรเพื่อหาค่าตอบที่ดีที่สุด (อวัช ธรรมทรัพย์ และสุรศักดิ์ มั่งสิงห์, 2559) โดยทั่วไปนิยมกำหนดประชากรเริ่มต้นโดยการสุ่มเลือกจำนวนโครโมโซมเท่ากับจำนวนประชากรทั้งหมด (Goldberg, 1989)

1.2 การประเมินค่าความเหมาะสม (Fitness Function) ของประชากรเป็นฟังก์ชันที่มีความสำคัญ เนื่องจากการประเมินค่าความเหมาะสมจะให้ค่าความเหมาะสมหรือค่าความแข็งแรง (Fitness Value) ของโอกาสในการอยู่รอดของโครโมโซมแต่ละตัวในกลุ่มประชากรที่มาจาก การหาค่าจุดประสงค์ (Objective Value) โครโมโซมทุกตัวจะบ่งบอกถึงความเหมาะสมของตัวเองเพื่อใช้สำหรับพิจารณาว่าโครโมโซมตัวนั้นเหมาะสมหรือไม่ที่จะนำมาใช้ในการสืบทอดพันธุกรรมสำหรับสร้างโครโมโซมรุ่นถัดไป ถ้าหากโครโมโซมใดมีค่าความเหมาะสมต่ำหรือความน่าจะเป็นต่ำก็จะถูกทิ้ง

ไป เปิดโอกาสให้โครโมโซมที่มีค่าความเหมาะสมสูงหรือความน่าจะเป็นสูงได้สืบทอดเป็นรุ่นถัดไป โดยโครโมโซมแต่ละตัวในกลุ่มประชากรจะถูกถอดรหัสให้กลายเป็นตัวแปรตัดสินใจ หลังจากนั้นค่าจุดประสงค์ของแต่ละคำตอบสามารถที่จะคำนวณได้จากตัวแปรตัดสินใจโดยผ่านการใช้ฟังก์ชันจุดประสงค์ การกำหนดฟังก์ชันจุดประสงค์เพื่อใช้ในการหาค่าความเหมาะสมแบ่งเป็นฟังก์ชันแบบจุดประสงค์เดียว (Single Objective Function) เป็นการกำหนดฟังก์ชันขึ้นมาหนึ่งฟังก์ชันที่ต้องการเพียงคำตอบเดียว ซึ่งเหมาะสำหรับปัญหาที่มีความซับซ้อนน้อย และไม่มี ความขัดแย้งกัน และฟังก์ชันแบบหลายจุดประสงค์ (Multi Objective Function) เป็นการกำหนดฟังก์ชันขึ้นมาหลาย ๆ ฟังก์ชันที่ต้องการคำตอบหลาย ๆ คำตอบ แต่ละคำตอบที่เป็นคู่แข่งกัน เหมาะสำหรับปัญหาที่มีความซับซ้อนมากและมีความขัดแย้งกัน

1.3 การดำเนินการทางพันธุกรรม (Genetic Operators) เพื่อให้เกิดการปรับเปลี่ยนสายพันธุ์หรือเกิดการปรับเปลี่ยนคำตอบ (ใกล้เคียง) ที่ดีที่สุดของปัญหามีกระบวนการหลัก 3 กระบวนการ (Deb, 1999; Vakili et al., 2017) คือ

1.3.1 การคัดเลือกโครโมโซม (Selection) เป็นการคัดเลือกโครโมโซมต้นกำเนิดสายพันธุ์หรือโครโมโซมพ่อแม่สำหรับการสืบสายพันธุ์เพื่อให้กำเนิดเป็นประชากรลูกหลานในรุ่นถัดไป โดยปกติแล้วถ้าต้องการจะได้สายพันธุ์ที่ดี ต้นกำเนิดสายพันธุ์ต้องดีด้วย เป็นไปตามหลักการอยู่รอดของสิ่งมีชีวิตที่เหมาะสมที่สุด ซึ่งโครโมโซมที่มีค่าความเหมาะสมที่ดีย่อมหมายถึงการเป็นโครโมโซมที่ดี และควรมีโอกาสที่จะให้กำเนิดลูกหลานในจำนวนที่มากกว่าได้ จะบ่งบอกได้ว่าโอกาสในการอยู่รอดในรุ่นถัดไปก็จะเพิ่มมากขึ้นด้วย ส่วนโครโมโซมที่มีค่าความเหมาะสมต่ำกว่าจะมีโอกาสถูกเลือกน้อยกว่าหรืออาจจะไม่ได้รับการคัดเลือกเลย (Vakili et al., 2017) ดังภาพที่ 2-1 ดังนั้นการคัดเลือกจึงเป็นกระบวนการที่สำคัญมากซึ่งส่งผลต่อกระบวนการต่อไป เพราะถ้าคัดเลือกต้นกำเนิดสายพันธุ์ไม่ดี อาจทำให้ได้ประชากรลูกหลานในรุ่นถัดไปที่ไม่ดีไปด้วย นอกจากนี้ยังพบปัญหาการลู่เข้าการลู่เข้าคำตอบที่ดีเฉพาะที่ (Local Maxima) แต่อาจจะไม่ใช่ว่าคำตอบที่ถูกต้อง และความหลากหลายทางสายพันธุ์ก็ยังคงต้องอยู่ในกระบวนการคัดเลือกอีกด้วย เทคนิคในการคัดเลือกมีอยู่หลายเทคนิคที่จะนำมาช่วยให้กระบวนการคัดเลือกทำงานได้ดีขึ้น เช่น การคัดเลือกแบบวงล้อรูเล็ตต์ (Roulette Wheel Selection) เป็นเทคนิคหนึ่งที่ยากเมื่อเทียบกับเทคนิคอื่นและได้รับความนิยมที่สุด (พยุ่ง มีสัจ, 2555, หน้า 197; Goldberg, 1989) การคัดเลือกสุ่มตัวอย่างแบบเฟ้นสุ่มสากล (Stochastic Universal Sampling Selection) ที่ช่วยลดความลำเอียงในการคัดเลือกได้ เพราะโอกาสที่สมาชิกของกลุ่มประชากรตัวใดจะถูกเลือกซ้ำหลาย ๆ ครั้งจะเกิดขึ้นเมื่อสมาชิกของกลุ่มประชากรตัวนั้น ๆ มีค่าความเหมาะสมสูงมาก ๆ (Arakaki & Usberti, 2018) การคัดเลือกแบบแข่งขัน (Tournament Selection) และการคัดเลือกแบบแบ่งเป็นช่วง (Truncation Selection) เป็นต้น



ภาพที่ 2-1 การคัดเลือกโครโมโซม

สำหรับการวิจัยนี้ทำการพัฒนาการคัดเลือกแบบแข่งขัน จากหลักการ 3 หลักการคือ

1) หลักการ Normalized Geometric Ranking ของ Joines & Houck (1994) ที่มีขั้นตอนดังนี้

1.1) หาค่าความเหมาะสมของโครโมโซมแต่ละตัวในกลุ่มประชากร จากฟังก์ชันจุดประสงค์ที่กำหนดขึ้น

1.2) นำค่าความเหมาะสมมาจัดเรียง (Sort) ลำดับ (Rank) ของโครโมโซมแต่ละตัว โดยเรียงจากค่าความเหมาะสมที่ดีที่สุดให้เป็นลำดับที่ 1 และลำดับที่ n เป็นค่าความเหมาะสมที่แย่ที่สุด เพื่อหาดัชนี (Index) ของลำดับของการจัดเรียง ซึ่งจะนำลำดับมาใช้ในการหาค่าการแจกแจงปกติ (Normal Distribution) ของค่าความเหมาะสม จากนั้นนำค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว แทนตามตำแหน่งดัชนีของลำดับของการจัดเรียง

1.3) หาค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว จากหลักการ Normalized Geometric Ranking (Joines & Houck, 1994) ที่มีสูตรคือ

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

โดยที่ q แทนค่าความน่าจะเป็นในการเลือกโครโมโซมที่ดีที่สุด

r แทนค่าลำดับของโครโมโซมแต่ละตัว

โดยลำดับที่ 1 เป็นค่าความเหมาะสมที่ดีที่สุด

และลำดับที่ n เป็นค่าความเหมาะสมที่แย่ที่สุด

p แทนขนาดของประชากร

1.4) นำค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว แทนตามตำแหน่งดัชนีของลำดับของการจัดเรียงที่ได้ตามขั้นตอนที่ 1.2) อีกครั้ง

2) หลักการคัดเลือกแบบวงล้อรูเล็ตของ Yu et al. (2016) ที่มีขั้นตอนดังนี้

2.1) หาค่าความน่าจะเป็น (Probabilities) ของแต่ละโครโมโซมจากค่าความเหมาะสม (Fitness Value) จะได้จำนวนค่าความน่าจะเป็นเท่ากับจำนวนโครโมโซม โดยคำนวณจาก

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

โดยที่ p_i แทนค่าความน่าจะเป็นเหมาะสมของโครโมโซมตัวที่ i

f_i แทนค่าความเหมาะสมของโครโมโซมตัวที่ i

2.2) หาผลรวมค่าสะสม (Cumulative Sum) ของค่าความน่าจะเป็น เรียกค่านี้ว่า

Prob

2.3) สร้างชุดตัวเลขสุ่มแบบเอกรูป (Uniform Random Variable Generation)

ขึ้นมา กำหนดขนาดชุดตัวเลขสุ่มให้เท่ากับจำนวนของโครโมโซม โดยมีช่วงการสุ่มอยู่ที่ 0-1 เรียกค่านี้ว่า *Rng*

2.4) ทำการวนซ้ำ (Loop) เพื่อจับคู่การเปรียบเทียบ *Prob* กับ *Rng* โดยที่

2.4.1) นำค่าตัวเลขสุ่ม *Rng* มาเทียบกับ *Prob* ทีละคู่ ถ้าตำแหน่งที่ 1 ของ *Rng* น้อยกว่าตำแหน่งที่ 1 ของ *Prob* ให้เลือกโครโมโซมตามตำแหน่ง *Rng* (คือตำแหน่งที่ 1) เก็บไว้ แสดงว่าโครโมโซมนี้ดี จะนำโครโมโซมไปใช้งานต่อไป พร้อมเลื่อนตำแหน่งของค่า *Rng* ไปอีก 1 ค่า ดังนั้นตำแหน่งของ *Rng* ก็จะกลายเป็นตำแหน่งที่ 2

2.4.2) ถ้าตำแหน่งที่ 1 ของ *Rng* มากกว่าตำแหน่งที่ 1 ของ *Prob* เลือกโครโมโซมตามตำแหน่ง *Rng* (คือตำแหน่งที่ 1) แต่ให้ไปเลื่อนตำแหน่งของ *Prob* ไปอีก 1 ตำแหน่งด้วย ตอนนี้ตำแหน่งของ *Prob* ก็จะกลายเป็นตำแหน่งที่ 2

2.4.3) เมื่อทำการวนซ้ำมารอบใหม่ทุกครั้ง ค่า *Rng* หรือค่า *Prob* จะมีการเลื่อนลำดับไปเรื่อย ๆ ตามเงื่อนไขของ > หรือ <

2.4.4) ทำกระบวนการ 2.4.1–2.4.3 ซ้ำไปเรื่อย ๆ จนกว่าจะครบตามจำนวนโครโมโซม

2.4.5) ผลที่ได้คือ โครโมโซมที่มีประเภท (Type) ลดลง แต่จำนวนโครโมโซมเท่าเดิม

2.5) นำโครโมโซมที่ได้ผ่านการคัดเลือกไปใช้ในกระบวนการการสลับสายพันธุ (Crossover) และการกลายพันธุ์ (Mutation) ในขั้นตอนต่อไปของวิธี GA

3) หลักการคัดเลือกแบบแข่งขันของ Goldberg & Deb (1991) ที่มีขั้นตอนดังนี้

3.1) หาค่าความเหมาะสมของทุก ๆ โครโมโซมออกมา จากฟังก์ชันจุดประสงค์ที่กำหนดขึ้น เช่น มีโครโมโซม 5 ตัวจะได้ค่าความเหมาะสม 5 ค่าคือ

ดัชนี 1 ค่าเหมาะสม = 569

ดัชนี 2 ค่าเหมาะสม = 554

ดัชนี 3 ค่าเหมาะสม = 617

ดัชนี 4 ค่าเหมาะสม = 681

ดัชนี 5 ค่าเหมาะสม = 496

3.2) กำหนดจำนวน Tournament (จำนวนหลักหรือคอลัมน์ (Column)) ในแต่ละแถว เช่น 4 Tournament ก็จะมี 4 หลักในแต่ละแถวของเมตริกซ์ Tournament ส่วนจำนวนแถวของเมตริกซ์ Tournament จะเท่ากับจำนวนโครโมโซมที่เป็นขนาดของประชากร (Population Size)

3.3) สร้างเมตริกซ์ Tournament ของค่าที่สุ่มดัชนี (Index) โดยค่าสุ่มนี้จะตั้งอยู่ในช่วงของจำนวนของขนาดประชากร เช่น ถ้าขนาดประชากรมี 5 ค่า ค่าสุ่มก็จะอยู่ในช่วง 1-5 เช่น

3	2	5	3
2	4	4	3
4	4	2	4
3	4	3	4
2	4	1	5

3.4) แทนค่าดัชนีที่สุ่มได้ด้วยค่าความเหมาะสมตามที่จับคู่ไว้ ในแต่ละตำแหน่งของเมตริกซ์ Tournament จากตัวอย่างจะได้ว่า

617	554	496	617
554	681	681	617
681	681	554	681
617	681	617	681
554	681	569	496

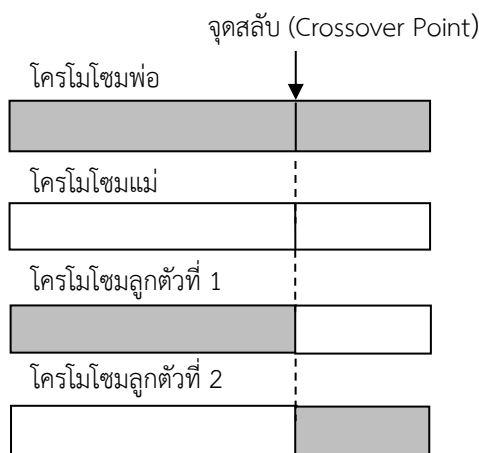
3.5) หาค่ามากที่สุด (Max) ของแต่ละแถวของขั้นตอนที่ 3.4) ซึ่งจะเป็นผู้ชนะ (Winner) ของ Tournament ทำให้ได้ดัชนีของการคัดเลือกโครโมโซมที่ต้องการ เช่น จากขั้นตอนที่ 3.4) ตำแหน่งที่เป็นผู้ชนะในแต่ละแถวคือ 1, 2, 1, 2, 2 จากนั้นนำตำแหน่งนี้กลับไปเลือกค่าดัชนีของเมตริกซ์ Tournament ในขั้นตอนที่ 3.3) อีกครั้ง ผลที่ได้คือ

<u>3</u>	2	5	3
2	<u>4</u>	4	3
<u>4</u>	4	2	4
3	<u>4</u>	3	4
2	<u>4</u>	1	5

ดังนั้นดัชนีของการคัดเลือกโครโมโซมที่ต้องการเป็น 3, 4, 4, 4, 4 ซึ่งผลลัพธ์คือโครโมโซมใหม่ตามตำแหน่งดัชนี 3, 4, 4, 4, 4

หลังจากการคัดเลือกโครโมโซมแล้ว โครโมโซมที่ถูกคัดเลือกจะกลายเป็นต้นกำเนิดสายพันธุ์ ซึ่งมีหน้าที่ในการให้กำเนิดลูกหลานด้วยกรรมวิธีเฉพาะของ GA ต่อไป และการวิจัยนี้ โครโมโซมคือ ค่าน้ำหนักของแต่ละเส้นเชื่อมต่อระหว่างโหนดของโครงข่ายประสาทเทียม


1.3.2 การสลับสายพันธุ์ (Crossover) เป็นการสร้างโครโมโซมขึ้นมาใหม่ เพื่อให้แตกต่างและหลากหลายจากโครโมโซมรุ่นเดิม ซึ่งอัลกอริทึมพยายามสร้างทางเลือกที่ดีขึ้นโดยรวมลักษณะที่ดีของแต่ละโครโมโซมเข้าด้วยกันทำให้มีโอกาสที่จะได้โครโมโซมที่ดีกว่าเดิม โครโมโซมที่มีค่าความเหมาะสมสูงกว่ามักจะถูกเลือกมาสลับสายพันธุ์บ่อยครั้งกว่าส่งผลให้มีโอกาสในการรอดไปยังรุ่นถัดไปมากขึ้น (Yang, 2008, p. 23) ขั้นตอนการสลับสายพันธุ์เริ่มจากการสุ่มเลือกโครโมโซมที่เป็นสมาชิกของกลุ่มประชากรที่ผ่านการคัดเลือกมาแล้วเป็นคู่ ๆ เราจะกำหนดให้เป็นโครโมโซมรุ่นพ่อกับแม่ (Parent Individuals) จากนั้นทำการแลกเปลี่ยนยีนระหว่างโครโมโซมพ่อกับแม่ (Metawa, Hassan, & Elhoseny, 2017) ทำให้เกิดเป็นโครโมโซมรุ่นลูก (Offspring Individuals) ขึ้นมาสองตัว โดยโครโมโซมรุ่นลูกจะถูกนำไปเป็นโครโมโซมที่เป็นสมาชิกของประชากรรุ่นถัดไป ซึ่งโครโมโซมรุ่นลูกนี้เกิดจากการคัดลอกโครโมโซมที่อยู่หน้าตำแหน่งที่สุ่มได้จากโครโมโซมพ่อ และคัดลอกโครโมโซมที่อยู่หลังตำแหน่งที่สุ่มได้จากโครโมโซมแม่ ต่อจากนั้นนำโครโมโซมที่ได้ทั้งสองมารวมกันเป็นโครโมโซมลูกตัวที่ 1 ส่วนลูกตัวที่ 2 ก็ให้ทำในลักษณะเดียวกันแต่สลับตำแหน่งระหว่างพ่อกับแม่ (Reeves, 1996; Vakili et al., 2017) ดังภาพที่ 2-2 โอกาสในการที่จะสุ่มเลือกโครโมโซมรุ่นพ่อกับแม่มาทำการสลับสายพันธุ์จะกำหนดจากความน่าจะเป็นในการสลับสายพันธุ์ (Probabilities of Crossover: P_c) (Engelbercht, 2005, p. 137) ซึ่งปกติมีช่วงความน่าจะเป็นอยู่ที่ 0.7–1.0 (Yang, 2008, p. 25) สำหรับวิธีการสลับสายพันธุ์นั้นมีรูปแบบคือ การสลับสายพันธุ์แบบหนึ่งตำแหน่ง (One-point Crossover) การสลับสายพันธุ์แบบสองตำแหน่ง (Two-point Crossover) และการสลับสายพันธุ์แบบหลายตำแหน่ง (Uniform Crossover) ดังนั้นควรพิจารณาเลือกวิธีที่ใช้ให้เหมาะสมกับปัญหาที่นำมาใช้



ภาพที่ 2-2 การสลับสายพันธุ์

การสลับสายพันธุ์เป็นผลมาจากการดำเนินการทางพันธุกรรมที่ใช้โครโมโซมต้นกำเนิดสายพันธุ์มากกว่า 1 ตัว ต่อไปจะเป็นการกลายพันธุ์ซึ่งเกิดขึ้นกับโครโมโซมเพียงตัวเดียวเท่านั้น

1.3.3 การกลายพันธุ์ (Mutation) เป็นกระบวนการที่เกิดขึ้นหลังกระบวนการสลับสายพันธุ์ จุดประสงค์คือทำให้ค่าของโครโมโซมที่มีอยู่เดิมเกิดการเปลี่ยนแปลงและช่วยหลีกเลี่ยงปัญหาการเวียนซ้ำอยู่กับค่าใดค่าหนึ่ง (Iteration Search) ทำให้ GA สามารถหลุดพ้นออกจากคำตอบที่เหมาะสมที่สุดแบบวงแคบเฉพาะถิ่นได้ (Local Optimum) โดยป้องกันไม่ให้โครโมโซมเกิดการเปลี่ยนแปลงในทิศทางที่มีความคล้ายคลึงกันไปหมด การกลายพันธุ์เป็นการเปลี่ยนค่าของยีนในแต่ละโครโมโซมที่ถูกสุ่มเลือกมาเพื่อให้เกิดโครโมโซมใหม่อีกหนึ่งโครโมโซม ซึ่งทำให้โครโมโซมของกลุ่มประชากรมีความหลากหลายมากขึ้น (Metawa et al., 2017; Yang, 2008, p. 23) มีผลทำให้คำตอบที่เกิดขึ้นในกระบวนการของ GA ครอบคลุมพื้นที่การค้นหาคำตอบทั่วถึงยิ่งขึ้น อัตราการกลายพันธุ์ขึ้นอยู่กับขนาดของประชากรเพื่อให้การสำรวจพื้นที่ในการค้นหาคำตอบเป็นไปอย่างทั่วถึง (Engelbercht, 2005, p. 138; Vakili et al., 2017) ดังนั้นการกำหนดอัตราการทำการกลายพันธุ์ต้องมีความเหมาะสมที่สุดต่อระบบด้วย โดยทั่วไปแล้วการกลายพันธุ์จะไม่เกิดขึ้นกับโครโมโซมทั้งหมดแต่จะขึ้นอยู่กับความน่าจะเป็นในการกลายพันธุ์ (Probabilities of Mutation: P_m) ควรกำหนดให้มีค่าประมาณ 0.1–0.3 จะกำหนดไว้ในช่วงของการเริ่มกระบวนการ ดังภาพที่ 2-3 เทคนิคในการกลายพันธุ์มีหลายวิธี ส่วนมากขึ้นอยู่กับวิธีการเข้ารหัสโครโมโซม เช่น การกลายพันธุ์แบบกลับบิต (Bit-Flipped Mutation) การกลายพันธุ์แบบผกผัน (Inversion Mutation) การกลายพันธุ์แบบแทรก (Insertion Mutation)



ภาพที่ 2-3 การกลายพันธุ์

สำหรับปัจจุบันนั้นยีนอาจเป็นค่าจำนวนจริง (Real Value Coding) ทำให้มีเทคนิคการกลายพันธุ์อื่นเกิดขึ้นอีกมากมาย เช่น ค่าของยีนจะถูกดัดแปลงภายในค่าพิสัย (Range) ที่กำหนด เรียกว่าการกลายพันธุ์แบบยูนิฟอร์ม (Uniform Mutation) ส่วนการกลายพันธุ์แบบโมดิฟายยูนิฟอร์ม (Modified Uniform Mutation) ยีนจะถูกดัดแปลงโดยค่าคงที่เพียงค่าเดียว และการกลายพันธุ์แบบนอนยูนิฟอร์ม (Non-uniform Mutation) เป็นวิธีการที่จะดัดแปลงยีนโดยค่าที่ค่อย ๆ ลดลงเมื่อคำตอบในหนึ่งรุ่น (Generation) ค่อย ๆ เพิ่มขึ้น เป็นต้น

การสลับสายพันธุ์และการกลายพันธุ์เป็นการสร้างและการเปลี่ยนแปลงของต้นกำเนิดสายพันธุ์ ซึ่งให้ผลเป็นโครโมโซมลูกหลาน การสลับสายพันธุ์มีผลให้โครโมโซมลูกหลานได้รับสายพันธุ์จากต้นกำเนิด โดยโครโมโซมลูกหลานจะได้รับส่วนที่ดีจากส่วนย่อยของต้นกำเนิดสายพันธุ์ ในขณะที่การกลายพันธุ์เป็นการสร้างความแปรผันขึ้นในโครโมโซมลูกหลาน เพื่อให้เกิดประชากรใหม่ที่ดีกว่า การดำเนินการทางพันธุกรรมทั้งสองถูกนำมาใช้ใน GA โดยหวังว่าการเปลี่ยนแปลงที่เกิดขึ้นจะมีผลทำให้โครโมโซมลูกหลานมีสายพันธุ์ที่ดีขึ้น เพื่อนำไปสู่คำตอบที่ดีที่สุดต่อไป (Kumari & Dubey, 2016; Saidi-Mehrabad & Bairamzadeh, 2018).

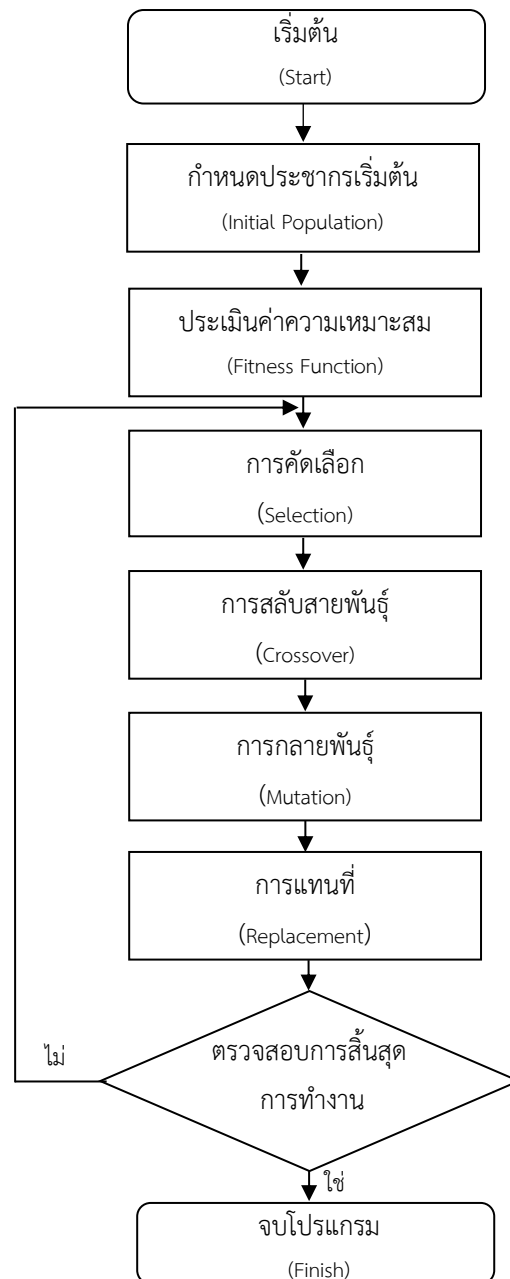
1.4 การแทนที่ (Replacement) เป็นขั้นตอนหลังจากที่ GA ได้โครโมโซมลูกหลานเรียบร้อยแล้ว แล้วนำโครโมโซมลูกหลานใหม่นี้ไปแทนที่ประชากรรุ่นเก่า จุดประสงค์ในการแทนที่ค่อนข้างชัดเจนคือ การนำโครโมโซมลูกหลานแทนที่ประชากรรุ่นก่อนทำให้ประชากรรุ่นใหม่เป็นโครโมโซมที่ดีกว่าเพราะได้สายพันธุ์ที่ดีจากต้นกำเนิดสายพันธุ์ที่ผ่านการคัดเลือกแล้ว (Arakaki & Usberti, 2018) วิธีในการคัดเลือกกว่าโครโมโซมไหนจะถูกแทนที่มีอยู่ 2 วิธีคือ

1.4.1 การแทนที่ประชากรทั้งรุ่น (Generational Genetic Algorithm) โดยนำประชากรลูกหลานไปแทนที่ประชากรรุ่นเก่าทั้งหมด ดังนั้นถ้าในระบบหนึ่งมีจำนวนประชากรเท่ากับ N จำนวนโครโมโซมลูกหลานที่จะมาแทนที่จะต้องมีความ N เช่นกัน วิธีนี้เป็นวิธีที่ง่ายเนื่องจากไม่จำเป็นต้องมีขั้นตอนของการคัดเลือกกว่าประชากรส่วนไหนจะถูกแทนที่ แต่การที่ไม่มีขั้นตอนของการคัดเลือกทำให้เกิดเป็นข้อเสียคือ โครโมโซมที่ดีในรุ่นเก่าจะถูกแทนที่ไปด้วย ซึ่งวิธีที่ง่ายก่อนที่จะทำการแทนที่ให้คัดเลือกเก็บโครโมโซมที่ดีที่สุด 2-3 ตัวแรกเอาไว้ด้วยวิธีการคัดเลือกในหัวข้อที่เคยอธิบายมาแล้วก่อนหน้านี้ โดยอาจจะใช้กลวิธีการคัดเลือกแบบหัวกะทิ (Elitist Strategy) อย่างไรก็ตามประชากรที่เหลืออยู่อาจจะถูกครอบงำด้วยโครโมโซมหัวกะทินี้ได้โดยง่าย คือถ้าไม่มี

โครโมโซมใหม่ที่ดีกว่าเกิดขึ้น โครโมโซมที่ดีที่สุดจากรุ่นเก่าก็จะถูกเก็บไว้อยู่ตลอดไป และไม่ก่อให้เกิดการเปลี่ยนแปลงใด ๆ ขึ้น มีผลทำให้ GA ไม่สามารถวิวัฒนาการโครโมโซมใหม่ขึ้นมาได้ ถึงแม้ว่าผลของโครโมโซมหวั่งกะทิจจะมีโอกาสเกิดขึ้นแต่วิธีนี้ก็ได้รับการพิสูจน์แล้วว่าทำให้ระบบโดยรวมดีขึ้น

1.4.2 การแทนที่ประชากรบางส่วน (Partial Genetic Algorithm) โดยนำประชากรลูกหลานไปแทนที่ประชากรรุ่นเก่าเพียงบางส่วนเท่านั้น ซึ่งปกติการคัดเลือกประชากรที่จะถูกแทนที่พิจารณาจากค่าความเหมาะสมของโครโมโซม โครโมโซมเก่าจะถูกแทนที่ด้วยโครโมโซมใหม่เพียง 1 หรือ 2 ตัวเท่านั้น สำหรับวิธีการแทนที่มีหลายวิธี เช่น การแทนที่ประชากรที่ด้อยที่สุดหรือการแทนที่ประชากรโดยการสุ่มเลือก เป็นต้น

1.5 การกำหนดการสิ้นสุดของการทำงาน (Termination Condition) เมื่อถึงขั้นการแทนที่ของประชากร จากนั้นจะเป็นการขั้นตอนการตรวจสอบว่าจบกระบวนการหรือยัง การทำงานของ GA เป็นวัฏจักรหมุนเวียนอยู่เช่นนี้จนกระทั่งถึงจุดหนึ่งตามเงื่อนไข เงื่อนไขในการสิ้นสุดการทำงานของวิธี GA นั้นจะสิ้นสุดการทำงานก็ต่อเมื่อได้ดำเนินการจนครบตามจำนวนรุ่นของประชากร (Number of Generation) ตามที่ผู้ใช้กำหนดหรือผู้ใช้อาจจะกำหนดให้สิ้นสุดการทำงานเมื่อค่าคำตอบในหลาย ๆ รอบที่ผ่านมาไม่มีการเปลี่ยนแปลง ซึ่งจะได้โครโมโซมที่เหมาะสมที่สุดหรือใกล้เคียงค่าที่ดีที่สุด วิธี GA มีกระบวนการทำงานดังภาพที่ 2-4



ภาพที่ 2-4 กระบวนการทำงานของวิธี GA

การกำหนดค่าพารามิเตอร์ในขั้นตอนต่าง ๆ นั้น เพื่อให้การทำงานของ GA มีความเหมาะสมที่สุดในการทำงานและแก้ปัญหาต่าง ๆ ได้อย่างเหมาะสม โดยการค้นหาคำตอบด้วยวิธี GA คือ การค้นหาคำตอบจากชุดข้อมูลจำนวนมาก (กลุ่มประชากรของโครโมโซม) แทนการพิจารณาข้อมูลที่ละคำตอบในวิธีการค้นหาแบบอื่น ๆ (Raeisi-Vanani et al., 2017) โดยหลักการของขั้นตอน

วิธี GA คือการคัดเลือกคำตอบที่ดีกว่าจากชุดคำตอบหรือกลุ่มประชากร และการผสมผสานรายละเอียดข้อมูลย่อยในชุดคำตอบ (การผสมผสานยีนในโครโมโซม) เพื่อค้นหาคำตอบที่ดียิ่งขึ้น ร่วมกับการสุ่มเปลี่ยนข้อมูลย่อยหรือการกลายพันธุ์เพื่อป้องกันการยึดติดกับคำตอบที่ดีเฉพาะที่ (Local Minima/ Local Maxima) ด้วยเหตุนี้ขั้นตอนวิธี GA จึงเป็นกระบวนการค้นหาคำตอบที่เหมาะสมซึ่งกำลังเป็นที่สนใจในงานวิจัยด้านต่าง ๆ ในปัจจุบัน เช่น งานวิศวกรรมศาสตร์ วิทยาศาสตร์ การจัดการ และอื่น ๆ (Kumari & Dubey, 2016) บ่อยครั้งที่การทำงานมักจะเกี่ยวข้องกับการหาจุดที่เหมาะสมที่สุดหรือจุดที่ดีที่สุด ขั้นตอนวิธี GA นำไปประยุกต์ใช้ค้นหาโครงสร้างและตัวแปรที่เหมาะสม ซึ่งทำให้ระบบมีประสิทธิภาพการทำงานสูงสุด (พวง มีสัจ, 2555, หน้า 7) ในด้านการพยากรณ์นั้น วิธี GA ไม่ถูกนำมาใช้ในการพยากรณ์โดยตรง แต่มักนำไปผสมหรือร่วมกับวิธีการพยากรณ์อื่น ๆ เพื่อเลือกโครงสร้างหรือหาค่าพารามิเตอร์ของวิธีการพยากรณ์นั้น ๆ ทำให้ประสิทธิภาพในการพยากรณ์ดีขึ้น (นนทชัย กานตานันทะ, 2555)

1.6 งานวิจัยที่เกี่ยวข้องกับการใช้วิธี GA

ธวัช รวมทรัพย์ และสุรศักดิ์ มั่งสิงห์ (2559) ศึกษาการจำแนกชนิดของใบพืชด้วยเทคนิคที่หลากหลาย ซึ่งแต่ละเทคนิคก็มีข้อดีและข้อเสียที่แตกต่างกันไปขึ้นอยู่กับปัญหาและวัตถุประสงค์การนำไปใช้ในการหาผลลัพธ์ จากคุณลักษณะของใบพืชประกอบไปด้วย รูปใบ เส้นใบ ปลายใบ โคนใบ ขอบใบ และขนาดของใบ สามารถนำมาใช้ในการจำแนกชนิดของพืชได้ ดังนั้นงานวิจัยนี้จึงสนใจการจำแนกชนิดของพืชโดยใช้วิธีเลือกตัวแทนที่เหมาะสมด้วยวิธี GA และใช้เทคนิคเพื่อนบ้านใกล้สุด (k-Nearest Neighbor: k-NN) ข้อมูลที่ใช้ในการทดลองได้แก่ ใบพืช 30 สายพันธุ์ จำนวน 340 ใบ จากผลการทดลองโดยใช้เทคนิค k-NN เพียงอย่างเดียวให้ผลลัพธ์ความถูกต้องเท่ากับ 79.12% ค่าความครบถ้วน (Recall) เท่ากับ 79.50% และค่าความแม่นยำ (Precision) เท่ากับ 73.17% แต่เมื่อใช้การเลือกตัวแทนที่เหมาะสมด้วยวิธี GA ร่วมกับเทคนิค k-NN ให้ผลลัพธ์ความถูกต้องเท่ากับ 86.27% ค่าความครบถ้วนเท่ากับ 83.06% และค่าความแม่นยำเท่ากับ 84.06% จากผลการทดลองพบว่า เมื่อใช้วิธี GA มาช่วยในการเลือกตัวแทนที่เหมาะสมทำให้ประสิทธิภาพการจำแนกชนิดพืชด้วยเทคนิค k-NN มีความถูกต้องมากขึ้น และมากกว่าการใช้เทคนิค k-NN เพียงเทคนิคเดียว

เจษฎา ตงศิริ และอนงค์ฤทธิ แข็งแรง (2561) ศึกษาการประมาณค่าปริมาณน้ำไหลเข้าอ่างเก็บน้ำน้ำอูนด้วยตัวแบบอุทกวิทยา SWAT โดยพิจารณาสภาพภูมิอากาศตอนภาคจากตัวแบบสภาพภูมิอากาศระดับภูมิภาค PRECIS ในสถานการณ์การปล่อยก๊าซเรือนกระจกแบบ A2 และ B2 ที่มีการเพิ่มขึ้นของอุณหภูมิ A2 มากกว่า B2 และข้อมูลการใช้ที่ดินเหนืออ่างเก็บน้ำจากแผนที่ Agri-Map พบว่าพื้นที่ปลูกข้าวลดลง แต่พื้นที่ปลูกมันสำปะหลัง อ้อย ข้าวโพดเพิ่มขึ้น นอกจากนี้ยังทำการปรับปรุงโครงสร้างควบคุมอ่างเก็บน้ำโดยใช้เทคนิค GA ร่วมกับตัวแบบอ่างเก็บน้ำ ข้อมูลที่นำมาใช้คือ

ปริมาณน้ำท่าเฉลี่ยรายเดือนที่ไหลเข้าอ่างเก็บน้ำตั้งแต่ปี ค.ศ. 1992 – 2016 สังเคราะห์ข้อมูลน้ำท่า 1,000 เหตุการณ์จากข้อมูลอดีต เพื่อประเมินประสิทธิภาพของโค้งควบคุม แสดงผลเป็นปริมาณน้ำที่ขาดแคลนและไหลล้นในรูปของความถี่ ขนาด และช่วงเวลา ผลการศึกษาพบว่าน้ำท่าอนาคตทั้งสองกรณีสูงกว่าน้ำท่าในอดีต น้ำท่าอนาคต A2 มีปริมาณสูงกว่าน้ำท่าอนาคต B2 ส่วนโค้งควบคุมใหม่ที่สร้างขึ้นด้วยเทคนิค GA สามารถลดสถานการณ์น้ำไหลล้นได้ดีกว่าโค้งควบคุมเดิมจากความถี่การไหลล้น 0.997 เป็น 0.992 ครั้งต่อปี และลดปริมาณน้ำไหลล้นเฉลี่ยจาก 251.685 เป็น 246.222 ล้านลูกบาศก์เมตร ด้วยเหตุนี้จึงสามารถสรุปได้ว่าโค้งควบคุมเดิม ด้วยเหตุผลนี้จึงสามารถสรุปได้ว่าโค้งควบคุมที่พัฒนาจากเทคนิค GA เชื่อมต่อกับตัวแบบสถานการณ์อ่างเก็บน้ำมีความเหมาะสม สามารถที่จะลดโอกาสในการเกิดเหตุการณ์น้ำขาดแคลนและน้ำไหลล้นในอนาคตได้ดีกว่าโค้งควบคุมเดิมที่ใช้งานอยู่ในเวลาปัจจุบันทั้งในสถานการณ์ A2 และ B2

สุวิมล คำแสน และอริวัฒน์ บุญมี (2561) ศึกษาการวางแผนเส้นทางการเยี่ยมชมจุดท่องเที่ยวในเมืองจำลอง จังหวัดชลบุรี เพื่อให้ได้คะแนนรวมในการเดินทางที่สะดวกภายใต้เงื่อนไขด้านกรอบเวลาที่จำกัดในการพัฒนาแนวทางการตัดสินใจ โดยนำวิธี GA เข้ามาพัฒนาเครื่องมือเพื่อช่วยในการวางแผนเพื่อให้ได้เส้นทางที่เหมาะสมที่สุด ในการแก้ปัญหาที่มีการพิจารณาเชื่อมโยงในส่วนของจำนวนนักท่องเที่ยวที่แตกต่างกัน จำนวนจุดเที่ยวชมสูงสุด รวมไปถึงเงื่อนไขด้านกรอบเวลาในการเยี่ยมชมที่จำกัด นอกจากนี้ได้นำหลักการการเข้ารหัสแบบฮิวริสติกมาใช้เพื่อป้องกันการยึดติดกับคำตอบที่ดีเฉพาะที่ และเพื่อปรับปรุงความสามารถในการค้นหาคำตอบที่เหมาะสมในปริภูมิคำตอบ จากผลการทดลองพบว่าวิธี GA มีผลเฉลยที่ดีกว่าขั้นตอนวิธีเพื่อนบ้านใกล้สุด (Nearest Neighbors: NN) ที่ค่าเฉลี่ยร้อยละ 2.12 และดีกว่าวิธีการค้นหาตามค่าที่ดีที่สุด (Best First Search: BFS) ที่ค่าเฉลี่ยร้อยละ 34.78

Saxena et al. (2014) ศึกษาการพยากรณ์ปริมาณน้ำฝนโดยใช้วิธีโครงข่ายประสาทเทียมร่วมกับวิธี GA ซึ่งวิธี GA นำมาใช้สำหรับกำหนดโครงสร้างที่เหมาะสมของโครงข่ายประสาทเทียมแบบ BPNN และปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับ (Backpropagation) พร้อมทั้งเปรียบเทียบความแม่นยำของการพยากรณ์โดยใช้วิธีโครงข่ายประสาทเทียมร่วมกับวิธี GA กับวิธีโครงข่ายประสาทเทียมแบบ FFNN ผลการศึกษาพบว่า การพยากรณ์โดยใช้วิธีโครงข่ายประสาทเทียมร่วมกับวิธี GA มีความแม่นยำมากกว่า และสามารถแก้ปัญหาค่าความล่าช้าในการลู่เข้าหาคำตอบได้

Ding, Cai, Sun, and Chen (2014) ศึกษาการสร้างระบบการพยากรณ์คุณภาพน้ำ เพื่อเป็นการควบคุมปริมาณน้ำเสีย และรักษามลพิษทางน้ำ โดยนำวิธีการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis: PCA) วิธี GA และวิธีโครงข่ายประสาทเทียมแบบ BPNN มาใช้เพื่อพยากรณ์คุณภาพน้ำในแม่น้ำ ขั้นตอนแรกวิธี PCA จะคัดเลือกตัวแปร เพื่อเป็นการลดมิติของตัว

แปรนำเข้า จากปัจจัยดัชนีคุณภาพน้ำ 23 ปัจจัย ถูกนำมารวมกันเหลือ 15 ปัจจัย วิธี PCA ได้พัฒนาความเร็วในขั้นตอนการเรียนรู้ได้อย่างมีประสิทธิภาพ ต่อมาวิธี GA ถูกนำมาใช้หาค่าที่เหมาะสมของพารามิเตอร์ของโครงข่ายประสาทเทียมแบบ BPNN ขั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ LM ความแม่นยำในการพยากรณ์น้ำคุณภาพดีเฉลี่ย 88.9% น้ำเสียเฉลี่ย 93.1% และค่าความแม่นยำโดยรวมเฉลี่ย 91% ระบบการพยากรณ์คุณภาพน้ำใช้วิธีการรวมกันของโครงข่ายประสาทเทียมกับวิธี GA สามารถพยากรณ์คุณภาพน้ำได้อย่างแม่นยำ และให้ผลที่เป็นประโยชน์สำหรับการเตือนภัยในทันทีทันใด

Huang and Hou (2017) ศึกษาการใช้โครงข่ายประเทียมร่วมกับวิธี GA เพื่อสร้างตัวแบบพยากรณ์รายได้จากการขายตัวเครื่องบิน โดยนำวิธี GA มาใช้เพื่อกำหนดค่าความเหมาะสมของจำนวนข้อมูลนำเข้าและจำนวนโหนดของชั้นซ่อนของโครงข่ายประสาทเทียมแบบ FFNN ผลการศึกษาแสดงให้เห็นว่าค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Relative Error: MARE) ของตัวแบบพยากรณ์มูลค่ารายได้จากการขายตัว และมูลค่าจริงที่มีการผสมระหว่างโครงข่ายประสาทเทียมกับวิธี GA เท่ากับ 10.51% และค่า R เท่ากับ 0.913 แสดงให้เห็นว่าตัวแบบที่นำมาใช้มีความสามารถในการพยากรณ์ที่ดี มีค่าความเที่ยง (Reliability) และประสิทธิภาพที่สูง

Arya and Pai (2018) สร้างตัวแบบพยากรณ์ปริมาณน้ำฝน โดยวิเคราะห์ข้อมูลปริมาณน้ำฝน 4 เดือน (มิถุนายน กรกฎาคม สิงหาคมและกันยายน) ตั้งแต่พ.ศ. 2525 ถึง พ.ศ. 2555 ในเมืองกัว (Goa) ประเทศอินเดีย เนื่องจากในสมัยปัจจุบันการคาดการณ์การปริมาณน้ำฝนเป็นเรื่องยากที่จะคาดการณ์เพราะข้อมูลมีลักษณะไม่เป็นเชิงเส้นและกระบวนการเกิดฝนมีความซับซ้อน ดังนั้นการสร้างตัวแบบพยากรณ์จึงจำเป็นต้องใช้เทคนิคการคำนวณขั้นสูง การศึกษาครั้งนี้จึงใช้วิธีโครงข่ายประสาทเทียม โดยขั้นตอนวิธีการเรียนรู้แบบ Feed Forward -Back Propagation (FFBP) และเพื่อให้ได้ผลลัพธ์ที่ดีที่สุดจึงได้นำวิธี GA มาใช้ร่วมกับโครงข่ายประสาทเทียม ผลลัพธ์ที่ได้คือการใช้วิธี GA ร่วมกับโครงข่ายประสาทเทียมมีประสิทธิภาพมากกว่าการใช้โครงข่ายประสาทเทียมเพียงวิธีเดียว

จากการศึกษางานวิจัยที่เกี่ยวข้องกับการใช้วิธี GA พบว่าวิธี GA ถูกนำมาใช้อย่างแพร่หลาย สามารถนำมาใช้เพียงวิธีเดียวหรือใช้ร่วมวิธีอื่น ๆ เพื่อเพิ่มประสิทธิภาพของการแก้ปัญหาในเรื่องต่าง ๆ เช่น นำมาใช้ในการเลือกตัวแทนที่เหมาะสมในการจำแนก ปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดในส่วนกระบวนการแพร่ย้อนกลับ กำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของแต่ละเส้นเชื่อม กำหนดจำนวนข้อมูลนำเข้าและจำนวนโหนดของชั้นซ่อนของโครงข่ายประสาทเทียม เป็นต้น โดยแต่ละขั้นตอนของวิธี GA จะพัฒนาค่าของคำตอบจนกระทั่งได้คำตอบที่ดีที่สุด ดังนั้นวิธี GA จึงเป็นทางเลือกหนึ่งในการนำไปใช้กับปัญหาการหาค่าที่เหมาะสมที่สุด

ตอนที่ 2 การวิเคราะห์ถดถอยพหุคูณ (Multiple Regression Analysis: MRA) และงานวิจัยที่เกี่ยวข้อง

การวิเคราะห์ถดถอยพหุคูณ (Multiple Regression Analysis: MRA) เป็นเทคนิคการวิเคราะห์ข้อมูลที่ใช้ศึกษาความสัมพันธ์ระหว่างตัวแปรเกณฑ์ 1 ตัวแปรกับตัวแปรพยากรณ์ตั้งแต่ 1 ตัวแปรขึ้นไป โดยมีวัตถุประสงค์ของ MRA มี 2 ประการคือ 1. เพื่อตรวจสอบตัวแปรพยากรณ์ตามทฤษฎีที่ทบทวนมาว่าตัวแปรใดที่สามารถนำมาใช้ในการพยากรณ์ตัวแปรเกณฑ์ได้อย่างมีนัยสำคัญทางสถิติ หรือ 2. เพื่อสร้างสมการพยากรณ์ที่ดีที่สุดในการพยากรณ์ตัวแปรเกณฑ์ (พูลพงษ์ สุขสว่าง, 2561, หน้า 95) กำหนดความสัมพันธ์ของตัวแปรพยากรณ์กับตัวแปรเกณฑ์เป็นสมการพยากรณ์เชิงเส้นตรงในรูปคะแนนดิบดังนี้ (บุญชม ศรีสะอาด, 2556, หน้า 110-112)

$$Y' = a + b_1x_1 + b_2x_2 + \dots + b_kx_k$$

โดยที่ Y'	แทนคะแนนพยากรณ์ของตัวแปรเกณฑ์
a	แทนค่าคงที่ของสมการพยากรณ์ในรูปคะแนนดิบ
b_1, b_2, \dots, b_k	แทนค่าน้ำหนักหรือสัมประสิทธิ์ถดถอย (Regression Coefficient) ของตัวแปรพยากรณ์ตัวที่ 1 ถึงตัวที่ k
x_1, x_2, \dots, x_k	แทนคะแนนของตัวแปรพยากรณ์ตัวที่ 1 ถึงตัวที่ k
k	แทนจำนวนตัวแปรพยากรณ์

สัมประสิทธิ์การถดถอย (b) เป็นค่าที่แสดงว่า เมื่อตัวแปรพยากรณ์ (x_i) ตัวนั้นเปลี่ยนแปลงไป 1 หน่วยจะทำให้ตัวแปรเกณฑ์ (Y') (คะแนนพยากรณ์ของตัวแปรเกณฑ์) เปลี่ยนแปลงไป b หน่วย

วิธี MRA ต้องคำนวณหาค่า a และ $b_1, b_2, b_3, \dots, b_k$ เพื่อนำมาแทนค่าลงในสมการโดยมีหลักการว่า ค่า b ทุกตัวต้องเป็นค่าที่ทำให้สมการพยากรณ์มีความคลาดเคลื่อนในการพยากรณ์น้อยที่สุดและพิจารณาความสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์กับตัวแปรเกณฑ์จากค่า R มีค่าอยู่ระหว่าง .00 ถึง 1.00 ไม่มีค่าที่เป็นลบ

2.1 การตรวจสอบข้อตกลงเบื้องต้นในการวิเคราะห์ MRA

การใช้วิธี MRA ต้องผ่านการตรวจสอบข้อตกลงเบื้องต้นในการใช้วิธี MRA ดังนี้ (Hair et al., 2010, pp. 181-186)

2.1.1 ตรวจสอบ Normality หมายถึงการแจกแจงของตัวแปรเกณฑ์จะต้องมีลักษณะเป็นโค้งปกติ

2.1.2 ตรวจสอบ Linearity หมายถึงตัวแปรพยากรณ์แต่ละตัวและตัวแปรเกณฑ์จะต้องมีความสัมพันธ์กันในลักษณะของเส้นตรง

2.1.3 ตรวจสอบ Homoscedasticity หมายถึงการแจกแจงทุก ๆ ค่าของตัวแปรพยากรณ์บนตัวแปรเกณฑ์มีค่าใกล้เคียงกัน

2.1.4 ตรวจสอบ Independence of the Error Terms หมายถึงความคลาดเคลื่อนจากการวัดตัวแปรพยากรณ์แต่ละตัวจะต้องเป็นอิสระต่อกัน

2.2 วิธีการเลือกตัวแปรพยากรณ์เพื่อให้ได้สมการถดถอยที่เหมาะสม ดังนี้

2.2.1 วิธี Enter เป็นวิธีการเอาตัวแปรพยากรณ์ทุกตัวทั้งตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์อย่างมีนัยสำคัญทางสถิติและไม่มีนัยสำคัญทางสถิติเข้าไปวิเคราะห์ในสมการถดถอย (เหมาะสำหรับงานวิจัยที่ทบทวนมาเป็นอย่างดีว่าตัวแปรพยากรณ์ที่นำเข้าสู่สมการมีความสัมพันธ์กับตัวแปรเกณฑ์)

2.2.2 วิธี Stepwise เป็นวิธีการคัดเลือกตัวแปรพยากรณ์เข้าสู่สมการโดยจะนำตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดเข้าเป็นสมการแรกและทดสอบความมีนัยสำคัญทางสถิติ ถ้าพบว่าไม่มีนัยสำคัญทางสถิติจะสิ้นสุดการคัดเลือก แต่ถ้าพบว่ามีความสัมพันธ์ก็คัดเลือกตัวแปรพยากรณ์ที่มีความสัมพันธ์อันดับถัดไปเข้าสู่สมการและทุกครั้งที่มีการนำตัวแปรพยากรณ์ตัวใหม่เข้าสู่สมการจะต้องมีการตรวจสอบว่าตัวแปรพยากรณ์ทุกตัวที่อยู่ในสมการก่อนหน้านี้ทุกตัวยังคงอยู่ในสมการหรือไม่ ถ้าไม่คงอยู่ก็จะคัดออกก่อนแล้วค่อยคัดเลือกตัวแปรพยากรณ์ตัวที่มีความสัมพันธ์อันดับถัดไปเข้าสู่สมการ แต่ถ้าไม่มีนัยสำคัญทางสถิติก็จะถูกคัดออก การคัดเลือกตัวแปรพยากรณ์เข้าสู่สมการจะดำเนินการอย่างนี้ไปเรื่อย ๆ จนกระทั่งไม่มีตัวแปรพยากรณ์ตัวใดที่จะนำเข้าหรือคัดออกจากสมการจึงถือว่าสิ้นสุดการคัดเลือก

2.2.3 วิธี Backward เป็นวิธีการคัดเลือกตัวแปรพยากรณ์ออกจากสมการทีละตัวแปร โดยเริ่มจากการสร้างสมการถดถอยที่รวมเอาตัวแปรพยากรณ์ทุกตัวเข้าสู่สมการแรกก่อน แล้วจึงคัดเลือกตัวแปรพยากรณ์ออกทีละตัวแปร โดยพิจารณาตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดจะคัดออก แล้วทำการทดสอบว่าตัวแปรพยากรณ์ที่เหลืออยู่สามารถร่วมกันทำนายตัวแปรเกณฑ์ได้อย่างมีนัยสำคัญทางสถิติหรือไม่ ถ้าไม่ได้ก็จะคัดเลือกตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่เป็นอันดับถัดมาออกจากสมการ แล้วพิจารณาว่าสมการที่เหลือตัวแปรพยากรณ์อยู่มีนัยสำคัญทางสถิติหรือไม่ ถ้ามีนัยสำคัญทางสถิติจะหยุดการคัดออก แต่ถ้าไม่มีนัยสำคัญทางสถิติจะทำการคัดเลือกตัวแปรพยากรณ์ออกต่อไปเรื่อย ๆ จนกว่าไม่มีตัวแปรพยากรณ์ที่ถูกคัดออกอีก การคัดเลือกจะสิ้นสุดเมื่อตัวแปรพยากรณ์ที่เหลืออยู่ในสมการมีความสัมพันธ์กับตัวแปรเกณฑ์อย่างมีนัยสำคัญทางสถิติ

2.2.4 วิธี Forward เป็นวิธีการคัดเลือกตัวแปรพยากรณ์เข้าสู่สมการทีละตัวแปรเรียงตามลำดับความสัมพันธ์ที่มีกับตัวแปรเกณฑ์ โดยตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดจะคัดเลือกเข้าก่อน เมื่อตัวแปรพยากรณ์ที่คัดเลือกเข้าสู่สมการแล้วจะทดสอบว่า

ตัวแปรนั้นสามารถทำนายตัวแปรเกณฑ์ได้อย่างมีนัยสำคัญทางสถิติหรือไม่ จากนั้นคัดเลือกตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์อันดับถัดมาเข้าสมการ แล้วทดสอบว่าตัวแปรพยากรณ์ที่อยู่ในสมการสามารถร่วมกันทำนายตัวแปรเกณฑ์ได้อย่างมีนัยสำคัญทางสถิติหรือไม่ ทำเช่นนี้ไปเรื่อย ๆ จนกระทั่งไม่มีตัวแปรพยากรณ์ตัวใดเข้าไปในสมการได้อีก จึงหยุดการคัดเลือกตัวแปรพยากรณ์ และถือว่าสมการที่ได้นั้นเป็นสมการที่เหมาะสม

2.3 งานวิจัยที่เกี่ยวข้องกับการใช้วิธี MRA

อรนงค์ บุเกตุ และพฤษดี ศิริแสงตระกูล (2556) พยากรณ์ปริมาณผลผลิตอ้อยของภาคตะวันออกเฉียงเหนือ โดยการประยุกต์ใช้โครงข่ายประสาทเทียมที่มีกระบวนการเรียนรู้แบบแพร่ย้อนกลับ การศึกษาผู้วิจัยได้รวบรวมปัจจัยต่าง ๆ ที่มีความสัมพันธ์กับผลผลิตอ้อยจากงานวิจัยที่เกี่ยวข้องได้แก่ ข้อมูลจังหวัด ปีการผลิต ข้อมูลปริมาณน้ำฝนเฉลี่ย อุณหภูมิเฉลี่ย ผลผลิตอ้อยเฉลี่ยต่อไร่ และพื้นที่ปลูกอ้อยเป็นข้อมูลนำเข้าของตัวแบบ ANN1 เพื่อยืนยันความสัมพันธ์ของปัจจัยกับปริมาณผลผลิตอ้อย ผู้วิจัยจึงได้ทำวิเคราะห์ความสัมพันธ์ของปัจจัยโดยใช้ Correlation และ Regression ผลการศึกษาพบว่าปัจจัยที่มีความสัมพันธ์ได้แก่ ข้อมูลจังหวัด ปีการผลิต ข้อมูลปริมาณน้ำฝนเฉลี่ย ผลผลิตอ้อยเฉลี่ยต่อไร่ และพื้นที่ปลูกอ้อย ซึ่งจะเป็นข้อมูลนำเข้าตัวแบบ ANN2 และเมื่อเพิ่มปัจจัยราคาพืชแข่งขันทางเศรษฐกิจที่น่าจะมีผลต่อปริมาณการปลูกอ้อยในเขตพื้นที่ภาคตะวันออกเฉียงเหนือคือ ราคาอ้อยเฉลี่ย ราคาขากพาราเฉลี่ย และราคามันสำปะหลังเฉลี่ย มารวมกับปัจจัยที่มีความสัมพันธ์ที่ได้จากการวิเคราะห์ด้วยวิธีทางสถิติได้แก่ ข้อมูลจังหวัด ปีการผลิต พื้นที่ปลูกอ้อย ผลผลิตอ้อยเฉลี่ยต่อไร่ และข้อมูลปริมาณน้ำฝนเฉลี่ย เป็นข้อมูลนำเข้าของตัวแบบ ANN3 ผลการศึกษาพบว่าตัวแบบ ANN3 ที่มีสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบ 8:4:1 ให้ผลพยากรณ์แม่นยำสูงที่สุด มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.9973 เมื่อเทียบกับ ANN1 ที่มีสถาปัตยกรรม 5:10:1 และ ANN2 ที่มีสถาปัตยกรรม 6:8:1 โดยมีค่าสัมประสิทธิ์สหสัมพันธ์ 0.9794, 0.9822 ตามลำดับ

พงศ์ศักดิ์ ชลธนสวัสดิ์, รัตนา ตั้งวงศ์กิจ, บพิตร ตั้งวงศ์กิจ และสุณัฐธิดา อัจฉริศิลป์เวท (2558) ศึกษาและวิเคราะห์อิทธิพลของปริมาณน้ำฝนเฉลี่ยรายปีต่อปริมาณผลผลิตอ้อยเฉลี่ยต่อไร่ในพื้นที่ภาคกลางเขต 7 (นครปฐม สุพรรณบุรี กาญจนบุรี ราชบุรีและอุทัยธานี) โดยใช้ข้อมูลย้อนหลัง 10 ปี ระหว่างปี พ.ศ. 2546–2555 วิเคราะห์อิทธิพลของปริมาณน้ำฝนเฉลี่ยรายปีต่อผลผลิตอ้อยเฉลี่ยต่อไร่ เพื่อให้ได้ข้อมูลสำหรับการวางแผนการให้น้ำและการจัดการการให้น้ำ สำหรับพื้นที่การเพาะปลูกอ้อยโรงงานทำให้ได้ปริมาณผลผลิตอ้อยสูงสุด การศึกษาวิจัยแบ่งเป็น 2 ตอนคือ 1) ศึกษาแนวโน้มการเปลี่ยนแปลงของจำนวนวันที่ฝนตก ปริมาณฝนเฉลี่ยรายปีและปริมาณผลผลิตอ้อยเฉลี่ยต่อไร่ และ 2) ศึกษาความสัมพันธ์ระหว่างปริมาณน้ำฝนเฉลี่ยรายปีต่อปริมาณผลผลิตอ้อยเฉลี่ยต่อไร่ ในรูปสมการถดถอย ผลการศึกษาพบว่า จำนวนวันที่ฝนตก ปริมาณน้ำฝนเฉลี่ยรายปีและผลผลิตอ้อย

เฉลี่ยต่อไร่ มีแนวโน้มการเปลี่ยนแปลงที่เพิ่มขึ้น ปริมาณน้ำฝนเฉลี่ยรายปีและปริมาณผลผลิตอ้อยเฉลี่ยต่อไร่มีความสัมพันธ์กันแบบแปรผันตามกัน คือเป็นไปในทิศทางเดียวกัน อิทธิพลของปริมาณน้ำฝนเฉลี่ยรายปีต่อปริมาณผลผลิตอ้อยเฉลี่ยต่อไร่ เมื่อปริมาณน้ำฝนเฉลี่ยรายปี (x) เพิ่มขึ้น จะส่งผลให้ปริมาณผลผลิตอ้อยเฉลี่ยต่อไร่ (y) เพิ่มขึ้นโดยมีสมการถดถอย คือ $y = 0.2732X - 537.21$ และมีค่า $R^2 = 0.4556$

กิตติเชษฐ์ นนทะสุด และธีรพจน์ เวศพันธุ์ (2560) เปรียบเทียบการสร้างตัวแบบพยากรณ์การใช้พลังงานไฟฟ้าของท่าอากาศยานเชียงใหม่ด้วยวิธีโครงข่ายประสาทเทียมกับวิธี MRA จากการพิจารณาค่าความคลาดเคลื่อนของการพยากรณ์ด้วยค่า MAPE เพื่อเลือกตัวแบบพยากรณ์ที่มีความเหมาะสมที่สุด สำหรับการพยากรณ์การใช้พลังงานไฟฟ้าของท่าอากาศยานเชียงใหม่ในอนาคต ตัวแปรที่ใช้ในการศึกษาได้แก่ จำนวนเที่ยวบิน จำนวนผู้โดยสาร จำนวนสินค้าและไปรษณีย์ เป็นตัวแปรพยากรณ์ และพลังงานไฟฟ้าเป็นตัวแปรเกณฑ์ ข้อมูลที่นำมาวิเคราะห์เป็นข้อมูลสถิติย้อนหลังระหว่างปี พ.ศ. 2551-2559 ผลการศึกษาพบว่า การพยากรณ์การใช้พลังงานไฟฟ้าด้วยวิธีโครงข่ายประสาทเทียม และวิธี MRA มีค่า MAPE เท่ากับ 1.64 และ 2.57 ตามลำดับ จึงสามารถสรุปได้ว่าตัวแบบพยากรณ์จากวิธีโครงข่ายประสาทเทียมมีความเหมาะสมที่สุด ซึ่งสามารถพยากรณ์การใช้พลังงานไฟฟ้าของท่าอากาศยานเชียงใหม่ในอนาคตสำหรับการวางแผนพัฒนาท่าอากาศยานเชียงใหม่

Mamman (2018) ศึกษาผลกระทบของปริมาณน้ำฝนที่มีต่อผลผลิตมันเทศในเมืองมอควา (Mokwa) รัฐไนเจอร์และประเทศไนจีเรีย ซึ่งผลผลิตทางการเกษตรในประเทศไนเจอร์มักได้รับความเสียหายจากการเปลี่ยนแปลงของสภาพภูมิอากาศ ดังนั้นการวิจัยนี้จึงทำการศึกษาและวิเคราะห์ผลกระทบของปริมาณน้ำฝนที่มีต่อผลผลิตมันเทศในเมืองมอควา เก็บรวบรวมข้อมูลจากแบบสอบถามของกลุ่มตัวอย่างจำนวน 100 คน ส่วนข้อมูลปริมาณน้ำฝนนั้นใช้ข้อมูลปี ค.ศ. 2003-2015 รวม 13 ปีที่ได้รับจากวิทยาลัยเกษตรมอควา และข้อมูลผลผลิตมันเทศได้รับจากกระทรวงเกษตรรัฐไนเจอร์ใช้ข้อมูลปี ค.ศ. 2000-2015 รวม 16 ปี โดยใช้ตัวแบบถดถอยเชิงเส้นและดัชนีค่าเบี่ยงเบนมาตรฐานผิดปกติ (Standardized Anomaly Index: SAI) ในการวิเคราะห์ข้อมูล จากการศึกษาพบว่า ค่าเฉลี่ยปริมาณน้ำฝนรายปีในบริเวณที่ศึกษามีค่าน้อยที่สุด สำหรับค่าเฉลี่ยปริมาณน้ำฝนรายเดือนมีค่า $R^2=0.8$ อย่างมีนัยสำคัญทางสถิติ นอกจากนี้ความแปรปรวนของปริมาณน้ำฝนยังมีความสัมพันธ์กับผลผลิตมันเทศอย่างมากในทิศทางบวก โดยมีค่า $r^2=0.88$

Navid and Niloy (2018) ศึกษาการพยากรณ์ปริมาณน้ำฝนโดยใช้วิธีการวิเคราะห์ถดถอยพหุคูณ (Multiple Linear Regression: MLR) ที่ประเทศบังคลาเทศ ตัวแปรเกณฑ์คือปริมาณน้ำฝน ตัวแปรพยากรณ์ได้แก่ หยาดน้ำฟ้า (Precipitation) (X_1) อุณหภูมิเฉลี่ย (X_2) เมฆที่ปกคลุม (X_3) และความดันไอน้ำ (Vapor Pressure) (X_4) และพิจารณาความแม่นยำของการพยากรณ์จากค่า R ผลลัพธ์ของความสัมพันธ์ของตัวแปรพยากรณ์กับตัวแปรเกณฑ์เป็นสมการ

พยากรณ์เชิงเส้นตรงคือ $Y' = -1323.062 + 0.237X_1 + 10.75X_2 + 16.317X_3 + 13.038X_4$ จากสมการสามารถนำไปใช้ในการพยากรณ์ปริมาณน้ำฝนในอนาคตเมื่อทราบข้อมูลของตัวแปรพยากรณ์ แต่การพยากรณ์ปริมาณน้ำฝนยังมีปัจจัยอื่น ๆ อีกที่อาจจะส่งผลต่อปริมาณน้ำฝนด้วย


Stephen and Ben-Edigbe (2018) ศึกษาผลกระทบของฝนที่ตกที่มีผลต่อพฤติกรรมของผู้ขับขี่และการยอมรับช่องว่างบริเวณวงเวียนหลายช่องทาง (Gap Acceptance at Multilane Roundabouts) ซึ่งงานวิจัยนี้เติมเต็มช่องว่างเรื่องของการพฤติกรรมผู้ขับขี่และการยอมรับช่องว่างบริเวณวงเวียนหลายช่องทาง โดยทดสอบสมรรถภาพด้านการจราจรระหว่างฝนตก ข้อมูลปริมาณของการจราจร ชนิดของยานพาหนะและการขับเคลื่อนถูกรวบรวมที่วงเวียนหลายช่องทางในเมืองเดอร์บัน (Durban) ประเทศแอฟริกาใต้ การสำรวจถูกทำขึ้นภายในพื้นที่ที่ห่างจากบริเวณที่มีเครื่องวัดปริมาณน้ำฝนประมาณ 1 กิโลเมตร ปริมาณน้ำฝนที่วัดได้แบ่งเป็น 3 ระดับคือ ฝนตกเล็กน้อย ฝนตกปานกลางและฝนตกหนัก พร้อมกับข้อมูลสภาพอากาศแห้ง (Dry Weather) ถูกใช้เพื่อควบคุมพารามิเตอร์ เทคนิคการวิเคราะห์แบบ Stepwise ถูกนำมาใช้ในการอธิบายผลกระทบที่เกิดขึ้นตัวแบบของสมการทุกสมการถูกทดสอบเพื่อหาค่าสถิติที่เหมาะสม ผลการศึกษาพบว่าปริมาณของฝนที่ตกมีผลต่อการขับขี่และการยอมรับช่องว่างวิกฤต

จากการศึกษางานวิจัยที่เกี่ยวข้องกับการใช้วิธี MRA พบว่าวิธี MRA ถูกใช้เพื่อคัดเลือกตัวแปรหรือปัจจัย (ตัวแปรพยากรณ์) ที่ส่งผลต่อตัวแปรเกณฑ์สำหรับนำไปวิเคราะห์ในขั้นตอนต่อไป ร่วมกับวิธีอื่น ๆ และใช้สร้างสมการพยากรณ์เพื่อพยากรณ์ตัวแปรเกณฑ์จากตัวแปรพยากรณ์ เทคนิคที่นิยมนำมาใช้คือ Stepwise จากนั้นพิจารณาประสิทธิภาพของการพยากรณ์จากค่า R^2

ตอนที่ 3 วิธีโครงข่ายประสาทเทียม (Artificial Neural Network) และงานวิจัยที่เกี่ยวข้อง

วิธีโครงข่ายประสาทเทียม (Artificial Neural Network) คือตัวแบบทางคณิตศาสตร์ที่พัฒนาขึ้นเพื่อจำลองการทำงานของโครงข่ายประสาทในสมองมนุษย์ผ่านกระบวนการเรียนรู้ กล่าวคือโครงข่ายประสาทเทียมมีคุณลักษณะคล้ายกับการส่งผ่านสัญญาณประสาทในสมองของมนุษย์ที่มีความสามารถในการรวบรวมความรู้ (Knowledge) ผ่านกระบวนการเรียนรู้ (Learning process) ความรู้จัดเก็บอยู่ในรูปแบบค่าน้ำหนัก (Weight) ของโครงข่าย ค่าน้ำหนักจะเป็นค่าบวกหรือค่าลบก็ได้ สามารถปรับเปลี่ยนค่าได้เมื่อมีการเรียนรู้สิ่งใหม่ ๆ เข้าไป (Mohammadi et al., 2018) การประมวลผลต่าง ๆ เกิดขึ้นในหน่วยประมวลผลย่อยเรียกว่าโหนด (Node) ระหว่างโหนดมีการเชื่อมต่อกัน (Connection) ของหน่วยรับข้อมูลนำเข้า (Input) และหน่วยส่งข้อมูลออก (Output) เป็นการจำลองลักษณะการทำงานมาจากเซลล์การส่งสัญญาณ (Signal) ที่มีเชื่อมต่อของเดนไดรต์ (Dendrites) ที่เปรียบเสมือนเป็นหน่วยรับข้อมูลนำเข้า และแอกซอน (Axon) ที่เปรียบเสมือนหน่วย

ส่งข้อมูลออกในระบบประสาทของมนุษย์ ภายในโหนดมีฟังก์ชันที่ทำหน้าที่กำหนดสัญญาณส่งออกที่เรียกว่า ฟังก์ชันกระตุ้น (Activation Function) หรือฟังก์ชันการแปลง (Transfer Function) ทำหน้าที่เปรียบเสมือนกระบวนการทำงานภายในเซลล์ (ธนาวุฒิ ประกอบผล, 2552; Haykin, 1999, pp. 10-11; Kirar, 2015) ดังภาพที่ 2-5 นิยาม ทฤษฎีและงานวิจัยที่เกี่ยวข้องกับโครงข่ายประสาทเทียมคือ



ภาพที่ 2-5 โครงข่ายประสาทเทียม นำเสนอโดย ณีฎฐา ผิวมา (2558)

3.1 โครงสร้างของโครงข่ายประสาทเทียมประกอบด้วย 5 องค์ประกอบ (จตุภัทร เมฆพ่ายพ และกิตติการ สายธนู, 2554; ณีฎฐา ผิวมา, 2558; ณีฐพงษ์ วารีประเสริฐ, 2552, หน้า 249-250; ธนาวุฒิ ประกอบผล, 2552; ศุภโชค แสงสว่าง, 2559) อธิบายไว้ดังนี้

3.1.1 ข้อมูลนำเข้า (Input Data) หมายถึงข้อมูลที่ระบบจะนำเข้ามาประมวลผลตามรูปแบบของปัญหาที่ต้องการแก้ไขหรือพิจารณาซึ่งข้อมูลนำเข้าจะมีความสอดคล้องและสัมพันธ์กับปัญหาที่เกิดขึ้น เพื่อนำข้อมูลมาตัดสินใจแก้ไขปัญหานั้น โดยจะถูกจำแนกตามคุณลักษณะของข้อมูลนำเข้า (Attribute) หรือตามความต้องการของระบบ ข้อมูลนำเข้าเพื่อทำการประมวลผลเป็นข้อมูลเชิงปริมาณหรือเชิงคุณภาพก็ได้หากเป็นข้อมูลเชิงคุณภาพต้องแปลงให้อยู่ในรูปเชิงปริมาณที่โครงข่ายประสาทเทียมยอมรับได้ เป็นข้อความ รูปภาพหรือเสียงก็ได้ โดยข้อมูลแต่ละชนิดจะถูกแปลงให้อยู่ในรูปแบบที่คอมพิวเตอร์เข้าใจได้ หลังจากนั้นเมื่อเข้าสู่ขั้นตอนการประมวลผล จำเป็นต้องกำหนดค่าน้ำหนักของความสัมพันธ์ระหว่างข้อมูลให้กับข้อมูลนำเข้าด้วย

3.1.2 ค่าน้ำหนัก (Weight Values) เป็นสิ่งที่ได้จากการเรียนรู้ของโครงข่ายประสาทเทียมหรือเรียกอีกอย่างหนึ่งว่า “ค่าความรู้” กำหนดให้เฉพาะข้อมูลนำเข้าแต่ละตัว เพื่อใช้ในการแยกแยะความแตกต่างของข้อมูลนำเข้า ถือเป็นองค์ประกอบที่สำคัญมากในระบบโครงข่ายประสาทเทียม ค่าน้ำหนักที่แตกต่างกันจะแสดงระดับความสำคัญของข้อมูลนำเข้า ทำให้เลือกข้อมูลตรงกับปัญหาได้ โดยวิธีการอาจได้จากการลองผิดลองถูกและสร้างแบบแผน (Pattern) จากประสบการณ์เพื่อใช้ในการเรียนรู้

3.1.3 ฟังก์ชันผลรวม (Summation Function: S) เป็นองค์ประกอบที่มีหน้าที่รวมค่าน้ำหนักที่ได้จากโครงข่ายของข้อมูลนำเข้า (a_i) และค่าน้ำหนัก (w_i) ในแต่ละชั้น (Layer) เพื่อใช้สำหรับสรุปผลความสัมพันธ์ระหว่างข้อมูลนำเข้าทั้งหมด ซึ่งเป็นขั้นตอนก่อนการนำข้อมูลเหล่านั้นมาแปลงให้อยู่ในรูปสารสนเทศที่มีความหมายหรือสามารถเข้าใจได้ กำหนดให้ n แทนจำนวนข้อมูลนำเข้าในชั้นรับข้อมูลเข้า b แทนค่าความเอนเอียง (Bias) ที่เพิ่มเข้าไปในฟังก์ชันผลรวม คำนวณฟังก์ชันผลรวมจาก

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

3.1.4 ฟังก์ชันการแปลง (Transformation Function) เป็นองค์ประกอบที่ทำหน้าที่ในการประสาน (Integrate) สารสนเทศที่ผ่านการประมวลผลจากโครงข่ายในชั้นต่าง ๆ แล้วนำสารสนเทศเหล่านั้นมาแปลงให้สามารถสื่อความหมายได้ เพื่อนำมาใช้สำหรับการแสดงผลลัพธ์ต่อไป ฟังก์ชันในองค์ประกอบนี้บางครั้งเรียกว่า ฟังก์ชันกระตุ้น เป็นการคำนวณการจำลองการทำงานของโครงข่ายประสาทเทียม โดยทั่วไปฟังก์ชันการแปลงจะแบ่งเป็น 2 ลักษณะคือ

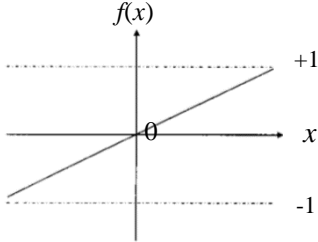
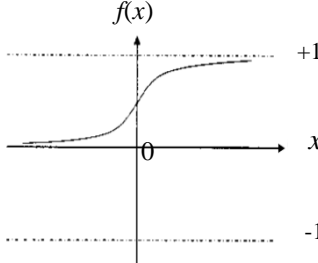
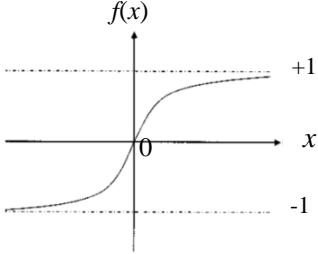
3.1.4.1 ฟังก์ชันการแปลงเชิงเส้น (Linear Transfer Function) ซึ่งการแปลงนี้สามารถเรียนรู้เพียงความสัมพันธ์เชิงเส้นระหว่างข้อมูลนำเข้า และข้อมูลส่งออก ดังนั้นจึงไม่สามารถหาผลลัพธ์ได้สำหรับบางกรณี อย่างไรก็ตามถ้าผลลัพธ์ที่ได้ไม่ใช่ผลลัพธ์ที่ดีที่สุด ฟังก์ชันการแปลงเชิงเส้นจะหาค่าต่ำสุดของผลรวมค่าความคลาดเคลื่อนกำลังสอง แต่ถ้าอัตราการเรียนรู้มีค่าน้อย โครงข่ายประสาทเทียมจะหาผลลัพธ์ที่ใกล้เคียงเท่าที่จะเป็นไปได้ที่แสดงลักษณะเชิงเส้นของลักษณะของโครงข่าย

3.1.2.4.2 ฟังก์ชันการแปลงไม่ใช่เชิงเส้น (Nonlinear Transfer Function) ประกอบด้วย ฟังก์ชันการแปลงคือ

- ซิกมอยด์ฟังก์ชัน (Sigmoid Function) หรือฟังก์ชันการแปลงแบบซิกมอยด์ ซึ่งการแปลงนี้จะบีบช่วงข้อมูลนำเข้าที่ไม่จำกัดให้เป็นช่วงของข้อมูลส่งออกที่จำกัด โดยที่ช่วงของข้อมูลส่งออกจะอยู่ในช่วง 0 ถึง 1 ฟังก์ชันการแปลงแบบซิกมอยด์จะแสดงลักษณะของข้อเท็จจริงที่มีความชันเข้าใกล้ศูนย์ เมื่อข้อมูลนำเข้ามีจำนวนมาก ขั้นตอนวิธีการเรียนรู้แบบแพร่ย้อนกลับ มีวัตถุประสงค์เพื่อลดผลกระทบที่ส่งผลต่อขนาดของอนุพันธ์ไม่ให้มีผลกระทบต่อค่าน้ำหนักปัจจุบันโดยขนาดของการเปลี่ยนแปลงค่าน้ำหนักถูกกำหนด โดยค่าปัจจุบันที่แยกออกมา ค่าปัจจุบันสำหรับค่าน้ำหนักและค่าความเอนเอียงแต่ละค่าจะเพิ่มขึ้น เมื่ออนุพันธ์ของฟังก์ชันสัมพันธ์กับค่าน้ำหนักที่มีเครื่องหมายเดียวกันสำหรับการกระทำซ้ำรอบสองและค่าปัจจุบันจะลดลง เมื่ออนุพันธ์ที่สัมพันธ์กับน้ำหนักรับเปลี่ยนแปลงเครื่องหมายจากการกระทำซ้ำรอบก่อน ถ้าอนุพันธ์เท่ากับศูนย์แสดงว่าค่าปัจจุบันยังคงเดิม

- ฟังก์ชันไฮเปอร์โบลิกแทนเจนต์ (Hyperbolic Tangent Function) มีลักษณะเช่นเดียวกับฟังก์ชันการแปลงแบบซิกมอยด์ แต่ต่างกันเพียงช่วงของข้อมูลส่งออก โดยการแปลงนี้จะอยู่ในช่วง -1 ถึง +1 ฟังก์ชันการแปลงของโครงข่ายประสาทเทียมสามารถสรุปได้ดังตารางที่ 2-1

ตารางที่ 2-1 ฟังก์ชันการแปลงของโครงข่ายประสาทเทียม

ชนิดของฟังก์ชันการแปลง	รูปแบบ	สมการทางคณิตศาสตร์	ช่วงของข้อมูลส่งออก
เชิงเส้น		$f(x) = x$	$(-\infty, \infty)$
ซิกมอยด์ฟังก์ชัน		$f(x) = \frac{1}{1 + e^{-x}}$	$(0, 1)$
ไม่เชิงเส้น			
ไฮเปอร์โบลิกแทนเจนต์		$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$	$(-1, 1)$

จะเห็นได้ว่าฟังก์ชันการแปลงมีหลายชนิด การที่จะเลือกใช้ฟังก์ชันชนิดใดขึ้นอยู่กับปัญหางานที่ทำการศึกษา ลักษณะของผลลัพธ์ ความต่อเนื่องของข้อมูลและขอบเขตของผลลัพธ์ เป็นต้น

3.1.5 ข้อมูลส่งออก (Output Data) เป็นผลลัพธ์จริง (Actual Output) จากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม เป็นองค์ประกอบที่เกิดจากการประมวลผลข้อมูลผ่านกระบวนการต่าง ๆ ทั้งจากผลรวมค่าน้ำหนักของข้อมูลนำเข้าที่ถูกปรับเปลี่ยนค่าน้ำหนักแล้วจะถูกประมวลผลผ่านฟังก์ชันการแปลงเป็นสารสนเทศที่มีความหมาย ซึ่งสารสนเทศเหล่านี้คือ ผลลัพธ์ที่แสดงผลแก่ผู้ใช้ต่อไป สำหรับผลลัพธ์ที่ได้จะเป็นแนวทางในการแก้ไขปัญหาตามที่ระบบคาดหวังไว้

โดยอาจเป็นผลลัพธ์ที่ยังไม่สมบูรณ์หรือตรงตามที่ต้องการ เนื่องจากผลลัพธ์ดังกล่าวอาจนำไปใช้เป็นข้อมูลนำเข้าของอีกระบบหนึ่งก่อนที่จะได้ผลลัพธ์ที่ต้องการอย่างแท้จริง กำหนดให้ y แทนข้อมูลส่งออก f แทนฟังก์ชันการแปลง สามารถคำนวณข้อมูลส่งออกจาก

$$y = f\left[\left(\sum_{i=1}^n a_i w_i\right) + b\right]$$

3.2 โครงข่ายประสาทเทียมแบ่งชั้น (Layer) การทำงานออกเป็น 3 ชั้น ดังนี้

3.2.1 ชั้นรับข้อมูลเข้า (Input Layer) เป็นชั้นที่นำข้อมูลดิบเข้ามาสู่ระบบโครงข่าย โดยข้อมูลนี้จะถูกนำไปประมวลผลในลำดับต่อไป แต่ละโหนดของชั้นนี้จะเชื่อมโยงกับทุกโหนดของชั้นถัดไป

3.2.2 ชั้นซ่อน (Hidden Layer) เป็นชั้นที่รับข้อมูลจากชั้นรับข้อมูลเข้า ซึ่งมีการกำหนดข้อมูลค่าน้ำหนักให้กับข้อมูลที่ส่งไปยังแต่ละชั้นโหนด โดยค่าน้ำหนักจะถูกกำหนดระหว่างชั้นรับข้อมูลเข้าและชั้นซ่อน

3.2.3 ชั้นส่งข้อมูลออก (Output Layer) เป็นชั้นการส่งข้อมูลออกซึ่งเป็นผลลัพธ์ที่ผ่านการประมวลผลจากทั้งฟังก์ชันผลรวมและฟังก์ชันการแปลง จนได้ผลลัพธ์ที่สามารถนำไปประยุกต์ใช้งานในด้านต่าง ๆ ต่อไป

3.3 หลักการทำงานของโครงข่ายประสาทเทียม นำเสนอโดย Golic (2013) มี 2 ขั้นตอนได้แก่

3.3.1 ขั้นตอนการเรียนรู้ (Training) เริ่มจากป้อนข้อมูลนำเข้าและข้อมูลส่งออกที่ต้องการจากชุดข้อมูลการเรียนรู้ (Training Data Set) ซึ่งประกอบด้วย 2 ส่วน 1) การคำนวณแบบป้อนไปข้างหน้า (Feed Forward) จากชั้นรับข้อมูลเข้าแล้วส่งต่อไปยังชั้นซ่อน ต่อไปยังชั้นส่งข้อมูลออก และ 2) การคำนวณแบบย้อนกลับ (Backward) เพื่อทำการปรับค่าน้ำหนักและความเอนเอียง

3.3.2 ขั้นตอนการทดสอบ (Testing) โดยนำโครงข่ายประสาทเทียมที่ได้จากขั้นตอนการเรียนรู้มาใช้งาน เริ่มจากป้อนข้อมูลนำเข้าจากชุดข้อมูลทดสอบ (Testing Data Set) ขั้นตอนของการทดสอบมีเพียงส่วนเดียวคือ การคำนวณแบบป้อนไปข้างหน้าโดยนำค่าน้ำหนักที่ได้จากขั้นตอนการเรียนรู้มาใช้งาน


3.4 สถาปัตยกรรมโครงข่ายประสาทเทียม (Architecture of Neural Networks)

โครงสร้างการเชื่อมต่อของโครงข่ายประสาทเทียม รวมถึงรูปแบบการเชื่อมต่อของโครงข่ายประสาทเทียม เรียกว่า สถาปัตยกรรมของโครงข่ายประสาทเทียม สำหรับสถาปัตยกรรมของโครงข่ายประสาทเทียมที่แตกต่างกัน มีผลทำให้ประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมมีความแตกต่างกัน แบ่งได้เป็น 4 รูปแบบดังนี้

3.4.1 เพอร์เซ็ปตรอน (Perceptrons) เป็นสถาปัตยกรรมของโครงข่ายประสาทเทียมที่ง่ายที่สุด ประกอบด้วยเซลล์ประสาทเพียงโหนดเดียวที่รับค่าข้อมูลนำเข้ามา เพื่อหาค่าฟังก์ชันผลรวม จากนั้นเข้าสู่การแปลงค่าด้วยฟังก์ชันการแปลง ได้ผลลัพธ์ออกมาเป็นข้อมูลส่งออกเพียงค่าเดียว เพอร์เซ็ปตรอนเหมาะสำหรับการแก้ปัญหาเพื่อจำแนกรูปแบบหรือจัดหมวดหมู่ ซึ่งมีความรวดเร็ว และเชื่อถือได้ (Haykin, 1999, p. 117)


3.4.2 ชั้นของโครงข่าย (Network Layer) โครงข่ายประสาทเทียมประกอบด้วยเซลล์ประสาทเทียมหรือโหนดจำนวนมากเชื่อมต่อกัน ซึ่งการเชื่อมต่อแบ่งออกเป็นกลุ่มย่อยที่เรียกว่า ชั้น (Layer) ในแต่ละชั้นประกอบด้วยโหนดที่ทำหน้าที่ประมวลผลและเชื่อมต่อผลลัพธ์ไปยังชั้นถัดไป โดยทั่วไปประกอบด้วย 3 ชั้นได้แก่ ชั้นรับข้อมูลเข้า ชั้นส่งข้อมูลออก และชั้นซ่อนที่อยู่ระหว่างชั้นรับข้อมูลเข้ากับชั้นส่งข้อมูลออก ซึ่งเป็นชั้นที่เชื่อมชั้นรับข้อมูลเข้าและชั้นส่งข้อมูลออก บางครั้งชั้นซ่อนอาจมีมากกว่า 1 ชั้นก็ได้ และจากที่จำนวนชั้นของโครงข่ายไม่เท่ากันนั้น สามารถแบ่งประเภทของโครงข่ายประสาทเทียมตามจำนวนชั้นของโครงข่ายแบบกว้าง ๆ ได้ 2 แบบดังนี้

3.4.2.1 โครงข่ายแบบชั้นเดียว (Single-Layer Perceptron: SLP) เป็นโครงข่ายประสาทเทียมที่มีชั้นรับข้อมูลเข้าและชั้นส่งข้อมูลออก โดยไม่มีชั้นซ่อนซึ่งถือว่าเป็นโครงข่ายประสาทเทียมอย่างง่าย (Chauhan, Yadav, & Arya, 2018) จำนวนโหนดที่อยู่ในชั้นรับข้อมูลเข้าขึ้นอยู่กับจำนวนส่วนประกอบ (Components) ของข้อมูลนำเข้า ส่วนฟังก์ชันกระตุ้นขึ้นอยู่กับลักษณะของข้อมูลส่งออก เมื่อโหนดที่อยู่ในชั้นรับข้อมูลเข้ารับข้อมูลเข้าสู่โครงข่าย จากนั้นจะส่งข้อมูลผ่านเส้นเชื่อมต่าง ๆ ไปให้โหนดในชั้นส่งข้อมูลออก ปริมาณข้อมูลที่นำเข้าสู่โหนดในชั้นส่งข้อมูลออกจะขึ้นอยู่กับค่าน้ำหนักที่กำกับอยู่บนเส้นเชื่อมโยงทุกเส้น หลังจากโหนดในชั้นส่งข้อมูลออกจะนำข้อมูลที่ได้รับมาคำนวณโดยใช้ฟังก์ชันการแปลงที่เหมาะสมกับปัญหา แล้วส่งผลลัพธ์ที่ได้ออกมาเป็นข้อมูลส่งออก (Haykin, 1999, p. 21; Sibanda & Pretorius, 2012) โครงข่ายแบบชั้นเดียวแสดงดังภาพที่ 2-6



ภาพที่ 2-6 โครงข่ายแบบชั้นเดียว

3.4.2.2 โครงข่ายแบบหลายชั้น (Multi-layer Perceptron: MLP) เป็นโครงข่ายประสาทเทียมที่มีชั้นรับข้อมูลเข้า ชั้นส่งข้อมูลออก และชั้นซ่อนอย่างน้อย 1 ชั้น (Haykin, 1999, p. 21) ไม่มีข้อจำกัดทางทฤษฎีต่อจำนวนชั้นซ่อน แต่ปกติแล้วจะมีเพียง 1 หรือ 2 ชั้นเท่านั้น โดยมีข้อพิจารณาคือ จำนวนชั้นและจำนวนโหนดมากจะนำไปสู่ความซับซ้อนของตัวแบบมากเกินไป (Overfitting) และจะทำให้ระยะเวลาในการคำนวณช้ามากด้วย ถ้าเกิดความซับซ้อนของตัวแบบมากเกินไปสิ่งนี้อาจจะพิจารณาให้ลดจำนวนของโหนดในชั้นซ่อน ในทางกลับกันหากมีจำนวนโหนดน้อยเกินไป จะทำให้ไม่สามารถเรียนรู้ได้อย่างมีประสิทธิภาพ สิ่งนี้อาจจะพิจารณาให้เพิ่มจำนวนโหนดในชั้นซ่อน (สายชล สินสมบูรณ์, 2558, หน้า 196; Dawson & Wilby, 1999) จะส่งผลทำให้การคำนวณเกิดความคลาดเคลื่อนได้ เนื่องจากการไม่ลู่เข้าค่าต่ำสุด (Convergent) ในแต่ละชั้นซ่อน จะมีฟังก์ชันคำนวณ ชั้นซ่อนนั้นมีหน้าที่สำคัญคือ จะพยายามแปลงข้อมูลที่เข้ามาในชั้นนั้น ๆ ให้สามารถแยกแยะความแตกต่างโดยใช้เส้นตรงเส้นเดียว (Linearly Separable) ก่อนที่ข้อมูลจะถูกส่งไปถึงชั้นส่งข้อมูลออก โครงข่ายแบบนี้เหมาะสำหรับงานที่มีความซับซ้อน โดยมีกระบวนการเรียนรู้แบบมีผู้สอน (Supervised Learning) (ณัฐฐา ผิวมา, 2558) นิยมนำมาใช้ในการพยากรณ์ (Rasel & Imteaz, 2016; Hashim et al., 2017) โครงข่ายแบบหลายชั้นแสดงดังภาพที่ 2-7



ภาพที่ 2-7 โครงข่ายแบบหลายชั้น นำเสนอโดย ณัฐฐา ผิวมา (2558)

3.4.3 โครงข่ายแบบป้อนไปข้างหน้า (Feedforward Network) เป็นสถาปัตยกรรมของโครงข่ายประสาทเทียมที่มีการเชื่อมโยงระหว่างชั้นที่ติดกัน จากชั้นหนึ่ง ๆ ไปยังชั้นต่อ ๆ ไป ในบางสถาปัตยกรรมอาจมีการเชื่อมโยงข้ามชั้นก็ได้ แต่โหนดที่อยู่ในชั้นเดียวกันไม่มีการเชื่อมต่อกัน ข้อมูลที่ประมวลผลแต่ละโหนดของโครงข่ายจะถูกส่งไปในทิศทางเดียว โดยเริ่มจากโหนดรับข้อมูลนำเข้า (input nodes) ส่งต่อมาเรื่อย ๆ จนถึงโหนดส่งข้อมูลออก (Output nodes) โดยไม่มีการย้อนกลับของข้อมูล (Ramesh, Parkavi, & Yasodha, 2011; Sibanda & Pretorius, 2012; Uddin, Jameel, & Razak, 2015)

3.4.4 โครงข่ายแบบมีการป้อนไปเวียนกลับ (Feedback Network หรือ Recurrent Network) เป็นสถาปัตยกรรมของโครงข่ายประสาทเทียมที่อาจมีการเชื่อมโยงกันของ เซลล์ประสาทเทียมในชั้นหนึ่ง ๆ ย้อนกลับไปยังชั้นอื่น ๆ ที่อยู่ก่อนหน้านั้นหรือแม้แต่ภายในชั้นเดียวกันเอง ข้อมูลที่ประมวลผลแต่ละโหนดของโครงข่ายนั้นจะมีการป้อนกลับเข้าไปยังโครงข่ายหลาย ๆ ครั้ง จนกระทั่งได้ผลลัพธ์ออกมา (Chauhan et al., 2018; Haykin, 1999, p. 23; Ramesh et al., 2011; Uddin et al., 2015)

3.5 ประเภทของการเรียนรู้ของโครงข่ายประสาทเทียม (Learning of Neural Network) โดยทั่วไปการเรียนรู้ของโครงข่ายประสาทเทียมคือ การสอนโครงข่ายให้ทำการคำนวณ ข้อมูลส่งออกพร้อมกับปรับค่าน้ำหนักโดยใช้ข้อมูลนำเข้าที่ป้อนให้กับโครงข่าย โดยอาศัยกระบวนการ ทำซ้ำ (Iterative) ลักษณะการเรียนรู้ของโครงข่ายประสาทเทียมสามารถแบ่งได้เป็น 3 รูปแบบ ดังนี้

3.5.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นการเรียนรู้โดยการ กำหนดข้อมูลนำเข้าและข้อมูลส่งออก (ผลลัพธ์) ที่ต้องการให้กับโครงข่ายประสาทเทียม แล้วระบบจะ ปรับค่าน้ำหนักและค่าความเอนเอียง เพื่อให้ได้ค่าส่งออกที่ได้มีความใกล้เคียงหรือตรงกับค่าส่งออกที่ ต้องการมากที่สุด (ธนาวุฒิ ประกอบผล, 2552; Chauhan et al., 2018; Haykin, 1999, pp. 63-64; Maitanmi, Bridget, Andy, Yinka, & Onwodi, 2013; Ramesh et al., 2011) จึงจำเป็นต้อง ทราบค่าหรือรูปแบบโครงสร้างของข้อมูลส่วนหนึ่ง สำหรับใช้ในกระบวนการเรียนรู้และเป็นตัวช่วยใน การตัดสินใจต่อไป ประเด็นที่สำคัญของการเรียนรู้แบบมีผู้สอนคือ การลู่เข้าของความคลาดเคลื่อน (Error Convergence) (ศุภกานต์ พิมลธเรศ, 2553) ตัวอย่างโครงข่ายประสาทเทียมที่ใช้วิธีการ เรียนรู้แบบนี้ เช่น

3.5.1.1 โครงข่ายประสาทเทียมแบบเรียนรู้ค่าเฉลี่ยกำลังสองน้อยที่สุด (Least Mean Square Learning: LMS) คือมีขั้นตอนวิธีการเรียนรู้หรืออัลกอริทึม (Algorithm) ของ โครงข่ายที่ง่ายไม่ยุ่งยาก โดยอาศัยค่าขีดจำกัดล่างสุดของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Square Error: MSE) เป็นค่าหลักในการวิเคราะห์และตัดสินใจเพื่อการเรียนรู้ LMS โดย LMS จะใช้ ค่าเฉลี่ยรวมของค่า MSE ที่เกิดขึ้นจากชุดข้อมูลทั้งหมดที่พิจารณา ในการปรับค่าน้ำหนักของข้อมูล ซึ่งจะช่วยให้ค่าน้ำหนักในการวิเคราะห์มีความแม่นยำมากขึ้น แต่ค่า MSE ที่ใช้ใน LMS เลือกค่าที่ น้อยที่สุด เพื่อหลีกเลี่ยงการแกว่งของข้อมูลที่ส่งผลให้เกิดความไม่แน่นอนในระบบการเรียนรู้

ขั้นตอนวิธีการเรียนรู้ของ LMS เกี่ยวข้องกับการทดสอบข้อมูลและ การคำนวณหาค่าส่งออก โดยใช้ค่าคลาดเคลื่อนมาช่วยสนับสนุนในการกำหนดค่าน้ำหนัก ด้วยการ ปรับแต่งตามความเหมาะสมจากการทดสอบที่สุ่มขึ้นมา พิจารณาในส่วนของการทดสอบที่ประสบ ความสำเร็จและมีค่าคลาดเคลื่อนที่เหมาะสม การทำงานของ LMS มีลักษณะคล้ายโครงข่ายแบบ ชั้นเดียว สถาปัตยกรรมของ LMS ประกอบด้วยชั้นรับข้อมูลเข้าและชั้นส่งข้อมูลออก ไม่มีชั้นซ่อน

โดยเริ่มจากการคำนวณค่าส่งออกด้วยค่าน้ำหนักที่กำหนดหรือสุ่มขึ้นมา จากนั้นวิเคราะห์ค่าคลาดเคลื่อนที่เกิดขึ้นว่าค่า MSE อยู่ในระดับที่เหมาะสมหรือไม่ หากยังไม่เป็นที่ต้องการจะดำเนินการตามขั้นตอนแรกอีกครั้งจนกระทั่งได้ค่า MSE เป็นที่น่าพอใจ ในการคำนวณหาค่าคลาดเคลื่อนนั้นจะใช้หลักการหาค่าเฉลี่ยรวมของ MSE เป็นหลัก การทดสอบทุกครั้งจะปรับค่าน้ำหนักให้สามารถคำนวณค่าส่งออกได้ดีขึ้น ช่วยให้ค่าคลาดเคลื่อนของค่าส่งออกลดลง ดังนั้น LMS จึงเป็นวิธีที่มีประสิทธิภาพและมีขั้นตอนไม่ซับซ้อนด้วย

3.5.1.2 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation Neural Network: BPNN) บางครั้งเรียกการแพร่ย้อนกลับ (Backpropagation) เป็นวิธีการที่มีลักษณะการเรียนรู้แบบมีผู้สอน (Wahyuni et al., 2018) หากพิจารณาโดยภาพรวมแล้ววิธีการนี้จะคล้ายกับ LMS แต่ค่าน้ำหนักของ BPNN จะมีหลายระดับชั้นกว่า LMS ที่มีเพียงชั้นเดียว จึงทำให้ค่าคลาดเคลื่อนของ BPNN มี 2 ลักษณะคือ ฟังก์ชันค่าคลาดเคลื่อนที่ใช้กับชั้นส่งข้อมูลออกและฟังก์ชันค่าคลาดเคลื่อนที่ใช้กับชั้นซ่อน


BPNN เป็นขั้นตอนวิธีโครงข่ายประสาทเทียมแบบหลายชั้นที่ใช้ขั้นตอนวิธีการเรียนรู้แบบแพร่ย้อนกลับ (Backpropagation Algorithms) มีการเรียนรู้แบบมีผู้สอนและการทำงานของฟังก์ชันการแปลงไม่ใช่เชิงเส้น โดยการปรับค่าน้ำหนักในเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสม การปรับค่าจะขึ้นอยู่กับความแตกต่างของค่าผลลัพธ์ที่เป็นข้อมูลส่งออกของตัวแบบกับค่าผลลัพธ์จริง (นิภาพร ชนะมาร และพรณิ สิทธิเดช, 2557) สถาปัตยกรรมของ BPNN ประกอบด้วย 3 ชั้น ได้แก่ ชั้นรับข้อมูลเข้า ชั้นซ่อนและชั้นส่งข้อมูลออก (Wahyuni et al., 2018) ขั้นตอนวิธีการเรียนรู้ของโครงข่ายแบบ BPNN ประกอบด้วย 3 ขั้นตอนคือ 1) ขั้นตอนการคำนวณแบบป้อนไปข้างหน้าจากชั้นรับข้อมูลเข้าไปยังชั้นซ่อนและส่งไปชั้นส่งข้อมูลออกตามลำดับ 2) ขั้นตอนการคำนวณและการแทนค่ากลับของผลรวมของความคลาดเคลื่อนของผลลัพธ์ โดยทำการเปรียบเทียบความคลาดเคลื่อนของผลลัพธ์จากตัวแบบกับค่าผลลัพธ์จริง และ 3) ขั้นตอนการปรับค่าน้ำหนักและค่าความเอนเอียง กระบวนการจะดำเนินการซ้ำทั้ง 3 ขั้นตอนจนกว่าผลลัพธ์ที่ได้จะใกล้เคียงกับค่าผลลัพธ์จริง (อรอนงค์ บุเกตุ และพุทธิชาติ ศิริแสงตระกูล, 2556; Purnomo et al., 2017; Ramesh et al., 2011) ถ้าค่าความคลาดเคลื่อนอยู่ในช่วงที่ยอมรับได้ให้ทำการรับข้อมูลนำเข้าชุดถัดไป แต่ถ้าค่าความคลาดเคลื่อนมากกว่าค่าที่ยอมรับได้ให้ทำการปรับค่าน้ำหนัก และค่าความเอนเอียงใหม่เพื่อให้ข้อมูลส่งออกของตัวแบบใกล้เคียงกับค่าผลลัพธ์จริงมากที่สุด (ณัฐธา ฝิวมา, 2558) ซึ่งค่าน้ำหนักจากการเรียนรู้จะเก็บไว้ใช้อีกครั้งในขั้นตอนการทดสอบ โดยขั้นตอนการทดสอบจะไม่มี การปรับค่าน้ำหนัก ส่วนค่าความเอนเอียงในกรณีที่โครงข่ายมีจำนวนโหนดไม่เหมาะสมคือ จำนวนโหนดน้อยเกินไป การเพิ่มโหนดเข้าไปจะทำให้โครงข่ายมีประสิทธิภาพของการเรียนรู้ดีขึ้น หลังจากที่โครงข่ายได้ผ่านการเรียนรู้สามารถนำโครงข่ายไปประยุกต์ใช้งาน ขั้นตอนนี้เป็นขั้นตอนการคำนวณแบบป้อนไปข้างหน้าเพียงขั้นตอนเดียว

โดยนำค่าน้ำหนักที่ได้จากการเรียนรู้ไปประยุกต์ใช้ในงานด้านต่าง ๆ ต่อไป BPNN ถือเป็นวิธีการที่สามารถเข้าใจง่ายและมีการประยุกต์ใช้โดยทั่วไป

3.5.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการเรียนรู้ที่ไม่ได้กำหนดค่าส่งออก (ผลลัพธ์) ที่ต้องการไว้ล่วงหน้า มีเฉพาะข้อมูลนำเข้าเท่านั้น (Chauhan et al., 2018) แต่เป็นการเรียนรู้เพื่อปรับค่าน้ำหนักและความเอนเอียง เพื่อตอบสนองต่อข้อมูลนำเข้า โดยไม่ได้ใช้ค่าส่งออกร่วมด้วยในการเรียนรู้ ซึ่งการปรับค่าน้ำหนักจะใช้ชุดข้อมูลการเรียนรู้เป็นตัวปรับค่า ซึ่งค่าน้ำหนักจะปรับตามกลุ่มที่ข้อมูลนำเข้าที่มีรูปแบบคล้ายคลึงกัน ตัวอย่างโครงข่ายประสาทเทียมที่ใช้วิธีการเรียนรู้แบบนี้ เช่น

3.5.2.1 โครงข่ายประสาทเทียมที่ใช้การเรียนรู้เฮบบ์เปียล (Hebbian Learning) บางครั้งเรียกว่ากฎการเรียนรู้ของเฮบบ์ (Hebb's Rule) เป็นวิธีการหรือทฤษฎีที่เกี่ยวข้องกับการจัดกลุ่มของข้อมูล โดยใช้ต้นแบบมาจากระบบประสาทคือ เซลล์ใด ๆ ที่อยู่ใกล้กันและสามารถกระตุ้นเซลล์ที่อยู่ใกล้เคียงแบบซ้ำ ๆ ต่อเนื่องกันจนเกิดการเปลี่ยนแปลงขึ้นกับเซลล์ตนเองและเซลล์ใกล้เคียง จะถือว่าเซลล์ทั้งสองมีปฏิสัมพันธ์ที่สนับสนุนกัน ส่งผลให้ทั้งคู่สามารถเจริญเติบโตไปด้วยกันได้ ด้วยรูปแบบการกระตุ้นในลักษณะนี้เมื่อถูกนำมาใช้กับข้อมูลในระบบโครงข่ายประสาทเทียม น้ำหนักของชุดข้อมูลที่อยู่ใกล้กันจะสนับสนุนกันจนทำให้ค่าน้ำหนักของทั้งสองเพิ่มขึ้นได้ในที่สุด

วิธี Hebb's Rule จะเกี่ยวข้องกับความสัมพันธ์ของชุดข้อมูลทั้งสองที่สนับสนุนกัน ทำให้น้ำหนักของข้อมูลมีความน่าเชื่อถือมากขึ้น ช่วยให้เกิดความมั่นใจว่าค่าน้ำหนักดังกล่าวสามารถนำมาใช้งานได้อย่างมีประสิทธิภาพ แต่ละโหนดของชั้นรับข้อมูลเข้าจะเชื่อมโยงกับทุกโหนดของชั้นส่งข้อมูลออกอย่างสมบูรณ์ใน Hebb's Rule ดังนั้นการทำงานของวิธี Hebb's Rule จะขึ้นอยู่กับรูปแบบของข้อมูลนำเข้าเป็นหลัก ซึ่งเป็นการส่งข้อมูล (Mapping) ระหว่างรูปแบบข้อมูลนำเข้า (Input Pattern) กับรูปแบบการเรียกกลับหรือรูปแบบค่าส่งออก (Recalled Pattern หรือ Output Pattern) ที่สามารถกลับไปสู่รูปแบบข้อมูลนำเข้าได้ จากการพิจารณาข้อมูลที่อยู่ใกล้เคียง แต่การส่งข้อมูลดังกล่าว มีข้อเสียคือ สามารถส่งข้อมูลได้เฉพาะข้อมูลที่มีความสัมพันธ์กันในแบบตั้งฉาก (Orthogonal) เท่านั้น ผลลัพธ์ในการส่งข้อมูลด้วยวิธี Hebb's Rule แสดงดังภาพที่ 2-8



ภาพที่ 2-8 ผลลัพธ์ในการส่งข้อมูลด้วยวิธี Hebb's Rule

3.5.2.2 โครงข่ายประสาทเทียมที่ใช้การแบ่งกลุ่มข้อมูลแบบเคมีน (K-Means Clustering) เป็นวิธีการที่ได้รับความนิยมอย่างแพร่หลายสำหรับจำแนกกลุ่มในรูปแบบไม่มีผู้สอน โดยใช้ข้อมูลเวกเตอร์ (Vector Data) ที่เรียกว่าเคมีน (K-Mean) แยกกลุ่มแบบการรวมกลุ่ม (Cluster) ซึ่งให้ความสำคัญกับข้อมูลที่อยู่ตรงกลางมากกว่าบริเวณอื่นที่เรียกว่าการรวมกลุ่มเซนทรอยด์ (Cluster Centroid) ศูนย์กลางในการพิจารณาข้อมูลขึ้นอยู่กับการรวมกลุ่มของข้อมูล หากบริเวณใดมีการรวมกลุ่มของข้อมูลมากจะถูกกำหนดเป็นศูนย์กลางในการพิจารณา ส่วนข้อมูลที่อยู่ นอกเหนือจากบริเวณศูนย์กลางจะไม่นำมาพิจารณา ทุกครั้งที่มีการเปลี่ยนตำแหน่งของการรวมกลุ่ม ศูนย์กลางในการพิจารณาขอบเขตของข้อมูลจะเปลี่ยนตามเสมอ จากสาเหตุนี้สามารถสรุปได้ว่าข้อมูลเวกเตอร์มีส่วนทำให้เกิดการเปลี่ยนแปลงของศูนย์กลางได้ ซึ่งจะส่งผลต่อการเปลี่ยนแปลงของค่า น้ำหนักด้วย

หลักการทำงานของขั้นตอนวิธีการเรียนรู้แบบ K-Means Clustering เริ่มจากการกำหนดค่าข้อมูลเดี่ยว เพื่อระบุศูนย์กลางที่ต้องการพิจารณา จากนั้นจึงเริ่มพิจารณาข้อมูลที่อยู่ข้างเคียงเพื่อระบุศูนย์กลางการรวมกลุ่มของข้อมูล ทำให้ทราบถึงขอบเขตของข้อมูลที่จะต้องพิจารณา หลังจากนั้นจึงคำนวณค่า K ของศูนย์กลางอีกครั้ง หากค่าของข้อมูลยังสามารถทำให้ศูนย์กลางเกิดการเปลี่ยนแปลงได้ จะต้องกลับไปพิจารณาที่ขั้นตอนการกำหนดศูนย์กลางการรวมกลุ่มของข้อมูลอีกครั้ง จนกว่าจะได้ค่าข้อมูลที่ไม่ส่งผลต่อศูนย์กลาง การทำงานของ K-Means Clustering จึงถือว่าเป็น เสร็จสมบูรณ์ จากกระบวนการดังกล่าวแสดงให้เห็นว่า การเลือกศูนย์กลางมีความสำคัญมาก ดังนั้น

วิธีการนี้จะประสบปัญหาเกี่ยวกับการกำหนดศูนย์กลาง เนื่องจากต้องอาศัยประสบการณ์ของผู้ใช้และอาจต้องใช้เวลาานาน หากมีข้อมูลจำนวนมากรวมกลุ่มอยู่ภายในบริเวณเดียวกัน

3.5.3 การเรียนรู้แบบเชิงบังคับ (Reinforcement Learning) การเรียนรู้แบบนี้จะคล้ายคลึงกับการเรียนรู้แบบมีผู้สอน แต่มีความแตกต่างกันโดยไม่นำเสนอค่าส่งออกที่ต้องการให้กับโครงข่าย เมื่อได้ค่าส่งออกจะบอกได้ว่าถูกหรือผิด การเรียนรู้แบบนี้จะให้คะแนนความถูกต้องของโครงข่ายในรูปแบบการให้รางวัลเมื่อโครงข่ายทำงานถูกต้องและลงโทษเมื่อโครงข่ายทำงานผิดพลาด (F. S. Panchal & Panchal, 2014; Haykin, 1999, pp. 64-65; Ramesh et al., 2011) กำหนดทิศทางการเรียนรู้จากการเปลี่ยนแปลงสภาพแวดล้อม (ศุภกานต์ พิมลธเรศ, 2553; J. Kaur, & Kaur, 2018)

การเรียนรู้ของโครงข่ายประสาทเทียมที่นิยมใช้ได้แก่ การเรียนรู้แบบมีผู้สอนและการเรียนรู้แบบไม่มีผู้สอน ตัวอย่างที่มีการนำมาประยุกต์ใช้ เช่น การพยากรณ์ ซึ่งการเรียนรู้แบบมีผู้สอน BPNN เป็นโครงข่ายหนึ่งที่ตั้งอยู่ในประเภทของการพยากรณ์โดยการใช้ข้อมูลนำเข้าเพื่อพยากรณ์ผลลัพธ์ที่เป็นค่าส่งออก (Anderson & McNeill, 1992) การพยากรณ์เป็นกระบวนการสร้างรูปแบบทางคณิตศาสตร์ โดยอาศัยข้อมูลจากอดีตมาสร้างเป็นตัวแบบพยากรณ์ ส่วนวิธีการเรียนรู้แบบไม่มีผู้สอนจะใช้การจัดแบ่งกลุ่ม พิจารณาตามรูปแบบของข้อมูลนำเข้า (ธนารุณี ประกอบผล, 2552; Chauhan et al., 2018; Haykin, 1999, pp. 65-66; Ramesh et al., 2011; Uddin et al., 2015) โดยใช้วิธีการเรียนรู้จากลักษณะและความสัมพันธ์ของข้อมูลนำเข้า เพื่อจำแนกและแยกแยะข้อมูลออกเป็นกลุ่ม ๆ อาศัยเฉพาะข้อมูลดิบก็สามารถจำแนกข้อมูลที่เกี่ยวข้องได้ เป็นต้น

3.6 การประยุกต์ใช้งานโครงข่ายประสาทเทียมในสาขาวิชาต่าง ๆ โครงข่ายประสาทเทียมได้ถูกพัฒนาและนำมาประยุกต์ใช้กันอย่างแพร่หลายในด้านต่าง ๆ ทำให้มีการคิดค้นรูปแบบหรือโครงสร้างของโครงข่ายประสาทเทียมที่แตกต่างกันขึ้นมากมาย เพื่อนำไปใช้กับระบบงานที่ต้องการได้อย่างเหมาะสม ตอบสนองความต้องการหรือวัตถุประสงค์ขององค์กรหรือผู้พัฒนา จึงมีการแบ่งลักษณะงานของโครงข่ายประสาทเทียมออกเป็น 5 ประเภท นำเสนอโดยณัฐพงษ์ วาริประเสริฐ (2552, หน้า 256-257) ดังนี้

3.6.1 การคาดคะเน (Prediction) เป็นลักษณะงานที่ต้องการความสามารถในด้านการคาดการณ์หรือทำนายสถานการณ์ต่าง ๆ ที่อาจเกิดขึ้น เพื่อเป็นข้อมูลสำหรับการดำเนินงานหรือเตรียมหาวิธีป้องกัน เช่น การพยากรณ์อากาศ การวิเคราะห์ตลาดหุ้น และระบบเตือนภัยต่าง ๆ เป็นต้น

3.6.2 การจำแนก (Classification) เป็นลักษณะงานที่มีความสามารถในการคัดแยกและจำแนกกลุ่มข้อมูล โดยการระบุชนิดของข้อมูลที่ต้องการแยกออกจากกลุ่ม เนื่องจากข้อมูลภายใน

กลุ่มอาจมีความคล้ายคลึงกันมาก ทำให้ไม่สามารถแยกหรือชี้ชัดได้ว่าภายในกลุ่มนั้นมีข้อมูลที่แตกต่างกันอยู่

3.6.3 การเชื่อมโยง (Association) เป็นลักษณะการใช้งานที่ให้ความสำคัญกับการเชื่อมโยงของข้อมูล เพื่อใช้สนับสนุนการจำแนกข้อมูลที่เชื่อมโยงกันได้ง่ายขึ้นหรือใช้สนับสนุนงานด้านต่าง ๆ ที่ต้องการบ่งบอกถึงความเชื่อมโยงของข้อมูลที่ชัดเจน

3.6.4 การกลั่นกรอง (Filtering) เป็นลักษณะงานที่ต้องการความสามารถในการกลั่นกรองข้อมูล เพื่อให้ได้ข้อมูลที่ระบบต้องการเท่านั้น โดยเฉพาะข้อมูลในรูปแบบสัญญาณซึ่งอาจมีสัญญาณรบกวนสอดแทรกหรือปะปนมาจึงต้องมีการปรับให้เหลือเฉพาะข้อมูลที่แท้จริง

3.6.5 การสร้างแนวคิด (Conceptualization) เป็นลักษณะงานที่ต้องการสร้างกรอบความสัมพันธ์ระดับแนวคิดให้กับข้อมูล เพื่อจัดกลุ่มข้อมูลที่มีความสัมพันธ์กันให้อยู่ภายในกรอบเดียวกัน ช่วยให้ข้อมูลสามารถอ้างอิงถึงกันได้ ลดการกระจายตัวของข้อมูลซึ่งช่วยให้สามารถคำนวณได้ง่ายขึ้น

3.7 ประโยชน์ของโครงข่ายประสาทเทียม ชูพันธุ์ รัตนโกศา (2559, หน้า 291) และ ญัฐพงษ์ วารีประเสริฐ (2552, หน้า 259-260) อธิบายดังนี้

3.7.1 เกิดข้อผิดพลาดได้ยาก (Fault Tolerance) โครงข่ายประสาทเทียมประกอบด้วย โครงข่ายที่ใช้ประมวลผลมากมายหลายโครงข่าย ทำให้โอกาสที่เกิดข้อผิดพลาดจากการวิเคราะห์มีน้อยลง แต่ถึงแม้ว่าจะเกิดข้อผิดพลาดในการวิเคราะห์จากเพียงหนึ่งหรือสองโครงข่าย จะไม่ส่งผลทำให้ทั้งระบบเกิดข้อผิดพลาดได้

3.7.2 ความสามารถในการหาเหตุผล (Generalization) การเชื่อมโยงที่เป็นอิสระและการประมวลผลที่มีประสิทธิภาพของโครงข่ายประสาทเทียม ช่วยให้การหาเหตุผลหรือข้อสรุปเป็นไปได้อย่างราบรื่น ถึงแม้ว่าโครงข่ายได้รับข้อมูลนำเข้าที่ไม่ครบถ้วนหรือไม่เพียงพอต่อการหาข้อสรุปหรือได้รับข้อเท็จจริงที่ไม่เคยได้รับมาก่อน ระบบจะสามารถลำดับการเชื่อมโยงข้อเท็จจริงจนสามารถให้ข้อสรุปและเหตุผลได้

3.7.3 ความสามารถในการปรับเปลี่ยน (Adaptability) โครงข่ายประสาทเทียมสามารถเรียนรู้สภาพแวดล้อมใหม่ได้ ดังนั้นเมื่อมีเหตุการณ์ใหม่ ๆ เข้าสู่ระบบก็สามารถปรับเปลี่ยนหรือปรับปรุงองค์ความรู้ให้ทันสมัยตามเหตุการณ์ใหม่นั้น

3.7.4 ความสามารถในการพยากรณ์ (Forecasting Capability) โครงข่ายประสาทเทียมสามารถนำข้อมูลทางสถิติเดิมที่มีอยู่ในระบบ มาใช้คาดการณ์หรือพยากรณ์ข้อมูลในอนาคตได้ ทำให้สามารถรับรู้ปัญหาที่เกิดขึ้นและหาแนวทางแก้ไขได้ทันที่

3.7.5 โครงข่ายประสาทเทียมสามารถเรียนรู้และจดจำในลักษณะแบบแผนได้ (Pattern Recognition) ที่เป็นรูปแบบเดียวกับสมองมนุษย์ ทำให้ระบบมีการเรียนรู้ข้อมูลที่ซับซ้อนได้ จึงทำให้มีประสิทธิภาพสูงในการแปลสารสนเทศ

3.7.6 การประมวลผลสามารถคัดแยกสารสนเทศที่ไม่มีประโยชน์ออกจากระบบและเติมเต็มสารสนเทศที่มีไม่ครบถ้วนให้สมบูรณ์ได้

3.8 ข้อจำกัดของโครงข่ายประสาทเทียม ญัฐพงษ์ วารีประเสริฐ (2552, หน้า 260) อธิบายดังนี้

3.8.1 ด้วยความสามารถและประสิทธิภาพของโครงข่ายประสาทเทียม การพัฒนาจึงต้องใช้เวลาและมีความซับซ้อนมากพอสมควร ปัญหาที่มีความซับซ้อนมากเท่าใด ยิ่งต้องใช้เวลามากขึ้น ดังนั้นควรพิจารณาถึงความเหมาะสมนี้ด้วย

3.8.2 การประมวลผลจำเป็นต้องวิเคราะห์ถึงข้อมูลนำเข้า เพื่อให้เห็นถึงความสอดคล้องระหว่างข้อมูลกับปัญหา หากข้อมูลนำเข้าไม่มีความสัมพันธ์กับปัญหา ผลลัพธ์ที่ได้ก็จะไม่ใช่ผลลัพธ์ที่ดีที่สุด

3.8.3 การประมวลผลและการดำเนินการด้วยคอมพิวเตอร์ จำเป็นต้องใช้เครื่องที่มีความเร็วและประสิทธิภาพสูง เพื่อให้การประมวลผลเป็นไปอย่างที่ต้องการและใช้ระยะเวลาไม่มากเกินไป

นอกจากประโยชน์แล้วผู้พัฒนาจำเป็นต้องเข้าใจถึงข้อจำกัดของโครงข่ายประสาทเทียมด้วย ซึ่งจะช่วยให้การพัฒนาดำเนินไปได้อย่างราบรื่น รวมทั้งยังทราบถึงอุปสรรคและปัญหาเบื้องต้นที่อาจจะเกิดขึ้นหากนำโครงข่ายประสาทเทียมมาประยุกต์ใช้งาน

3.9 โครงข่ายประสาทเทียมได้มีการนำไปประยุกต์ใช้อย่างแพร่หลายในหลากหลายสาขาวิชา และสำหรับในปัจจุบันการนำโครงข่ายประสาทเทียมมาใช้มีจำนวนเพิ่มมากขึ้นด้วย เนื่องจากปัญหาที่มีความซับซ้อน (Chauhan et al., 2018) โดยพิจารณาการนำไปใช้จากวัตถุประสงค์ความต้องการ เพื่อนำไปแก้ปัญหาได้นั้น ๆ เช่น ด้านการแพทย์ ด้านธุรกิจ ด้านวิศวกรรม ด้านอุตสาหกรรม เป็นต้น มีรายละเอียดดังนี้

3.9.1 ด้านการแพทย์

นำไปใช้ในการวินิจฉัยโรคหรือนำไปใช้ในการจำลองอวัยวะต่าง ๆ ในร่างกายมนุษย์ สำหรับการวินิจฉัยโรค โครงข่ายประสาทเทียมมีส่วนสนับสนุนการทำงานในด้านการจำแนกรายละเอียดของโรคต่าง ๆ ซึ่งอาจมีพื้นฐานจากอาการที่ใกล้เคียงกันมาก ทำให้ยากต่อการตรวจและวินิจฉัย โดยใช้การเรียนรู้เพื่อเพิ่มความน่าเชื่อถือในการจำแนกข้อมูลของโรคต่าง ๆ ให้มีประสิทธิภาพและความถูกต้องมากขึ้น ระบบช่วยเหลือการวินิจฉัยนี้สามารถลดภาระของแพทย์ในการวินิจฉัยโรคได้ระดับหนึ่งและช่วยเหลือข้อมูลต่าง ๆ กับพยาบาลหรือผู้ช่วยพยาบาล ให้สามารถวินิจฉัยโรคใน

ขั้นต้นได้ พร้อมทั้งให้คำแนะนำในการรักษาโรคที่ไม่ร้ายแรง ส่งผลทำให้ผู้ป่วยได้รับการรักษาที่รวดเร็วขึ้น นอกจากนี้ยังนำมาใช้ในการสร้างตัวแบบของอวัยวะต่าง ๆ ในร่างกายมนุษย์ด้วย โดยใช้ความสามารถของโครงข่ายประสาทเทียมในการควบคุมกระบวนการวิเคราะห์ เนื่องจากอวัยวะต่าง ๆ มีความซับซ้อนมาก ทำให้การวิเคราะห์ค่าต่าง ๆ ของข้อมูลที่จำเป็นสำหรับควบคุมการทำงานของอวัยวะต้องใช้ระบบการคำนวณที่แม่นยำ เพื่อให้ตอบสนองและทำงานได้เหมือนกับอวัยวะของมนุษย์มากที่สุด การควบคุมนั้นจะต้องอาศัยความสัมพันธ์ของข้อมูลต่าง ๆ เช่น อัตราการสูดฉีดของเลือด อัตราการเต้นของหัวใจและระดับความดัน เป็นต้น

3.9.2 ด้านธุรกิจ

นำไปใช้ในการคาดคะเนหรือการทำนาย เพื่อใช้ประกอบการวิเคราะห์และช่วยตัดสินใจที่เกี่ยวข้องกับข้อมูลต่าง ๆ ทางธุรกิจ เนื่องจากธุรกิจแต่ละชนิดย่อมมีความเสี่ยงและมีปัจจัยต่าง ๆ ที่เกี่ยวข้องกับการเจริญเติบโตขององค์กรค่อนข้างมาก ทั้งการตลาด การบัญชี การผลิตและการวางกลยุทธ์ ซึ่งมีข้อมูลจำนวนมากที่เกี่ยวข้อง ถ้ายังเป็นธุรกิจขนาดใหญ่ก็ยิ่งมีความซับซ้อนและมีจำนวนข้อมูลมากขึ้นด้วย ดังนั้นจึงต้องมีระบบที่สามารถวิเคราะห์ข้อมูล เรียนรู้และวางแผน เพื่อเป็นตัวช่วยในการบริหารงานได้เป็นอย่างดี โครงข่ายประสาทเทียมจึงถูกนำมาใช้ เช่น การวิเคราะห์ความเสี่ยงในการลงทุน เพื่อแสดงให้เห็นว่าการลงทุนคุ้มค่าและให้ผลตอบแทนมากหรือน้อยเป็นที่น่าพอใจหรือไม่ สมควรแก่การลงทุนหรือไม่ เป็นต้น นอกจากนี้ยังมีปัจจัยที่สำคัญต่อการเติบโตขององค์กรคือการตลาด เพราะเป็นส่วนหนึ่งที่สามารถสร้างผลกำไรให้กับองค์กร หากมีการวางแผนการตลาดอย่างรอบคอบและมีประสิทธิภาพโดยใช้ระบบโครงข่ายประสาทเทียม ย่อมช่วยเพิ่มผลกำไรให้กับองค์กรได้อีกทางด้วย นำโครงข่ายประสาทเทียมไปใช้ในการวางแผนการตลาดหรือสนับสนุนปัจจัยต่าง ๆ ที่สำคัญต่อการตลาด เช่น การวางแผนเส้นทางการขายของพนักงานขายสินค้า ที่วิเคราะห์ต้นทุนที่จะต้องใช้ในการช่วยลดต้นทุนให้น้อยที่สุดและเพิ่มกำไรจากการขายให้มากขึ้น เป็นต้น

3.9.3 ด้านวิศวกรรม

ส่วนใหญ่นิยมนำมาใช้ในการพัฒนาหุ่นยนต์ ซึ่งได้รับความนิยมกันอย่างแพร่หลาย เนื่องจากหุ่นยนต์สามารถนำไปสนับสนุนงานในด้านต่าง ๆ ได้อย่างมากมาย เช่น การแพทย์ อุตสาหกรรมบันเทิงและการกู้ภัย เป็นต้น จากสาเหตุดังกล่าวจึงทำให้โครงข่ายประสาทเทียมเป็นส่วนสำคัญในการพัฒนาหุ่นยนต์ นอกจากนั้นโครงข่ายประสาทเทียมยังมีความสำคัญต่อวิศวกรรมสาขาต่าง ๆ อีก โดยเฉพาะที่ต้องทำงานเกี่ยวข้องกับเครื่องจักรในด้านอุตสาหกรรม เพื่อเพิ่มประสิทธิภาพและควบคุมการผลิตให้ได้จำนวนผลิตภัณฑ์มากขึ้น ลดต้นทุนและลดความผิดพลาดที่จะเกิดขึ้นให้เหลือน้อยที่สุด

3.9.4 ด้านอุตสาหกรรม

จากที่กล่าวมาข้างต้นโครงข่ายประสาทเทียมสามารถนำไปประยุกต์ใช้งานที่เกี่ยวข้องกับเครื่องจักรต่าง ๆ ได้อย่างมีประสิทธิภาพ ดังนั้นในโรงงานอุตสาหกรรมจึงจำเป็นต้องมีการควบคุมกระบวนการผลิตและการดูแลความปลอดภัยในการดำเนินงาน เพื่อลดความเสี่ยงของบุคลากรที่อาจจะประสบอุบัติเหตุจากการใช้เครื่องจักร โดยการนำหุ่นยนต์มาใช้กับเครื่องจักรภายในโรงงาน ซึ่งเป็นเทคโนโลยีที่นิยมใช้ในโรงงานอุตสาหกรรมขนาดใหญ่ที่ต้องผลิตสินค้าแข่งกับเวลา นอกจากนี้ต้องให้ความสำคัญกับการผลิตแล้วยังต้องคำนึงถึงคุณภาพของสินค้าที่ผลิตได้ ดังนั้นต้องมีการควบคุมเครื่องจักรให้มีประสิทธิภาพและมีผลลัพธ์ที่น่าเชื่อถือ โครงข่ายประสาทเทียมจะช่วยสนับสนุนการวิเคราะห์และตรวจสอบข้อมูลต่าง ๆ ที่สำคัญต่อการผลิต เพื่อรักษาคุณภาพของสินค้าให้ดียิ่งขึ้น การใช้โครงข่ายประสาทเทียมในอุตสาหกรรม เช่น ระบบควบคุมอุณหภูมิเครื่องจักร ระบบควบคุมแรงดันของถังก๊าซ ระบบตรวจสอบคุณภาพสินค้าและระบบเตือนภัยภายในโรงงาน เป็นต้น

3.10 งานวิจัยด้านต่าง ๆ ที่นำโครงข่ายประสาทเทียมประสาทเทียมมาประยุกต์ใช้

ทักษิณา คงสมลาภ และสมชาย เล็กเจริญ (2560) ศึกษาปัจจัยที่ส่งผลต่อคะแนนการประเมินคุณภาพการศึกษาภายในระดับคณะของมหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ และเพื่อสร้างรูปแบบประเมินคุณภาพการศึกษาภายใน โดยใช้เทคนิคการทำเหมืองข้อมูลมาประยุกต์ใช้ได้แก่ ต้นไม้ตัดสินใจ (Decision Tree) J48 นาอิวเบย์ (Naïve Bayes) และโครงข่ายประสาทเทียมด้วยโปรแกรม Weka เวอร์ชัน 3.9 โดยข้อมูลที่ใช้ในการศึกษาเป็นคะแนนการประเมินคุณภาพการศึกษาภายในระดับคณะประจำปีการศึกษา 2557-2558 จำนวน 6 คณะ รวมทั้งสิ้น 12 ระเบียบ ซึ่งพิจารณาจากปัจจัยคะแนน ตัวบ่งชี้เกณฑ์การประเมิน 5 องค์ประกอบ ด้วยวิธี MRA จากการวิเคราะห์ศึกษาปัจจัยพบว่า องค์ประกอบที่ 1 การผลิตบัณฑิต เป็นปัจจัยที่ส่งผลต่อคะแนนการประเมินมากที่สุดจาก 5 องค์ประกอบ รองลงมาคือ องค์ประกอบที่ 2 การวิจัย องค์ประกอบที่ 5 การบริหารจัดการ องค์ประกอบที่ 3 การบริการวิชาการ และองค์ประกอบที่ 4 การทำนุบำรุงศิลปะและวัฒนธรรม ตามลำดับ สำหรับรูปแบบประเมินคุณภาพการศึกษาภายในพบว่า รูปแบบ จำลอง ต้นไม้ตัดสินใจมีความถูกต้องเท่ากับ 91.67 และค่า MAE มีค่าเท่ากับ 0.08 รองลงมาคือ นาอิวเบย์ มีความถูกต้องเท่ากับ 91.67 และมีค่าคลาดเคลื่อนเฉลี่ยเท่ากับ 0.08 และโครงข่ายประสาทเทียมมีความถูกต้องเท่ากับ 91.67 และมีค่าคลาดเคลื่อนเฉลี่ยเท่ากับ 0.16 ตามลำดับ จะเห็นได้ว่าทั้ง 3 รูปแบบมีความถูกต้องเท่ากัน แต่ค่าคลาดเคลื่อนเฉลี่ยของต้นไม้ตัดสินใจ J48 และนาอิวเบย์มีค่าเท่ากับ 0.08 ดังนั้นผู้วิจัยจึงนำเสนอตัวแบบต้นไม้ตัดสินใจ J48 ที่มีรูปแบบที่ง่ายต่อการเข้าใจ

ธนวัฒน์ ปุญญฤทธิ์ และชุตินันท์ ศรีสวัสดิ์ (2560) ศึกษาการจำแนกภาพดอกเดหลีโดยใช้เนื้อหาภาพ เพื่อให้การระบุภาพดอกเดหลีสะดวกและง่ายขึ้น เนื่องจากดอกเดหลีมีลักษณะที่ใกล้เคียงกับดอกหน้าวัว ผู้วิจัยจึงมีแนวคิดที่จะพัฒนาระบบที่จะช่วยในการระบุภาพดอกเดหลีตระกูล

Spathiphyllum ที่มีขั้นตอนดังนี้ ขั้นที่ 1 การเก็บรวบรวมภาพและข้อมูลของดอกเดหลีพันธุ์ Spathiphyllum ขั้นที่ 2 ดำเนินการศึกษาคุณลักษณะสำคัญที่มองเห็นได้ได้แก่ คุณลักษณะสำคัญเกี่ยวกับสี (Color-based Features) คุณลักษณะเกี่ยวกับรูปร่าง (Shape-based Features) และค่าระยะห่างระหว่างจุด (Distance Between Points) ขั้นที่ 3 ศึกษาอัลกอริทึมที่ใช้ในการจำแนกประเภท และขั้นตอนสุดท้ายคือการพัฒนากระบวนการพัฒนาผลจากการศึกษาพบว่า การจำแนกดอกเดหลีได้เลือกใช้เทคนิคโครงข่ายประสาทเทียมแบบหลายชั้น ทำการทดลองจำนวน 5 ครั้ง จากภาพทั้งหมด 60 ภาพ ผลที่ดีที่สุดพบว่าคุณลักษณะสำคัญที่มองเห็นได้จากภาพที่ช่วยในการจำแนกภาพดอกเดหลีได้ดีที่สุดคือ คุณลักษณะสำคัญเกี่ยวกับสี คุณลักษณะเกี่ยวกับรูปร่างและค่าระยะห่างระหว่างจุด เท่ากับ 96.67% โดยมีจำนวนรอบในการกระทำซ้ำเท่ากับ 500 รอบ อัตราการเรียนรู้ (Learning Rate) เท่ากับ 0.5 และค่าโมเมนตัม (Momentum) เท่ากับ 0.1

สายัณห์ เทพแดง, รัฐภรณ์ พงษ์ประเสริฐ, รุจิรา จุลภักดิ์, สิริรินทร์ สว่างวรรณ และฐิติพร สังข์รัตน์ (2561) ศึกษาการแบ่งกลุ่มการเกิดอุบัติเหตุทางถนนในประเทศไทยโดยใช้วิธีการเรียนรู้แบบ K-Means ที่ใช้ข้อมูลจากบริษัทกลางคุ้มครองผู้ประสบภัยจากรถจำกัด ระหว่างปี พ.ศ. 2553 ถึง 2560 ข้อมูลที่ได้รับมีทั้งสิ้น 77 จังหวัด นำข้อมูลไปแบ่งกลุ่มโดยใช้ K-Means แบ่งเป็น 4 กลุ่ม ซึ่งพิจารณาจากจำนวนครั้งการเกิดอุบัติเหตุ จำนวนผู้เสียชีวิตและจำนวนผู้บาดเจ็บ ผลการวิจัยพบว่า กลุ่มจังหวัดที่อันตรายมากที่สุดมี 5 จังหวัดได้แก่ กรุงเทพมหานคร ชลบุรี เชียงใหม่ นครราชสีมาและ สมุทรปราการ กลุ่มนี้มีจำนวนครั้งการเกิดอุบัติเหตุมีค่า Centroid อยู่ที่ 107,942 ครั้ง จำนวนผู้เสียชีวิตมีค่า Centroid อยู่ที่ 2,999 คน จำนวนผู้บาดเจ็บมีค่า Centroid อยู่ที่ 123,609 คน กลุ่มจังหวัดอันตรายมากมี 15 จังหวัดได้แก่ ขอนแก่น เชียงราย นครปฐม เป็นต้น กลุ่มนี้มีจำนวนครั้งการเกิดอุบัติเหตุมีค่า Centroid อยู่ที่ 37,748 ครั้ง จำนวนผู้เสียชีวิตมีค่า Centroid อยู่ที่ 1,399 คน จำนวนผู้บาดเจ็บมีค่า Centroid อยู่ที่ 43,110 คน กลุ่มจังหวัดที่อันตรายปานกลางมี 32 จังหวัดได้แก่ กาญจนบุรี กาฬสินธุ์ กำแพงเพชร เป็นต้น กลุ่มนี้มีจำนวนครั้งการเกิดอุบัติเหตุมีค่า Centroid อยู่ที่ 21,744 ครั้ง จำนวนผู้เสียชีวิตมีค่า Centroid อยู่ที่ 988 คน จำนวนผู้บาดเจ็บมีค่า Centroid อยู่ที่ 24,518 คน กลุ่มสุดท้ายจังหวัดที่อันตรายน้อยมี 25 จังหวัดได้แก่ กระบี่ ชุมพร ตราด เป็นต้น กลุ่มนี้มีจำนวนครั้งการเกิดอุบัติเหตุมีค่า Centroid อยู่ที่ 10,800 ครั้ง จำนวนผู้เสียชีวิตมีค่า Centroid อยู่ที่ 502 คน จำนวนผู้บาดเจ็บมีค่า Centroid อยู่ที่ 12,375 คน ผลจากการแบ่งกลุ่มสามารถนำไปเพิ่มความเข้มงวดในการกวดขันวินัยจราจร เช่น การขับรถเร็ว เมาแล้วขับ ฝ่าฝืนสัญญาณไฟจราจรสำหรับกลุ่มที่อันตรายมากที่สุด เป็นต้น

Malek, Gunalan, Kedija, Lau, Mosleh, Milow, Amber, and Saw (2016) ศึกษาการใช้โครงข่ายประสาทเทียมเพื่อจำแนกเวลาที่ใช้สำหรับการรักษากระดูกช่วงขาที่หักในเด็ก โครงข่ายประสาทเทียมที่นำมาใช้มีการเรียนรู้แบบมีผู้สอนและไม่มีผู้สอน ข้อมูลที่ใช้เป็นภาพเอ็กซเรย์

กระดูกส่วนยาวตั้งแต่ปีค.ศ. 2009 ถึง 2011 ของกระดูกช่วงขาที่หักที่เกี่ยวข้องกับกระดูกต้นขา (Femur) กระดูกหน้าแข้ง (Tibia) กระดูกน่อง (Fibula) ของเด็กอายุ 0 ถึง 13 ปี อายุ วันที่และเวลาของการบาดเจ็บเบื้องต้น ข้อมูลได้จากศูนย์สุขภาพเด็กในมหาวิทยาลัยมาลายาเมดิคอลเซ็นเตอร์ (University Malaya Medical Centre) ข้อมูลนำเข้าได้แก่ ประเภทของการแตกหัก จุดเชื่อมต่อของการแตกหัก มุมของการแตกหัก การเคลื่อนของการแตกหักและอายุ เวลาที่ใช้สำหรับการรักษา แบ่งเป็น 2 แบบคือ น้อยกว่า 12 สัปดาห์ (เวลาในการรักษาแบบปกติ) และมากกว่า 12 สัปดาห์ (เวลาในการรักษาที่ช้ากว่าปกติ) เพื่อหาค่าความถูกต้องในการจำแนกเวลาสำหรับการรักษา โครงข่ายประสาทเทียมที่นำมาใช้มี 2 แบบคือ โครงข่ายประสาทเทียมแบบจัดกลุ่มเอง (Self-Organizing Map: SOM) และโครงข่ายประสาทเทียมแบบหลายชั้น โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า แบบมาตรฐาน (Standard Feed-Forward) โครงข่ายประสาทเทียมแบบ BPNN ที่ประกอบด้วย 3 ชั้นได้นำมาใช้ในการศึกษานี้ โดยตัวแปรที่มีความเกี่ยวข้องน้อยจะถูกกำจัดออกด้วยการใช้กลวิธีแบบย้อนกลับ (Backward Elimination Method) และตัวแปรที่มีความเกี่ยวข้องมากจะถูกนำมาใช้กับโครงข่ายประสาทเทียม พิจารณาค่าความถูกต้องจากพื้นที่ใต้กราฟ (Area Under The Curve: AUC) และค่า RMSE ผลการศึกษาพบว่า ตัวแบบโครงข่ายประสาทเทียมที่ดีที่สุดมีค่าความถูกต้องคิดเป็น 80% ค่า RMSE=0.34 และค่า AUC=0.8 สรุปได้ว่าตัวแบบโครงข่ายประสาทเทียมสามารถนำมาใช้ในการจำแนกได้จริง

Rizwan, Krishnan, Karthikeyan, and Kumar (2016) ศึกษาการควบคุมการจราจรในสถานการณ์จริง ณ เวลาที่เกิดขึ้นจริงเป็นมาตรฐานหลักของระบบการควบคุมสัญญาณไฟจราจร และการให้สัญญาณไฟจราจรที่ซับซ้อนในเมืองคือ ประเด็นที่นำมาศึกษาทดลอง วัตถุประสงค์ของงานวิจัยนี้คือ เพื่อหาและปรับเวลาของสัญญาณไฟจราจรในช่วงที่มีการจราจรหนาแน่น สถานการณ์เช่นนี้เกิดขึ้นบ่อยครั้งที่เป็นช่วงเวลาเร่งด่วนคือ ช่วงเช้าและช่วงเย็นในช่องทางขาเข้า ขณะที่ช่องทางตรงข้ามกัน (ขาออก) มีการจราจรที่หนาแน่นน้อยกว่า เพื่อเป็นการพยากรณ์และปรับเปลี่ยนเวลาของสัญญาณไฟจราจรทั้งสองช่องทางในเวลาเดียวกัน เทคนิคโครงข่ายประสาทเทียมแบบหลายชั้นถูกนำมาใช้ในงานวิจัยนี้ โดยมีการสำรวจการจราจร ณ เวลาที่เกิดขึ้นจริงของยานพาหนะทุกประเภทที่ซับซ้อนอยู่บนถนนในเมืองตัญจาวัวร์ (Thanjavur) ประเทศอินเดีย จำนวนของยานพาหนะ (จักรยาน จักรยานยนต์ รถยนต์ รถบรรทุก รถโดยสารขนาดใหญ่) และความกว้างของถนนเป็นข้อมูลนำเข้าและค่าส่งออกที่ใช้สำหรับพยากรณ์เวลาในการให้สัญญาณไฟจราจร นอกจากนี้ความกว้างของถนนยังถูกนำมาเป็นส่วนสำคัญที่ใช้สำหรับการวางแผนผังเมืองในการจราจรอีกด้วย

Tikoo and Malik (2016) ศึกษาการตรวจจับใบหน้าโดยใช้วิธีการเรียนรู้แบบ Viola Jones และการจดจำใบหน้าด้วยโครงข่ายประสาทเทียมแบบ BPNN ในช่วงไม่กี่ปีที่ผ่านมาการตรวจจับและการจดจำใบหน้าของคนเป็นปัญหาที่ซับซ้อนอย่างมาก เนื่องจากมีการนำมาใช้งานใน

พบว่า จากการทดสอบโครงข่ายประสาทเทียมที่ได้ผ่านขั้นตอนการเรียนรู้สามารถระบุได้ 100% สำหรับการระบุภาพวาดและ 84% สำหรับการระบุรูปถ่าย

Gong, Zhang, and Wang (2018) ศึกษาการใช้ตัวแบบโครงข่ายประสาทเทียมและการถดถอยโลจิสติก (Logistic Regression) เพื่อวิเคราะห์บริเวณที่สามารถเกิดดินถล่มได้ง่ายและระบุปัจจัยควบคุมหลักของการเกิดดินถล่มในลุ่มน้ำเหมยเจียง (Meijiang River Basin) ของประเทศจีนตอนใต้ โดยใช้ตัวแปร 11 ตัวแปรได้แก่ ความสูง มุมลาดชัน ความชัน ความโค้งของภูมิประเทศ ระยะห่างของรอยเลื่อนของเปลือกโลก ชนิดหิน ชนิดดิน ชนิดของการใช้ประโยชน์ที่ดิน ค่าดัชนีพืชพรรณผลต่างแบบนอร์มัลไลซ์ (Normalized Difference Vegetation Index: NDVI) ความหนาแน่นของปริมาณน้ำฝน ความยาวของแม่น้ำ เป็นปัจจัยในการสร้างแผนที่บริเวณที่สามารถเกิดดินถล่มได้ง่าย โดยใช้ตัวอย่างพื้นที่ที่เกิดดินถล่ม 384 แห่งและพื้นที่ที่ไม่เกิดดินถล่ม 380 แห่ง เป็นชุดข้อมูลการเรียนรู้ของโครงข่ายประสาทเทียมที่มีการเรียนรู้แบบแพร่ย้อนกลับและเป็นข้อมูลในการวิเคราะห์การถดถอยโลจิสติก ตรวจสอบความถูกต้องด้วยเส้นโค้งคุณลักษณะสมบัตการทำงาน (Receiver Operating Characteristic: ROC) ผลการศึกษาพบว่า โครงข่ายประสาทเทียมมีความถูกต้องของการพยากรณ์เท่ากับ 82.6% ระหว่างแผนที่บริเวณที่สามารถเกิดดินถล่มได้ง่ายและตำแหน่งของตัวอย่างพื้นที่ที่เกิดดินถล่ม 384 แห่ง ส่วนการวิเคราะห์การถดถอยโลจิสติกมีความถูกต้องเฉลี่ย 75.4% ผลการพยากรณ์ของตัวแบบโครงข่ายประสาทเทียมมีความไวสูงและมีความถูกต้องมากกว่าตัวแบบถดถอยโลจิสติก ดังนั้นตัวแบบโครงข่ายประสาทเทียมมีความถูกต้อง เมื่อใช้ประเมินบริเวณที่สามารถเกิดดินถล่มได้ง่าย ปัจจัยหลักในการควบคุมการเกิดดินถล่มถูกระบุด้วยปัจจัย 11 ประการตามรูปแบบของโครงข่ายประสาทเทียม ความชัน ชนิดหินและชนิดของการใช้ประโยชน์ที่ดิน เป็นปัจจัยควบคุมหลักในการเกิดดินถล่มในภาคใต้ของประเทศไทย

Perol, Gharbi, and Denolle (2018) ศึกษาการค้นหาแผ่นดินไหวและการหาตำแหน่งโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) เนื่องจากการเกิดแผ่นดินไหวเพิ่มมากขึ้นอย่างต่อเนื่อง การสร้างการเรียนรู้ที่มีประสิทธิภาพและน่าเชื่อถือในการค้นหาแผ่นดินไหวและการหาตำแหน่งจึงเป็นสิ่งจำเป็น ขั้นตอนทีละเอียดยุคในปัจจุบัน คือ การตรวจสอบบันทึกการเกิดแผ่นดินไหวอย่างต่อเนื่อง การค้นหาสัญญาณแผ่นดินไหว สำหรับการศึกษานี้ได้พัฒนาปัญญาประดิษฐ์ (Artificial Intelligence: AI) และนำเสนอ ConvNetQuake ซึ่งเป็นโครงข่ายประสาทเทียมที่ใช้ในการค้นหาแผ่นดินไหวและการหาตำแหน่งจากคลื่นเดี่ยว (Single Waveform) ทำการศึกษาที่รัฐโอคลาโฮมา (Oklahoma) ประเทศสหรัฐอเมริกา ซึ่งมีการค้นหาแผ่นดินไหวมากกว่า 17 ครั้ง จากการสำรวจทางธรณีวิทยาในรัฐโอคลาโฮมา ผลที่ได้คือ วิธีการเรียนรู้ที่ใช้เร็วกว่าการใช้วิธีดั้งเดิม

Porte, Isaac, Mahilang, Sonboier, and Minj (2018) ศึกษาการพยากรณ์การเปลี่ยนแปลงของกระแสน้ำและระดับน้ำใต้ดิน ซึ่งกลายเป็นองค์ประกอบสำคัญของการควบคุมระบบทรัพยากรน้ำและภารกิจที่ทำนายสำหรับวิศวกรแหล่งน้ำ โดยใช้ข้อมูลระดับน้ำใต้ดินและปริมาณน้ำฝนที่เกิดขึ้นในรอบ 20 ปี ตั้งแต่ปีค.ศ. 1996 ถึงปีค.ศ. 2015 และใช้โครงข่ายประสาทเทียมในการพยากรณ์ตัวแปรแหล่งน้ำ ตัวแบบที่ได้รับการเรียนรู้ การตรวจสอบและการทดสอบใช้ตัวอย่างแบบสุ่ม การวิเคราะห์ถดถอยแสดงความสัมพันธ์ที่กระหว่างข้อมูลอยู่ในช่วง 0.12 ถึง 0.97 การประเมินผลการทำงานของโครงข่ายประสาทเทียมมีค่าสัมประสิทธิ์สหสัมพันธ์เท่ากับ 0.9781 ระหว่างการเรียนรู้เดือนมีนาคม เมษายน พฤษภาคม ดังนั้นจึงสามารถสรุปได้ว่า โครงข่ายประสาทเทียมเป็นวิธีที่สามารถนำไปใช้ในการพยากรณ์ระดับน้ำใต้ดินในเมืองไรปุระ (Raipur) ของรัฐฉัตตีสครห์ (Chhattisgarh)

Putra, Nurhidayat, and Wicaksono (2018) ศึกษาการทำงานของโครงข่ายประสาทเทียมเพื่อกำหนดนักศึกษาใหม่ของมหาวิทยาลัย การรับเข้าศึกษาใหม่ของมหาวิทยาลัย Universitas Negeri Surabaya (Unesa) คือการรับนักศึกษาเข้าศึกษาที่มหาวิทยาลัยแห่งชาติอินโดนีเซีย ซึ่งถือเป็นเส้นทางการเข้าศึกษาที่นิยมมากสำหรับนักเรียนระดับมัธยมศึกษาหรืออาชีวศึกษาที่ต้องการศึกษาที่ Unesa จึงทำให้มีจำนวนผู้สมัครเรียนที่มหาวิทยาลัยแห่งนี้มากถึงหนึ่งหมื่นคนทุกปี ผู้สมัครจำนวนมากทำให้กระบวนการคัดเลือกมีความซับซ้อนมากขึ้น การศึกษานี้กล่าวถึงการใช้การเรียนรู้แบบมีผู้สอนของโครงข่ายประสาทเทียมแบบหลายชั้น เพื่อคัดเลือกนักศึกษาใหม่ของมหาวิทยาลัย ผลการศึกษาพบว่า การใช้โครงข่ายประสาทเทียมมีความถูกต้องแม่นยำสูง (ร้อยละ 89.56) แสดงถึงความถูกต้องที่เพียงพอสำหรับการตัดสินใจว่าผู้สมัครจะผ่านหรือไม่ผ่าน ในการเข้าศึกษาในสถานศึกษาระดับชาติ ระบบนี้สามารถใช้ในการพยากรณ์สำหรับปีต่อ ๆ ไป

Rehman, Ur Rehman, Babar, Qadeer, and Seelro (2018) ศึกษาการจดจำและการตรวจสอบลายเซ็นแบบออฟไลน์ (Offline) โดยใช้โครงข่ายประสาทเทียม ปัจจุบันนี้มีการนำเทคโนโลยีทางวิทยาศาสตร์มาใช้อย่างมากมาย เพื่อระบุตัวตนของบุคคล เทคนิคเหล่านี้ได้แก่ การจดจำดวงตา การจดจำใบหน้า การจดจำลายนิ้วมือ การจดจำและตรวจสอบลายเซ็น การใช้ลายเซ็นอาจมีความเกี่ยวข้องกับกฎหมายและเอกสารธุรกรรมทางการเงิน ส่วนการตรวจสอบลายเซ็นกลายเป็นสิ่งจำเป็นเพื่อแยกแยะระหว่างลายเซ็นจริงกับปลอม การตรวจสอบลายเซ็นสามารถทำได้ทั้งแบบออฟไลน์และแบบออนไลน์ (Online) ภายใต้ระบบออฟไลน์ลายเซ็นจะถูกนำมาใช้เป็นลักษณะรูปภาพและการจดจำจะใช้เทคนิคโครงข่ายประสาทเทียม การวิจัยนี้ทำการทดสอบการจดจำและการตรวจสอบลายเซ็นแบบออฟไลน์ (Signature Recognition and Verification System: SRVS) ที่ใช้โครงข่ายประสาทเทียม ซึ่งลายเซ็นจะนำมาเป็นภาพลายเซ็นและภายหลังจากการคัดแยกคุณลักษณะเด่นที่สำคัญ การเรียนรู้เริ่มขึ้นในการเก็บตัวอย่างครั้งแรกเพื่อหาลายเซ็นจริง โดยใช้โปรแกรม

Matlab การทดสอบใช้ลายเซ็นจากการสแกนจากหลายภาพ ผลที่ได้เป็นที่น่าพอใจ (สำเร็จประมาณ 95%) นอกจากนี้คุณภาพของภาพมีบทบาทสำคัญ เนื่องจากถ้าภาพมีคุณภาพไม่ดีอาจนำไปสู่ความล้มเหลวในการตรวจสอบหรือการจดจำลักษณะของลายเซ็นได้

Reno, Mosca, Marani, Nitti, D’Orazio, and Stella (2018) ศึกษาการตรวจจับลูกเทนนิสในสนามโดยใช้โครงข่ายประสาทเทียมแบบ CNN ในช่วงไม่กี่ปีที่ผ่านมาการวิจัยเกี่ยวกับวิดีโอกีฬาได้รับความสนใจอย่างต่อเนื่อง ข้อมูลวิดีโอจำนวนมากจากการแพร่ภาพกระจายเสียงและจากการตั้งค่ากล้อง และความต้องการข้อมูลที่มีความหมายจากข้อมูลเป็นความท้าทายในการวิจัยที่สำคัญ ดังนั้นการมองเห็นคอมพิวเตอร์และการเรียนรู้ด้วยเครื่องเป็นสิ่งสำคัญสำหรับการประมวลผลข้อมูลขนาดใหญ่ในวงการกีฬาโดยอัตโนมัติหรือกึ่งอัตโนมัติ แม้ว่ากีฬาจะมีความหลากหลายเพียงพอก็จะนำเสนอความท้าทายที่เป็นเอกลักษณ์ด้วยตัวเอง แต่ส่วนใหญ่มีความจำเป็นในการระบุตำแหน่งที่ใช้งานอยู่เช่นลูกบอลหรือผู้เล่น ในบทความนี้จะนำเสนอแนวทางการเรียนรู้ที่ลึกซึ้งในการระบุตัวลูกบอลในบริบทเทนนิส งานนี้ใช้ประโยชน์จากความสามารถในการจำแนกประเภทของโครงข่ายประสาทเทียมเพื่อตัดสินว่าลูกบอลอยู่ในกรอบเดียวหรือไม่ สามารถเอาชนะปัญหาทั่วไปที่อาจเกิดขึ้นกับวิธีการแบบเดิมในลำดับวิดีโอที่ยาวนานได้ (เช่น การเปลี่ยนแปลงการส่องสว่าง การทดลองข้อมูลจริง พิสูจน์ความถูกต้องของวิธีการที่นำเสนอซึ่งบรรลุความถูกต้อง 98.77% และแนะนำการใช้และการรวมเข้าด้วยกันในระบบที่มีความซับซ้อนมากขึ้น

3.11 งานวิจัยที่เกี่ยวข้องกับตัวแบบพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม

Asadi et al. (2013) ศึกษาการพยากรณ์ปริมาณน้ำฝนด้วยตัวแบบพยากรณ์ที่ใช้วิธีใหม่ในการสร้างตัวแบบ วิธีที่ใช้ได้แก่ วิธีโครงข่ายประสาทเทียมแบบ FFNN ด้วยการเรียนรู้แบบ LM ร่วมกับวิธี GA ร่วมกับวิธีการวิเคราะห์การถดถอย (Regression Analysis: RA) ที่ใช้วิธี Stepwise ร่วมกับการแบ่งชุดข้อมูลแบบ K-means โดยขั้นตอนการสร้างตัวแบบพยากรณ์ดังนี้ ใช้วิธี RA เพื่อคัดเลือกตัวแปรนำเข้าไปกับโครงข่ายประสาทเทียม จากนั้นแบ่งกลุ่มข้อมูลนำเข้าไปด้วยวิธีแบ่งกลุ่มข้อมูลแบบ K-means กำหนดค่าน้ำหนักเริ่มต้นของโครงข่ายประสาทเทียมด้วยวิธี GA มีขั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ LM ผลที่ได้คือตัวแบบพยากรณ์ปริมาณน้ำฝนที่ใช้วิธีใหม่มีความแม่นยำและรวดเร็วมากกว่าการใช้ระบบอนุมานนิเวศที่ปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS) ที่ใช้โครงข่ายประสาทเทียมร่วมกับวิธีฟัซซีลอจิก (Fuzzy Logic) โดยพิจารณาจากความแม่นยำจากค่า RMSE และค่า R^2

Kumar and Yadav (2013) ศึกษาตัวแบบพยากรณ์ปริมาณน้ำฝนที่ใช้โครงข่ายประสาทเทียมแบบ FFNN ด้วยวิธีการเรียนรู้ที่พัฒนาจาก Levenberg Marquardt Back Propagation Algorithm และจากนั้นพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า R^2 ผล

การศึกษาพบว่าตัวแบบที่พัฒนาขึ้นมีประสิทธิภาพสำหรับนำไปคำนวณและมีความแม่นยำ พิจารณาได้จากค่า $R^2 = 0.9858$

Dubey (2015) ศึกษาการพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมที่มีวิธีการเรียนรู้ที่แตกต่างกัน 3 แบบได้แก่ วิธีการเรียนรู้แบบมีการป้อนไปเวียนกลับ (Recurrent Algorithm) วิธีการเรียนรู้แบบป้อนไปข้างหน้า และวิธีการเรียนรู้แบบแพร่ย้อนกลับแบบป้อนไปข้างหน้า (Feed-forward Back propagation Algorithm) ผลการศึกษาพบว่าวิธีการเรียนรู้แบบป้อนไปข้างหน้าให้ความแม่นยำของตัวแบบพยากรณ์มากที่สุด ได้ค่า MSE = .0083

Mislan et al. (2015) ศึกษาการสร้างตัวแบบพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมด้วยการเรียนรู้แบบแพร่ย้อนกลับ ทดสอบความแม่นยำของตัวแบบพยากรณ์โดยใช้จำนวนชั้นซ่อน 2 ชั้นที่มีจำนวนรอบการกระทำซ้ำแตกต่างกันเป็น 500 รอบ 1000 รอบ และ 1500 รอบ ผลการศึกษาพบว่า รูปแบบโครงสร้างของตัวแบบพยากรณ์ที่มีความแม่นยำมากที่สุดคือ 2-50-20-1 จำนวนรอบการกระทำซ้ำเท่ากับ 1000 รอบ ได้ค่า MSE = 0.00096341

Chanklan et al. (2017) ศึกษาความสัมพันธ์ระหว่างข้อมูลดาวเทียมซึ่งข้อมูลเป็นดัชนีพืชพรรณ (Vegetation Index) กับข้อมูลภาคพื้นดินเป็นปริมาณน้ำฝน จากนั้นทำเหมืองข้อมูลโดยใช้โครงข่ายประสาทเทียม เพื่อสร้างตัวแบบพยากรณ์ปริมาณน้ำฝนแบบรายปี ตัวแบบพยากรณ์นี้คาดว่าจะประโยชน์ในการเฝ้าระวังการเกิดความแห้งแล้ง งานวิจัยนี้สำรวจข้อมูลระยะไกล คือค่า NDVI ที่ได้ข้อมูลมาจากดาวเทียม NOAA สำหรับข้อมูลภาคพื้นใช้ข้อมูลปริมาณน้ำฝนของจังหวัดนครราชสีมาตั้งแต่ปีค.ศ. 2005-2014 ได้ข้อมูลมาจากกรมอุตุนิยมวิทยาของประเทศไทย วิเคราะห์ความสัมพันธ์ระหว่าง NDVI และปริมาณน้ำฝนด้วยค่า R ผลการศึกษาพบว่า มีค่า R ในทิศทางบวกในช่วงระยะเวลา 1 เดือน ช่วงเดือนมิถุนายน-กันยายน มีค่าความสัมพันธ์สูงโดยเฉลี่ย $R=0.715$ จากนั้นสร้างตัวแบบพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมที่มี NDVI และปริมาณน้ำฝนเป็นพารามิเตอร์นำเข้าพร้อมกัน เปรียบเทียบกับที่มี NDVI เป็นพารามิเตอร์นำเข้าเพียงอย่างเดียว โดยพิจารณาค่าความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝนจากค่า RMSE ผลการศึกษาพบว่า การใช้การสำรวจข้อมูลระยะไกล NDVI พร้อมกับข้อมูลปริมาณน้ำฝนภาคพื้นดิน ให้ค่าความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียม เพื่อพยากรณ์ปริมาณน้ำฝนแบบรายปีในอนาคตได้ดีกว่า

Purnomo et al. (2017) ศึกษาการพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมแบบหลายชั้นด้วยการเรียนรู้แบบแพร่ย้อนกลับ งานวิจัยนี้เป็นการพยากรณ์ปริมาณน้ำฝนแบบรายเดือน 2 สถานีคือ Ampel และ Boyolali ตั้งแต่ปีค.ศ. 2001-2013 ซึ่งงานวิจัยนี้สร้างตัวแบบ 2 แบบ คือ 1. ตัวแบบที่ใช้เดือนเดียวกันเป็นข้อมูลนำเข้า และเป็นข้อมูลส่งออก เช่น การพยากรณ์เดือนธันวาคมปีค.ศ. 2016 ใช้ข้อมูลนำเข้าเป็นข้อมูลเดือนธันวาคมของปีค.ศ. 2015, 2014, 2013 และ

อื่น ๆ จากนั้นกำหนดจำนวนโหนดของชั้นซ่อนเท่ากับจำนวนโหนดของชั้นรับข้อมูลเข้า และ 2. ตัวแบบที่ใช้เดือนเดียวกัน และเดือนที่ต่างกันแต่เป็นปีที่มีน้อยกว่าอยู่ 1 ปี เป็นข้อมูลนำเข้า เช่น การพยากรณ์ปริมาณน้ำฝนเดือนธันวาคมปีค.ศ. 2016 ใช้ข้อมูลนำเข้าเป็นเดือนธันวาคมปีค.ศ. 2015, 2014, 2013 และอื่นๆ และเดือนพฤศจิกายนปีค.ศ. 2015, เดือนตุลาคมปีค.ศ. 2015, เดือนกันยายนปีค.ศ. 2015 และอื่น ๆ สร้างตัวแบบด้วยโปรแกรม Matlab R2009a ผลการวิจัยพบว่าตัวแบบที่ 1 ดีกว่าตัวแบบที่ 2 มีค่าความแม่นยำเฉลี่ยของตัวแบบที่ 1 มากกว่า 98% ส่วนตัวแบบที่ 2 มีค่าประมาณ 75% ตัวแบบที่ 1 มีค่า MSE ดีกว่าตัวแบบที่ 2 อยู่ 20 เท่า นอกจากนี้ตัวแบบทั้ง 2 มีแนวโน้มที่จะสามารถนำมาใช้พยากรณ์ได้อย่างแม่นยำมากขึ้น เมื่อความแปรปรวนของปริมาณน้ำฝนอยู่ในเกณฑ์ต่ำ

Samhitha and Srikanth (2017) ศึกษาเกี่ยวกับการประเมิน และการพยากรณ์ปริมาณน้ำฝนในอนาคตโดยใช้วิธี Inverse Distance Weighting (IDW) ร่วมกับโครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบแพร่ย้อนกลับ พื้นที่ที่ใช้ในการศึกษา คือลุ่มแม่น้ำ Ponnaiyar ซึ่งไหลผ่านรัฐทมิฬนาฑู (Tamilnadu) รัฐอานธรประเทศ (Andhra Pradesh) และรัฐकर्ณาฏกะ (Karnataka) ซึ่งวิธี IDW ทำหน้าที่ในการหาชุดข้อมูลปริมาณน้ำฝน อุณหภูมิต่ำสุด และอุณหภูมิสูงสุดชุดใหม่จากข้อมูลนำเข้าที่ทราบแล้ว (Know Data) เพื่อตรวจสอบความแม่นยำ (Validation) ของตัวแบบพยากรณ์ปริมาณน้ำฝนโดยใช้ข้อมูล 5 ปีตั้งแต่ปีค.ศ. 2012-2016 ผลที่ได้คือ ปริมาณน้ำฝนเฉลี่ย อุณหภูมิต่ำสุด และอุณหภูมิสูงสุดเท่ากับ 1528 มม. 21.1°C และ 38.1°C ตามลำดับ ตัวแบบพยากรณ์ปริมาณน้ำฝนที่ใช้โครงข่ายประสาทเทียมถูกนำมาใช้ในการพยากรณ์ปริมาณน้ำฝนหลังจากที่ผ่านขั้นตอนการเรียนรู้แล้ว พิจารณาค่าความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝนจากค่า MSE จากผลการศึกษาสามารถสรุปได้ว่าโครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบแพร่ย้อนกลับมีความเหมาะสม สมที่สุุดที่จะนำมาใช้ในการสร้างตัวแบบพยากรณ์ปริมาณน้ำฝน

Wahyuni et al. (2018) ศึกษาเกี่ยวกับการพยากรณ์ปริมาณน้ำฝนโดยการใช้โครงข่ายประสาทเทียมด้วยวิธีแบบแพร่ย้อนกลับ การใช้วิธีนี้ให้ผลการพยากรณ์ที่ดีเนื่องจากวิธีการแบบแพร่ย้อนกลับจะมีการปรับค่าน้ำหนักของเส้นเชื่อมในทุกรอบ ๆ ที่ทำการเรียนรู้ เพื่อให้ค่าที่เข้าใกล้ค่าน้ำหนักที่เหมาะสมหรือที่ควรจะเป็น ดังนั้นจึงทำให้มีค่าคลาดเคลื่อนน้อยที่สุด จึงสามารถรับรองได้ว่าวิธีนี้เป็นวิธีที่ดี งานวิจัยนี้ใช้โครงข่ายประสาทเทียมแบบหลายชั้น ที่มีลักษณะ 4-5-3 คือจำนวน 4 โหนดในชั้นรับข้อมูลเข้า 5 โหนดในชั้นซ่อน และ 3 โหนดในชั้นส่งข้อมูลออก โดยใช้ข้อมูลของตัวแปรนำเข้าได้แก่ อุณหภูมิอากาศ ความชื้นในอากาศ (Air Humidity) ความเร็วลม และรังสีดวงอาทิตย์ สำหรับข้อมูลของตัวแปรส่งออก ได้แก่ ปริมาณน้ำฝนน้อย (0-200 มม.) ปานกลาง (201-400 มม.) มาก (มากกว่า 400 มม.) ซึ่งข้อมูลเหล่านี้ถูกนำมาจากกรมอุตุนิยมวิทยาของประเทศญี่ปุ่น ผลงานวิจัยพบว่า โครงข่ายประสาทเทียมแบบหลายชั้นสามารถนำมาใช้ในการพยากรณ์ปริมาณน้ำฝน

ได้อย่างเหมาะสม การสร้างตัวแบบพยากรณ์ในงานวิจัยนี้ใช้โปรแกรม Java มีจำนวนรอบการกระทำซ้ำเป็น 1500 รอบ ผลการพยากรณ์โดยใช้ตัวแบบพยากรณ์ปริมาณน้ำฝนนี้เหมือนกับผลที่ได้จากการคำนวณด้วยมือ

3.12 งานวิจัยที่เกี่ยวข้องกับตัวแบบพยากรณ์รูปแบบอื่น ๆ โดยใช้โครงข่ายประสาทเทียม

อัทพล คุณเลิศ และพुरुชดี ศิริแสงตระกูล (2557) ศึกษาปัจจัยที่มีผลต่อปริมาณผลผลิตข้าว เพื่อการสร้างตัวแบบการพยากรณ์ปริมาณผลผลิตข้าว โดยรวบรวมข้อมูลการเพาะปลูกข้าวจากศูนย์วิจัยข้าว 11 ศูนย์ทั่วประเทศผ่านกระบวนการคัดเลือกปัจจัยด้วยวิธี MRA แบบ Stepwise ผลการศึกษาพบว่า มี 11 ปัจจัยที่มีผลกับปริมาณผลผลิตข้าว ประกอบด้วย พันธุ์ข้าว เดือนที่ปลูก เดือนที่ออกรวง ชนิดดิน อุณหภูมิเฉลี่ยช่วงเดือนที่ 1,3,4,5 ของการปลูกข้าว ปริมาณน้ำฝนเฉลี่ยช่วงเดือนที่ 2,4,5 ของการปลูกข้าว ปัจจัยเหล่านี้ถูกนำมาใช้ในการสร้างตัวแบบเพื่อพยากรณ์ผลผลิตข้าวด้วยเทคนิคโครงข่ายประสาทเทียมที่มีกระบวนการเรียนรู้แบบแพร่ย้อนกลับ และเปรียบเทียบตัวแบบจากเทคนิคโครงข่ายประสาทเทียมกับวิธี MRA ผลการทดสอบพบว่าตัวแบบการพยากรณ์ด้วยเทคนิคโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับมีประสิทธิภาพในการพยากรณ์สูงกว่าตัวแบบที่ใช้วิธี MRA ซึ่งมีค่า RMSE เท่ากับ 0.0951 และ 0.1273 ตามลำดับ

ยุพิน ไชยสมภาร และทวิ ชัยพิมลผลิน (2560) ศึกษาการพยากรณ์ระดับน้ำโดยใช้ข้อมูลน้ำฝนจากตัวแบบ WRF-ECHAM5 (Weather Research and Forecasting-ECHAM5) เป็นข้อมูลนำเข้าสำหรับการพยากรณ์ โดยใช้ตัวแบบโครงข่ายประสาทเทียม ซึ่งได้ใช้เหตุการณ์น้ำท่วมในช่วงค.ศ. 1980-2006 เพื่อศึกษาหาโครงสร้างสถาปัตยกรรมของตัวแบบที่เหมาะสมสำหรับการพยากรณ์ มีการเปรียบเทียบกระบวนการเรียนรู้แบบ LM และ Bayesian Regularization (BR) และการกำหนดจำนวนโหนดในชั้นซ่อนที่แตกต่างกัน ซึ่งอ้างอิงตามจำนวนตัวแปรของข้อมูลนำเข้า (50%, n, n+50% และ 2n) รวมทั้งมีการเปรียบเทียบประเภทของข้อมูลนำเข้าระหว่างการใช้น้ำฝนจากกริด (Grid) และค่าน้ำฝนที่ได้ทำการหาค่าเฉลี่ยแบบเคลื่อนที่ ผลการวิจัยพบว่าโครงสร้างสถาปัตยกรรมของตัวแบบโครงข่ายประสาทเทียมที่เหมาะสมคือ การเรียนรู้แบบ LM และจำนวนโหนดในชั้นซ่อนควรกำหนด 50% ของจำนวนข้อมูลนำเข้าและพบว่าการนำค่าน้ำฝนมาหาค่าเฉลี่ยแบบเคลื่อนที่ ให้ผลการพยากรณ์ได้ดีกว่าการใช้น้ำฝนจากกริดรวมกับการหาค่าเฉลี่ยแบบเคลื่อนที่

พิชญากร เลค (2561) ศึกษาการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินต่างประเทศ โดยใช้การวิเคราะห์อนุกรมเวลา ด้วยเทคนิคเหมือนข้อมูล 3 เทคนิคได้แก่ ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย การถดถอยเชิงเส้น และตัวแบบโครงข่ายประสาทเทียมแบบหลายชั้น เพื่อวางแผนในภาคธุรกิจและพัฒนาเศรษฐกิจของประเทศ โดยข้อมูลที่นำมาใช้เป็นข้อมูลอัตราแลกเปลี่ยนสกุลเงินต่างประเทศประจำปี พ.ศ. 2552-2560 จำนวน 108 เดือน ผลการศึกษาพบว่า ตัวแบบที่มีความ

เหมาะสมในการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินต่างประเทศได้แก่ สกุลเงินดอลลาร์ สกุลเงินปอนด์ สเตอริง สกุลเงิน ยูโร สกุลเงินเยนและสกุลเงินหยวน เรนมินบิ ตัวแบบที่มีความเหมาะสมกับอัตราแลกเปลี่ยนสกุลเงินต่างประเทศที่มีค่าความแม่นยำมากที่สุดคือ 1) ตัวแบบพยากรณ์ด้วยซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย เหมาะสมมากที่สุดกับชุดข้อมูลสกุลเงินดอลลาร์ สกุลเงินยูโรและ สกุลเงินเยน มีความแม่นยำมากที่สุดเท่ากับร้อยละ 2.43 ร้อยละ 1.39 และร้อยละ 2.57 ของค่าเฉลี่ยความคลาดเคลื่อนสัมพัทธ์ตามลำดับ 2) ตัวแบบถดถอยเชิงเส้นเหมาะสมมากที่สุดกับชุดข้อมูลสกุลเงินปอนด์สเตอริง มีค่าความแม่นยำมากที่สุดเท่ากับร้อยละ 0.64 ของค่าเฉลี่ยความคลาดเคลื่อนสัมพัทธ์ และ 3) ตัวแบบโครงข่ายประสาทเทียมแบบหลายชั้น เหมาะสมมากที่สุดกับชุดข้อมูลสกุลเงินหยวน เรนมินบิ มีค่าความแม่นยำมากที่สุดเท่ากับร้อยละ 0.97 ของค่าเฉลี่ยความคลาดเคลื่อนสัมพัทธ์

Yan (2015) ศึกษาการสร้างตัวแบบพยากรณ์แบบโครงข่ายประสาทเทียมแบบ BPNN เพื่อทดสอบผลของการใช้โครงข่ายประสาทเทียมแบบ BPNN จากนั้นนำตัวแบบมาใช้ในการพยากรณ์ค่าดัชนีความปลอดภัยในอาหาร (The Food Safety Index) โดยนำวิธี GA มาใช้ในการหาค่าน้ำหนักเริ่มต้นของโครงข่ายประสาทเทียมแบบ BPNN ทำการวิเคราะห์ผลแบบทฤษฎี พบว่าผลการวิจัยพิสูจน์ให้เห็นว่าการพยากรณ์แบบโครงข่ายประสาทเทียมแบบ BPNN เป็นสิ่งที่เหมาะสมสำหรับค่าดัชนีความปลอดภัยในอาหาร การพยากรณ์ค่าดัชนีความปลอดภัยในอาหาร เมื่อนำตัวแบบพยากรณ์ไปเปรียบเทียบกับโครงข่ายประสาทเทียมแบบ BPNN ที่ไม่ได้ใช้วิธี GA ร่วมด้วย ซึ่งวิธีที่ใช้ในงานวิจัยนี้ให้ค่าความแม่นยำมากกว่า

Lee et al. (2016) ศึกษาการพยากรณ์เกี่ยวกับยูงโดยใช้โครงข่ายประสาทเทียม เนื่องจากการพยากรณ์เกี่ยวกับยูงเป็นสิ่งที่สำคัญมากสำหรับการจัดการด้านความปลอดภัย และสุขภาพของมนุษย์ แต่การประมาณค่าของยูงที่เพิ่มมากขึ้นมีความไม่แน่นอน เพราะมีความผันแปรมาก งานวิจัยนี้จึงจะพัฒนาการพยากรณ์เกี่ยวกับยูงให้มีความง่าย และดีขึ้น คณะผู้วิจัยทำการทดสอบประสิทธิภาพของตัวแบบที่ใช้โครงข่ายประสาทเทียมซึ่งเป็นที่ยอมรับในการพยากรณ์เกี่ยวกับยูง พร้อมทั้งนำตัวแบบที่ได้ไปเปรียบเทียบกับตัวแบบที่ใช้ MLR ที่ได้มีการพัฒนาขึ้นมาเช่นกัน ตัวแบบทั้ง 2 แบบถูกนำมาใช้เพื่อประเมินปริมาณของยูงใน 2 ปี บริเวณพื้นที่ยองดิงโป (Yeongdeungpo-gu) กรุงโซล (Seoul) ประเทศเกาหลีใต้ (South Korea) ตัวแปรนำเข้าใช้ข้อมูลอุณหภูมิตามฤดูกาล, ความเร็วลม, ความชื้น และหยาดน้ำฟ้า (Precipitation) ผลที่ได้แสดงให้เห็นว่าศักยภาพของตัวแบบที่ใช้โครงข่ายประสาทเทียม และวิธี MLR มีความใกล้เคียงกันมาก เมื่อพิจารณาจากค่า R และค่า RMSE ตัวแบบที่ใช้โครงข่ายประสาทเทียมสามารถพยากรณ์ได้เมื่อมีความแปรปรวนสูงเมื่อเทียบกับวิธี MLR นอกจากนี้ตัวแบบที่ใช้โครงข่ายประสาทเทียมยังแสดงให้เห็นถึงความสัมพันธ์ระหว่างตัวแปรนำเข้ากับปริมาณยูงได้ดีกว่า

Wang et al. (2017) ศึกษาเกี่ยวกับการใช้โครงข่ายประสาทเทียมที่ถูกปรับค่าให้เหมาะสมโดยใช้วิธี GA เพื่อสร้างตัวแบบพยากรณ์แรงงอ (Bending Force) ในการวัดเหล็กอ่อนชนิดม้วน ข้อมูลที่ใช้ในการพยากรณ์รวบรวมจากโรงงานผลิตเหล็ก ซึ่งถูกคัดเลือกมาเป็นตัวแปรนำเข้า และใช้โปรแกรม Matlab ในการสร้างตัวแบบ GA-ANN โดยวิธี GA นำมาใช้เพื่อหาค่าน้ำหนักเริ่มต้น และค่าความเอนเอียงของโครงข่ายประสาทเทียมแบบ BPNN การประเมินศักยภาพของตัวแบบพยากรณ์พิจารณาจากค่า MAPE ค่า MAE ค่า RMSE และค่า R ผลการพยากรณ์ที่ได้จะนำมาเปรียบเทียบกับค่าที่ได้จากการวัด เพื่อหาค่าความแม่นยำของตัวแบบ GA-ANN สถาปัตยกรรมโครงข่ายประสาทเทียมที่ใช้ในการเรียนรู้ คือ 9-11-1 จากผลการศึกษาพบว่าประสิทธิภาพของตัวแบบ GA-ANN ที่ดีที่สุดมีค่า MAE=0.01 และค่า R=0.983 นอกจากนี้ตัวแบบ GA-ANN ยังสามารถนำไปปรับใช้กับสถานการณ์อื่น ๆ ได้อีกด้วย

Akbar et al. (2018) ศึกษาเกี่ยวกับการหาค่าที่เหมาะสม และการพยากรณ์ผลผลิตของน้ำมันหอมระเหยที่ทำจากขมิ้นในเมืองเกษตรกรรมต่าง ๆ ของประเทศอินเดีย น้ำมันหอมระเหยที่ทำจากขมิ้นมีประโยชน์ต่อระบบเผาผลาญและยังมีคุณสมบัติเพิ่มเติมอีกหลายประการ เช่น สามารถช่วยป้องกันแมลง ช่วยในเรื่องระบบย่อยอาหาร เป็นต้น น้ำมันหอมระเหยเหล่านี้จึงมีมูลค่าต่ออุตสาหกรรมยา และเครื่องสำอางเป็นอย่างมาก โครงข่ายประสาทเทียมถือเป็นพื้นฐานในการสร้างตัวแบบพยากรณ์ที่ถูกพัฒนาขึ้นโดยใช้ข้อมูลของน้ำมันหอมระเหยที่ทำจากขมิ้น 131 ชนิด ที่รวบรวมมาจากเมืองทั้ง 8 ของรัฐโอริสสา (Odisha) มีการวิเคราะห์ดิน และปัจจัยด้านสิ่งแวดล้อมของเมืองเหล่านั้น แต่ละเมืองมี 11 พารามิเตอร์ที่ถูกนำมาใช้ในขั้นตอนการเรียนรู้ และการทดสอบในตัวแบบโครงข่ายประสาทเทียม ผลการศึกษาแสดงให้เห็นว่าโครงข่ายประสาทเทียมแบบหลายชั้นแบบ FFNN มีทั้งสิ้น 12 โหนด ให้ค่าที่เหมาะสมที่สุด และเป็นตัวแบบพยากรณ์ที่เหมาะสมที่สุด เมื่อพิจารณาจากค่า $R^2 = 0.88$ นอกจากนี้ยังแสดงให้เห็นว่าตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมเป็นตัวแบบที่เหมาะสมสามารถนำมาใช้สำหรับการพยากรณ์ผลผลิตของน้ำมันหอมระเหยที่ทำจากขมิ้น ซึ่งจะส่งผลดีต่อด้านการค้าอีกด้วย

จากการศึกษางานวิจัยที่เกี่ยวข้องกับตัวแบบพยากรณ์ปริมาณน้ำฝนและงานวิจัยที่เกี่ยวข้องกับตัวแบบพยากรณ์รูปแบบอื่น ๆ โดยใช้โครงข่ายประสาทเทียมพบว่า ตัวแบบที่สร้างจากวิธีโครงข่ายประสาทเทียมมีความแม่นยำและรวดเร็วในการพยากรณ์นั้นขึ้นอยู่กับหลาย ๆ ปัจจัย เช่น รูปแบบโครงข่ายประสาทเทียมที่นำมาใช้ วิธีการเรียนรู้ที่เลือกใช้ จำนวนรอบของการกระทำซ้ำ วิธีที่นำมาใช้ร่วมกับโครงข่ายประสาทเทียม เป็นต้น ดังนั้นการสร้างตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมต้องกำหนดรูปแบบต่าง ๆ เหล่านี้ให้เหมาะสม เพื่อให้ตัวแบบพยากรณ์มีความแม่นยำมากที่สุด นอกจากนี้โครงข่ายประสาทเทียมยังเป็นที่นิยมในการนำมาใช้สำหรับสร้างตัวแบบพยากรณ์ร่วมกับวิธีต่าง ๆ เช่น วิธี MRA วิธี GA วิธี PCA วิธี Fuzzy Logic เป็นต้น เพื่อเป็นการเพิ่ม

ประสิทธิภาพของการพยากรณ์ ทำให้การพยากรณ์มีความแม่นยำและรวดเร็วเพิ่มขึ้น และวิธีที่นิยมนำมาใช้ร่วมคือวิธี GA (Asadi et al., 2013; Ding et al., 2014; Huang & Hou, 2017; Saxena et al., 2014; Wang et al., 2017; Yan, 2015)

ตอนที่ 4 ข้อมูลปริมาณน้ำฝน การพยากรณ์ปริมาณน้ำฝนและงานวิจัยที่เกี่ยวข้อง

จากรายงานการเปลี่ยนแปลงสภาพภูมิอากาศ (Climate Change) ของประเทศไทยผ่าน มาของกรมอุตุนิยมวิทยาและสำนักงานกองทุนสนับสนุนการวิจัยแสดงให้เห็นว่า อุณหภูมิมีแนวโน้มเพิ่มสูงขึ้นอย่างมีนัยสำคัญ ทั้งอุณหภูมิสูงสุดเฉลี่ย อุณหภูมิต่ำสุดเฉลี่ยและอุณหภูมิเฉลี่ย ส่งผลทำให้ ความรุนแรงของภัยพิบัติทางธรรมชาติเพิ่มมากขึ้น ทั้งจากความผันแปรของอุณหภูมิและปริมาณ น้ำฝน ซึ่งเป็นปัญหาในปัจจุบันของประเทศไทยและต่างประเทศ ดังนั้นจึงให้ความสนใจและตระหนัก ถึงความสำคัญของปัญหาดังกล่าว โดยเฉพาะปัญหาโลกร้อนและปัญหาปริมาณน้ำฝนที่ลดลงในบาง พื้นที่ ทำให้เกิดความแห้งแล้งมากขึ้นหรือมีปริมาณน้ำฝนเพิ่มขึ้นมาก ทำให้เกิดอุทกภัยรุนแรง การ ติดตามสถานการณ์น้ำฝนและอุณหภูมิที่ผันแปรไปรวมทั้งลักษณะการผันแปรและแนวโน้มเป็น สิ่งจำเป็น และมีประโยชน์ในการใช้เป็นข้อมูลพื้นฐานเพื่อประกอบการพิจารณาหรือวางแผนรับมือกับ ปัญหาและผลกระทบที่อาจเกิดขึ้น (อภิสิทธิ์ พัทธโรภาสวัฒนกุล และคณะ, 2560) ปริมาณน้ำฝนเป็น ผลมาจากกระบวนการธรรมชาติที่ซับซ้อนและกลายเป็นปัญหาหลักทางอุตุนิยมวิทยา (Purnomo et al., 2017)

4.1 ฝน (Rain)

หยาดน้ำฟ้า (Precipitation) เป็นชื่อเรียกรวมของหยดน้ำและน้ำแข็งที่เกิดจากการ ควบแน่นของไอน้ำแล้วตกลงมาสู่พื้นดิน เช่น ละอองหมอก ฝนละออง ฝน หิมะ ลูกเห็บ เป็นต้น การ แบ่งประเภทของหยาดน้ำฟ้า นั้น พิจารณาจากขนาดของเส้นผ่านศูนย์กลางของหยดน้ำและน้ำแข็ง หยาดน้ำฟ้าแตกต่างจากหยดน้ำหรือละอองน้ำในก้อนเมฆ (Cloud Droplets) คือ หยาดน้ำฟ้ามี ขนาดใหญ่และมีน้ำหนักมากพอที่จะชนะแรงต้านอากาศและตกลงสู่พื้นโลกได้โดยไม่ระเหยเป็นไอน้ำ ก่อน ดังนั้นกระบวนการเกิดหยาดน้ำฟ้าจึงมีความซับซ้อนมากกว่ากระบวนการควบแน่นที่ทำให้เกิด เมฆ

ฝน (Rain) เป็นหยดน้ำที่มีขนาดประมาณ 0.5-5 มิลลิเมตร เป็นรูปแบบหนึ่งของน้ำที่ ตกลงมาจากฟ้า ฝนส่วนใหญ่ตกลงมาจากเมฆนิมโบสตราตัส (Nimbostratus) และเมฆคิวมูโลนิมบัส (Cumulonimbus) ฝนตกเกิดจากน้ำโดนความร้อนของแสงอาทิตย์หรือความร้อนอื่นใดที่ใช้ในการต้มน้ำจนทำให้ระเหยกลายเป็นไอ ลอยขึ้นไปในอากาศ เมื่อไอน้ำมากขึ้นจะรวมกันเป็นละอองน้ำเล็ก ๆ ปริมาณของละอองน้ำยิ่งมากขึ้นเรื่อย ๆ จะรวมตัวกันเป็นเมฆฝน พอมากขึ้นอากาศไม่สามารถพยุง ละอองน้ำเหล่านี้ต่อไปได้ น้ำก็จะหล่นลงมายังโลกที่เรียกว่า ฝนตก วัฏจักรน้ำ (Water Cycle) ที่

เกิดขึ้นจะเป็นลักษณะนี้ตลอดและยังคงดำเนินต่อไปเรื่อย ๆ น้ำฝนที่ตกลงมาบนโลกถือเป็นกระบวนการหนึ่งของวงจรที่หมุนเวียนอยู่ในโลกอย่างต่อเนื่องไม่มีที่สิ้นสุด เริ่มต้นด้วยการระเหยโดยพลังงานความร้อนจากแสงอาทิตย์ที่ส่องตรงมายังผิวน้ำ ทำให้น้ำจากมหาสมุทรและแหล่งน้ำต่าง ๆ กลายเป็นไอลอยขึ้นไปเป็นส่วนหนึ่งของบรรยากาศ เมื่อรวมกับน้ำที่พืชคายออกมาและน้ำแผ่นผิวดิน ระเหยขึ้นมาอีกส่วนหนึ่ง ทั้งหมดรวมกันเป็นน้ำที่กลายเป็นไอ กระแสลมอ่อนจะหอบเอาไอน้ำดังกล่าวลอยขึ้นที่สูง เมื่อกระทบกับอากาศเย็นในเบื้องสูงจะกลั่นตัวกลายเป็นละอองน้ำเล็ก ๆ จากนั้นละอองน้ำจำนวนมากจะรวมกันเป็นเมฆและรวมตัวกันเป็นหยดน้ำที่มีขนาดใหญ่ขึ้น ปริมาณมากขึ้นจนบรรยากาศรับไว้ไม่ไหวจึงตกลงสู่พื้นดินในรูปของหยาดน้ำฟ้า (Precipitation) ประเภทต่าง ๆ เช่น น้ำฝน ลูกเห็บ หิมะ เป็นต้น น้ำฝนเป็นต้นกำเนิดของน้ำที่ปรากฏบนผิวโลก เมื่อฝนตกลงมาบนพื้นดิน จะมีน้ำบางส่วนซึบอยู่บนผิวดินและบางส่วนซึมลงไปสะสมอยู่ในดิน ทำให้เกิดเป็นแหล่งน้ำตามธรรมชาติในดินที่อำนวยความสะดวกให้กับพืชได้โดยตรง เมื่อมีฝนตกมากน้ำไม่สามารถจะซึบอยู่ได้บนผิวดินและซึมลงไปดินได้ทั้งหมดก็จะเกิดเป็นน้ำไหลนองไปบนผิวดิน จากนั้นจะไหลลงสู่ที่ลุ่ม ที่ต่ำ ลำน้ำ ลำธาร แม่น้ำ แล้วจึงไหลลงสู่ทะเลและมหาสมุทร เมื่อได้รับพลังงานความร้อนจากแสงอาทิตย์ น้ำก็จะระเหยกลับขึ้นบรรยากาศอีกครั้งกลายเป็นวงจรเวียนซ้ำ ๆ อย่างนี้เรื่อย ๆ ไป

4.2 การวัดปริมาณน้ำฝน (Rainfall)

ปริมาณน้ำฝน หมายถึงระดับความลึกของน้ำฝนในภาชนะที่รองรับน้ำฝน เมื่อภาชนะรองรับน้ำฝนวางอยู่ในแนวระดับและวัดในช่วงเวลาที่กำหนด เครื่องวัดปริมาณน้ำฝนเรียกว่า เครื่องวัดปริมาณน้ำฝน (Rain Gauge) ต้องติดตั้งในที่โล่งแจ้ง ระยะห่างของเครื่องวัดต้องอยู่ห่างจากสิ่งกีดขวางแวดล้อมอย่างน้อย 2 เท่าของความสูงของสิ่งนั้น มีลักษณะเป็นภาชนะเปิดรับน้ำฝน กลางแจ้ง ปริมาณน้ำฝนมีหน่วยเป็นมิลลิเมตร (มม.) หรือนิ้ว (25.4 มิลลิเมตร = 1 นิ้ว) การวัดปริมาณน้ำฝนแบ่งเป็น 2 ชนิดคือ

4.2.1 เครื่องมือวัดปริมาณน้ำฝนแบบมาตรฐาน (Standard Rain Gauge) มีลักษณะเป็นรูปทรงกระบอก 2 ชั้นวางซ้อนกัน (ภาพที่ 2-9) และภายในมีกระบอกอีกอันหนึ่งสำหรับรองรับน้ำฝน ส่วนบนของกระบอกชั้นนอกเป็นปากถังมีลักษณะเป็นกรวยทำหน้าที่รองรับน้ำฝนเข้าสู่ถังชั้นใน เพื่อป้องกันการระเหยของน้ำฝน ปริมาณน้ำฝนที่วัดได้เป็นความสูงของน้ำฝนจากพื้นดินโดยคิดว่าน้ำฝนนั้นไม่มีการระเหยหรือไหลซึมลงสู่ดิน โดยกำหนดให้ปากถังมีเส้นผ่านศูนย์กลาง 20 เซนติเมตร ส่วนล่างของกระบอกใช้เป็นที่รองรับถังชั้นใน การติดตั้งตำแหน่งปากถังต้องอยู่ในแนวระดับและความสูงจากพื้นดินประมาณ 80 เซนติเมตร (รังสรรค์ อากาศพิษกุล, 2547, หน้า 179) ปริมาณน้ำฝนที่วัดได้หารด้วยพื้นที่รับปริมาณน้ำฝนเป็นค่าความสูงของน้ำฝน (วิชัย ศรีบุญถือ, 2552, หน้า 178)



ภาพที่ 2-9 เครื่องมือวัดปริมาณน้ำฝนแบบมาตรฐาน

4.2.2 เครื่องมือวัดปริมาณน้ำฝนแบบบันทึก (Recording Rain Gauge) เป็นเครื่องมือที่ทำการบันทึกปริมาณน้ำฝนตามช่วงเวลาที่เกิดฝนลงบนกระดาษกราฟและสามารถคำนวณหาความเข้ม (Intensity) ของฝนที่ตกในช่วงเวลานั้น ๆ มีทั้งชนิดบันทึกแบบรายวัน (Daily) รายสัปดาห์ (Weekly) และรายเดือน (Monthly) ลักษณะทั่วไปของเครื่องมือประกอบด้วย 2 ส่วนที่สำคัญคือ ส่วนแรกจะเป็นกระบอกลานนาฬิกาที่มีกระดาษกราฟน้ำฝนหุ้มอยู่โดยรอบ ระยะเวลาการหมุนในหนึ่งรอบที่นิยมใช้เท่ากับ 24 ชั่วโมง ส่วนที่สองจะเป็นกลไกสำหรับวัดปริมาณน้ำฝนที่มีลักษณะการทำงานแบบต่าง ๆ กัน ที่นิยมใช้มี 3 ชนิดได้แก่ แบบกาลักน้ำ (Siphon Rain Gauge) (ภาพที่ 2-10) แบบตาชั่งวัดน้ำหนัก (Weighing Rain Gauge) (ภาพที่ 2-11) แบบคานกระดก (Tipping Bucket Rain Gauge) (ภาพที่ 2-12) (รังสรรค์ อาภาศัพท์กุล, 2547, หน้า 180)



ภาพที่ 2-10 เครื่องมือวัดปริมาณน้ำฝนแบบบันทึกแบบกาลักน้ำ



ภาพที่ 2-11 เครื่องมือวัดปริมาณน้ำฝนแบบบันทึกแบบตาชั่งวัดน้ำหนัก



ภาพที่ 2-12 เครื่องมือวัดปริมาณน้ำฝนแบบบันทึกแบบคานกระดก

การรายงานปริมาณน้ำฝน จะรายงานว่าฝนตกเล็กน้อย ฝนตกปานกลาง ฝนตกหนักหรือ ฝนตกหนักมาก แต่การที่จะตั้งเกณฑ์สากลไม่อาจทำได้ เพราะสภาพของฝนในแต่ละประเทศมีปริมาณไม่เหมือนกัน ประเทศไทยรายงานเป็นจำนวนมิลลิเมตร ต่อ 24 ชั่วโมง เกณฑ์การพิจารณาปริมาณน้ำฝนในระยะเวลา 24 ชั่วโมงของแต่ละวันตั้งแต่ 07.00 น. ของวันหนึ่งถึงเวลา 07.00 น. ของวันรุ่งขึ้น ตามลักษณะของฝนที่ตกในประเทศที่อยู่ในเขตร้อนย่านมรสุม (Monsoon) สามารถแบ่งเกณฑ์การรายงานปริมาณน้ำฝนในระยะเวลา 24 ชั่วโมง กรมอุตุนิยมวิทยา (2556, หน้า 20) อธิบายดังตารางที่ 2-2

ตารางที่ 2-2 เกณฑ์การรายงานปริมาณน้ำฝนในระยะเวลา 24 ชั่วโมง

ปริมาณน้ำฝน	เกณฑ์การรายงาน
ฝนตกวัดจำนวนไม่ได้	ปริมาณน้ำฝนน้อยกว่า 0.1 มิลลิเมตร
ฝนตกเล็กน้อย	ปริมาณน้ำฝนระหว่าง 0.1-10.0 มิลลิเมตร
ฝนตกปานกลาง	ปริมาณน้ำฝนระหว่าง 10.1-35.0 มิลลิเมตร
ฝนตกหนัก	ปริมาณน้ำฝนระหว่าง 35.1-90.0 มิลลิเมตร
ฝนตกหนักมาก	ปริมาณน้ำฝนตั้งแต่ 90.1 มิลลิเมตร

และเกณฑ์การรายงานการกระจายของน้ำฝน จะรายงานว่าฝนตกบางพื้นที่ ฝนตกกระจาย เป็นแห่ง ๆ ฝนตกกระจาย ฝนตกเกือบทั่วไปหรือฝนตกทั่วไป อธิบายดังตารางที่ 2-3

ตารางที่ 2-3 เกณฑ์การรายงานการกระจายของน้ำฝนในระยะเวลา 24 ชั่วโมง

การกระจายของน้ำฝน	เกณฑ์การรายงาน
ฝนตกบางพื้นที่	ฝนตกน้อยกว่า 20% ของพื้นที่
ฝนตกกระจายเป็นแห่ง ๆ	ฝนตกตั้งแต่ 20% ขึ้นไปแต่ไม่ถึง 40% ของพื้นที่
ฝนตกกระจาย	ฝนตกตั้งแต่ 40% ขึ้นไปแต่ไม่ถึง 60% ของพื้นที่
ฝนตกเกือบทั่วไป	ฝนตกตั้งแต่ 60% ขึ้นไปแต่ไม่ถึง 80% ของพื้นที่
ฝนตกทั่วไป	ฝนตกตั้งแต่ 80% ขึ้นไปของพื้นที่

4.3 ลักษณะของข้อมูลฝน แบ่งเป็น 2 ลักษณะ ดังนี้

4.3.1 ปริมาตร-ช่วงเวลา-ความถี่ของฝน (Volume-Duration-Frequency: VDF)

ปริมาตร (Volume) หมายถึงปริมาณน้ำฝนทั้งหมดตลอดช่วงเวลาที่ยกมา ช่วงเวลา (Duration) หมายถึงความยาวนานของฝนที่ตกครั้งหนึ่ง ๆ และความถี่ของฝน (Frequency) หมายถึงเหตุการณ์ที่ฝนจะมีช่วงเวลาการตกและปริมาณเท่ากับครั้งนั้น ๆ เกิดขึ้นบ่อยแค่ไหน

4.3.2 ความเข้ม-ระยะเวลาการตก-ความถี่ (Intensity-Duration-Frequency: IDF) การเลือกปริมาณน้ำฝนเพื่อใช้ในการออกแบบทางอุทกวิทยามักเลือกจากโค้งความสัมพันธ์ระหว่างความเข้มฝน ระยะเวลาการตกและความถี่ในการเกิด โดยสมการทางคณิตศาสตร์ของโค้ง IDF (Mathematical Representation of IDF Curve) คือ

$$i = \frac{a}{t_r + b}$$

เมื่อ i คือความเข้มฝน (ความลึกต่อเวลา)

t_r คือช่วงระยะเวลาการตกของฝน (เวลา)

a, b คือค่าคงที่เฉพาะของแต่ละพื้นที่และรอบปีการเกิดซ้ำ

ในการเลือกใช้ต้องกำหนดความถี่ในการเกิดของฝนหรือรอบปีการเกิดซ้ำและช่วงระยะเวลาการตกของฝน โดยจะพิจารณารอบปีการเกิดซ้ำมาก (มีโอกาสดเกิดน้อย) สิ่งนี้ออกแบบมีความสำคัญหรือมีความเสียหายรุนแรง ถ้าปริมาณน้ำมีค่ามากกว่าที่ออกแบบไว้ ส่วนระยะเวลาการตกของฝนจะพิจารณาจากระยะเวลาที่น้ำจากจุดไกลสุดของพื้นที่ไหลมาถึงทางออก ซึ่งจะเป็นเวลาที่ทำให้เกิดปริมาณการไหลสูงสุด

4.4 ประเภทของฝนที่ตกในประเทศไทย (Toeybeast, 2018)

ประเทศไทยมีลักษณะเป็นคาบสมุทรมีทะเลขนานทั้งสองข้างคือ ทะเลจีนใต้และมหาสมุทรอินเดีย ทำให้มีความชื้นผ่านไปมาค่อนข้างมาก ฝนที่ตกในประเทศไทยจึงลักษณะแตกต่างกัน แบ่งตามสาเหตุการเกิด ดังนี้

4.4.1 ฝนพาความร้อน (Convective Rain) คือฝนที่เกิดจากกลุ่มอากาศร้อนลอยตัวสูงขึ้นจนถึงจุดไอน้ำกลั่นตัวลงมาเป็นฝนในตอนเย็นและกลางคืน ลักษณะฝนที่ตกเป็นแบบฝนโปรย (Rain Shower) หรือเกิดฝนตกหนักมากเป็นระยะเวลาสั้น ๆ ในขณะที่ฝนตกอาจจะมีพายุพัดรุนแรง มีลูกเห็บตกและฟ้าคะนองรุนแรง การเกิดฝนชนิดนี้จะปรากฏในเดือนมีนาคมและเดือนเมษายน

4.4.2 ฝนปะทะภูเขา (Orographic Rain) คือฝนที่เกิดจากลมที่มีความชื้นพัดไปปะทะภูเขา โดยเฉพาะลมมรสุมตะวันตกเฉียงใต้ ลมนี้จะพัดสูงขึ้นและอุณหภูมิลดต่ำลงจนถึงจุดที่ไอน้ำกลั่นตัวตกลงมาเป็นฝน ฝนชนิดนี้เป็นฝนที่ตกมากและตกบ่อยครั้ง จะเริ่มตั้งแต่สัปดาห์ที่ 2 ของเดือนพฤษภาคมและสิ้นสุดในสัปดาห์ที่ 2 ของเดือนพฤศจิกายน ตามปกติมักเกิดในช่วงตอนบ่ายหรือตอนกลางคืน

4.4.3 ฝนพายุหมุน (Cyclonic Rain) ประเทศไทยตั้งอยู่ในทางผ่านของพายุหมุนซึ่งก่อตัวในทะเลจีนใต้ แล้วเคลื่อนตัวมาทางตะวันตกเข้าสู่ชายฝั่งทะเลเวียดนามเลยเข้าสู่ภาคตะวันออกเฉียงเหนือของประเทศไทย พายุที่พัดเข้ามาในประเทศไทยมักจะอ่อนกำลังลงเป็น

ดีเปรสชันหรือหางพายุ นอกจากนี้ฝนพายุหมุนยังเกิดจากการปะทะของอากาศหลายกระแส ซึ่งพัดมาจากทิศทางต่าง ๆ เช่น ประเทศจีนตอนใต้ ฝนชนิดนี้เกิดในเดือนมิถุนายนถึงเดือนตุลาคม

4.4.4 ฝนแนวปะทะ (Frontal Rain) คือฝนที่เกิดจากมวลอากาศร้อนและอากาศเย็นมาพบกัน อากาศเย็นจะหมุนอากาศร้อนลอยตัวขึ้นบน อุณหภูมิของอากาศจะลดลงจนกลั่นตัวตกลงเป็นฝน ฝนชนิดนี้เกิดในช่วงเดือนตุลาคมถึงเดือนพฤศจิกายน และช่วงเดือนกุมภาพันธ์ถึงเดือนเมษายน

4.4.5 ฝนมรสุม (Monsoon) เป็นฝนที่ตกในฤดูมรสุมและเป็นฝนที่ตกต่อเนื่องกันเป็นเวลานาน มีปริมาณน้ำฝนมากเมื่อร่องมรสุมพัดผ่าน

4.4.6 ฝนชะช่อมะม่วง (Mango Shower) เป็นฝนที่ตกนอกฤดู ปริมาณน้ำฝนที่ตกมีไม่มาก เกิดจากคลื่นในกระแสลมตะวันออกเฉียงใต้พัดผ่านเข้าสู่มาฝั่งแผ่นดิน เกิดในเดือนมกราคมและเดือนกุมภาพันธ์ ที่เรียกว่าฝนชะช่อมะม่วงเพราะช่วงที่ฝนชนิดนี้ตกจะเป็นระยะที่ไม่ผลต่าง ๆ กำลังผลิออกดอกออกช่อโดยเฉพาะมะม่วง ซึ่งปกติมะม่วงจะถูกผึ้งในอากาศจับตามช่อ ผึ้งละอองเหล่านี้ส่วนมากจะเป็นเกลือ ความเค็มทำให้ช่อมะม่วงเหี่ยวแห้งและร่วงหล่นไปไม่ติดผล แต่เวลาที่ฝนตกน้ำฝนจะชะผึ้งที่จับช่อมะม่วงให้หมดไป ช่อมะม่วงจะสะอาดและชุ่มชื้นทำให้ติดผลได้มาก ส่วนชาวนามักจะเรียกฝนชะช่อมะม่วงว่า ฝนชะลาน

4.4.7 ฝนชูฟ้าคะนอง (Thunder Shower) หรือฝนไล่ช้าง ฝนชนิดนี้จะตกหนักอย่างกะทันหันและหยุดทันทีทันใด บางครั้งมีลูกเห็บเกิดขึ้นด้วย

4.4.8 พายุฝนฟ้าคะนอง (Thunderstorm) ซึ่งเป็นสาเหตุสำคัญที่ทำให้เกิดลักษณะอากาศร้ายชนิดต่าง ๆ เช่น ลมกระโชก ฟ้าแลบและฟ้าผ่า ฝนตกหนัก อากาศปั่นป่วนรุนแรง ทำให้มีลูกเห็บตกและอาจเกิดน้ำแข็ง ประเทศไทยพายุฝนฟ้าคะนองสามารถก่อตัวได้เกือบตลอดเวลาและในทุกพื้นที่ เนื่องจากอยู่บริเวณภูมิอากาศในเขตร้อน (Tropic) โดยเฉพาะในเดือนมีนาคมถึงเดือนพฤษภาคม พายุฝนฟ้าคะนองที่เกิดขึ้นจะมีความรุนแรงกว่าปกติ จนเกิดเป็นลักษณะที่เรียกว่า พายุฤดูร้อน

4.4.9 ฝนตกเป็นครั้งคราว (Occasional Rain) เป็นฝนที่ตกไม่ต่อเนื่องกัน หยุดนานจึงจะตกใหม่ ท้องฟ้าครึ้มฝนมีเมฆหนา

4.4.10 ฝนตกเป็นระยะ (Intermittent Rain) เป็นฝนที่ตกแล้วหยุด หยุดแล้วตก

4.4.11 ฝนตกต่อเนื่องกัน (Continuous Rain) บางครั้งเรียกว่าฝนพรำหรืออื่น ๆ ได้แก่ ฝนเฉพาะแห่ง ฝนเป็นแห่งและฝนกระจายเป็นบริเวณกว้าง

4.4.12 ฝนโคลน (Mud Rain) เป็นฝนที่มีละอองของดินทราย ผงฝุ่นผสมอยู่ ทำให้ฝนที่ตกลงมามีสีคล้ายน้ำโคลน

4.4.13 ฝนเลือด (Blood Rain) เป็นฝนที่มีฝุ่นสีแดงผสมอยู่มาก เกิดขึ้นเนื่องจากเม็ดฝนที่กระแสมกภายในก้อนเมฆหอบกลับขึ้นสู่เบื้องบนก่อนจะตกลงมาสู่พื้นดิน มีการจับเอาฝุ่นละอองสีแดงเข้าเม็ดฝน จนทำให้น้ำฝนที่ตกลงมามีสีแดงคล้ายเลือด

4.4.14 ฝนสีเหลือง (Sulphur Rain) เป็นฝนที่มีละอองของฝุ่นสีเหลืองอยู่มาก สีเหลืองเกิดจากการที่ฝุ่นละอองสีเหลืองหรือเกสรดอกไม้ถูกพัดพาสูงขึ้นไป พร้อมกับกระแสอากาศ แล้วจึงตกลงมาพร้อมกับฝนทำให้น้ำฝนมีสีเหลืองคล้ายกำมะถัน

4.5 ความสำคัญของปริมาณน้ำฝน

ปริมาณน้ำฝนได้กลายเป็นประเด็นสำคัญที่มีการศึกษามากมาย เนื่องจากส่งผลกระทบต่อชีวิตทางสังคมทั้งในชนบทหรือในเขตเมือง (Sihananto & Mahmudy, 2017) น้ำฝนนับเป็นผลิตผลจากธรรมชาติที่เราไม่สามารถผลิตเพิ่มขึ้นมาหรือลดปริมาณที่มีอยู่ในธรรมชาติได้เองตามต้องการ บางปีอาจเกิดฝนแล้งเป็นเหตุให้น้ำในแม่น้ำลำธารมีน้อย จนไม่สามารถแบ่งปันได้ทั่วถึงหรือบางปีฝนตกชุกต่อเนื่องจนเกิดความเสียหายเนื่องจากน้ำท่วมทรัพย์สินและพื้นที่ชุมชน (ฐกร กาญจน์จิระเดช, มยุรี รัตนเสริมพงศ์ และสมบูรณ์ สุขสำราญ, 2561) ปริมาณน้ำฝนเป็นสิ่งที่สำคัญยิ่งสิ่งหนึ่งในอุตุนิยมวิทยา เพราะน้ำฝนเป็นปัจจัยสำคัญที่เกี่ยวข้องกับการกสิกรรมและอื่น ๆ พื้นที่ใดจะอุดมสมบูรณ์และสามารถทำการเพาะปลูกได้หรือจะเป็นทะเลทรายขึ้นอยู่กับปริมาณน้ำฝนที่ตกลงมาในบริเวณนั้น ความสำคัญของปริมาณน้ำฝนในด้านต่าง ๆ เช่น

4.5.1 ด้านการเกษตรกรรม ปริมาณน้ำฝนถูกใช้ในการวางแผนการเพาะปลูก การสรรหาแนวทางการป้องกันและแก้ไข เพื่อบรรเทา ภัยร้ายผลกระทบและความเสียหายที่อาจเกิดขึ้นกับการเกษตรกรรม (Samhitha & Srikanth, 2017; Tafoughalti et al., 2018; Wahyuni et al., 2018) ซึ่งปริมาณน้ำฝนเป็นปัจจัยที่ส่งผลต่อการเกษตรกรรมมากทั้งด้านบวกและด้านลบ เช่น การเกษตรกรรมข้าวซึ่งถือว่าการเกษตรกรรมหลักของประเทศไทยและประเทศไทยยังเป็นผู้ผลิตและส่งออกข้าวรายใหญ่อันดับต้น ๆ ของภูมิภาคเอเชียตะวันออกเฉียงใต้และของโลกด้วย การปลูกข้าวนั้น กล้าข้าวสำหรับปลูกข้าวรายปีมีความต้องการปริมาณน้ำอย่างมากโดยเฉพาะอย่างยิ่งช่วงเวลาดอนออกช่อดอกถึงออกรวง หลังจากนั้นเมื่อถึงระยะเก็บเกี่ยวต้นข้าวไม่ต้องการน้ำเลย นั่นคือหากปริมาณน้ำมีความเหมาะสมตามช่วงเวลาเจริญเติบโตของข้าวจะทำให้ได้ผลผลิตข้าวที่ดี ดังนั้นปริมาณน้ำฝนจึงมีความสำคัญยิ่งต่อการทำนาของประเทศไทย กล่าวคือหากคาดการณ์ช่วงเวลาลงกล้าข้าวผิดเมื่อถึงเวลาเก็บเกี่ยวแต่ก็ยังมีฝนตกอยู่จึงทำให้ผลผลิตข้าวเสียหายเนื่องมาจากน้ำฝน ในทางกลับกันหากลงกล้าข้าวก่อนช่วงเวลาที่เหมาะสม ปริมาณน้ำฝนไม่พอในช่วงที่กล้าข้าวต้องการน้ำมาก ๆ ส่งผลให้ต้องมีการผันน้ำจากบริเวณอื่นเข้ามาเป็นการเพิ่มต้นทุนการเพาะปลูกมากขึ้นไปด้วย รวมถึงเกษตรกรชาวสวนยางพาราในภาคใต้ ยางพาราเป็นพืชเศรษฐกิจหลักของประเทศไทย มีปริมาณการส่งออกมากที่สุดในโลก โดยมีภาคใต้เป็นแหล่งปลูกสำคัญ เนื่องจากเป็นภูมิภาคที่มีสภาพภูมิอากาศ

แบบร้อนขึ้น มีปริมาณน้ำฝนมากเหมาะสมต่อการเจริญเติบโตของยางพาราซึ่งเป็นพืชที่ปลูกโดยอาศัยน้ำฝน การเปลี่ยนแปลงของสภาวะความรุนแรงของฝนในแง่ปริมาณ ความถี่และความแรง โดยเฉพาะอย่างยิ่งการเพิ่มขึ้นของปริมาณฝนในช่วงฤดูร้อน ความแรงของฝนและเหตุการณ์ฝนตกหนักในพื้นที่ภาคใต้ ส่งผลกระทบต่อสรีรวิทยาและผลผลิตของยางพารา ปัจจุบันปริมาณน้ำฝนรายปีในภาคใต้เพิ่มขึ้นส่งผลโดยตรงต่อจำนวนวันกรีตในรอบปีด้วย ดังนั้นเกษตรกรชาวสวนยางพาราต้องให้ความสนใจต่อการเปลี่ยนแปลงปริมาณน้ำฝนในพื้นที่และเตรียมตัวรับมือ ตลอดจนต้องมีการปรับตัวกับการเปลี่ยนแปลงของปริมาณน้ำฝนในอนาคต

4.5.2 ด้านการพยากรณ์ ข้อมูลปริมาณน้ำฝนถูกนำมาใช้เป็นตัวแปรในการพยากรณ์ของหลากหลายสาขา เช่น การพยากรณ์ระดับน้ำ (ยุพิน ไชยสมภาร และทวี ชัยพิมลผลิน, 2560; ศุภมิตร บุญทา และจิระนันต์ เจริญรัตน์, 2559) การพยากรณ์อัตราการไหลของน้ำสูงสุด (อนุชา กาญจนารักษ์ และวรรณดี ไทยสยาม, 2561) การพยากรณ์เกี่ยวกับยูง (Lee et al., 2016) การพยากรณ์ปริมาณน้ำฝน (Arya & Pai, 2018; Chanklan et al., 2017; Purnomo et al., 2017; Shaikh & Sawlani, 2017; Wahyuni et al., 2018) เป็นต้น

4.5.3 ด้านการเตือนภัยพิบัติ เช่น การเตือนภัยดินถล่ม ปัจจัยที่สำคัญที่ทำให้ดินถล่มคือปริมาณน้ำฝน เหตุการณ์ดินถล่มในประเทศไทยที่เกิดขึ้นแล้วเกิดขึ้นในช่วงเวลาที่ฝนตกหนักติดต่อกันหลายวัน ทั้งฝนที่ตกตามฤดูกาลและฝนที่ตกหนัก เนื่องจากอิทธิพลพายุหมุนเขตร้อนที่พัดผ่านเข้ามาในประเทศไทย (สุทธิศักดิ์ ศรีลัมพ์ และธีรไฉย นุ้ยมาก, 2556) ดังนั้นการเตือนภัยดินถล่มจะอาศัยปริมาณน้ำฝนสะสมในแต่ละพื้นที่ ซึ่งอาจจะลดความเสียหายได้ในระดับหนึ่ง หากไม่มีการเตือนภัยพิบัติก็จะมีมาตรการป้องกันย่อมส่งผลกระทบต่อเศรษฐกิจและสังคมของประเทศโดยรวม เป็นต้น นอกจากนี้ข้อมูลปริมาณน้ำฝนยังถูกใช้ในการเตือนภัยแล้งและการเกิดอุทกภัยอีกด้วย ดังนั้นควรติดตามสถานการณ์การเปลี่ยนแปลงปริมาณน้ำฝนอย่างต่อเนื่อง เพื่อเป็นเตรียมตัวรับมือหากเกิดการเปลี่ยนแปลงนั้นที่ส่งผลกระทบต่อตัวเรา

4.5.4 ด้านการเก็บกักน้ำ เนื่องด้วยปริมาณน้ำที่ไหลในลำน้ำธรรมชาติ มักจะผันแปรไปตามจำนวนฝนที่ตกในเขตลุ่มน้ำและตามฤดูกาล กล่าวคือในช่วงฤดูน้ำหลากน้ำในแม่น้ำอาจจะมีจำนวนมาก แต่ในฤดูแล้งจะมีจำนวนเพียงเล็กน้อย ส่วนลำธารและทางน้ำเล็ก ๆ นั้น โดยมากจะมีน้ำไหลมาเฉพาะในเวลาที่ยังฝนตกเท่านั้น การแก้ไขปัญหาเพื่อให้มีน้ำใช้สำหรับการชลประทานอย่างเพียงพอในเวลาที่ต้องการตลอดไป จึงจำเป็นต้องหาวิธีการเก็บกักน้ำที่มีมากในลำน้ำตอนฤดูน้ำหลากไว้ สำหรับเป็นแหล่งน้ำต้นทุนเก็บสำรองไว้ใช้เมื่อถึงคราวจำเป็น โดยมีการสร้างอ่างเก็บน้ำหรือเขื่อนเพื่อเก็บน้ำที่มีมากในช่วงฤดูฝนไว้ใช้ในเวลาที่ฝนไม่ตก ปริมาณน้ำตามธรรมชาติที่อ่างเก็บน้ำสามารถเก็บเอาไว้ได้จะขึ้นอยู่กับปริมาณน้ำฝนในเขตพื้นที่รับน้ำฝน อ่างเก็บน้ำแต่ละแห่งจะกำหนดขนาดความจุที่เหมาะสม โดยให้ความจุสำหรับน้ำที่จะมีมาทั้งหมดไม่ปล่อยให้มิน้ำเหลือไหลทิ้งไป

โดยเปล่าประโยชน์ โครงการชลประทานที่มีน้ำจากอ่างเก็บน้ำช่วยจะไม่เกิดปัญหาการขาดแคลนน้ำ และมีประสิทธิภาพดีกว่าการชลประทานประเภทที่ใช้น้ำเฉพาะที่มีมาตามธรรมชาติโดยตรง นอกจากนี้ยังสามารถใช้น้ำจากอ่างเก็บน้ำทำการเพาะปลูกพืชในหน้าแล้งได้เป็นอย่างดี

4.5.5 ด้านการท่องเที่ยว การท่องเที่ยวของไทยเป็นภาคส่วนที่มีความสำคัญทางเศรษฐกิจอย่างมาก การเปลี่ยนแปลงปริมาณน้ำฝนหรือการกระจายตัวของน้ำฝนก็อาจทำให้แหล่งท่องเที่ยวบางสถานที่เปลี่ยนไป บางสถานที่ปริมาณฝนน้อยทำให้ไม่สวยงามเท่าที่ควร บางสถานที่ไม่เหมาะกับการเดินทางไปเที่ยวในช่วงที่มีปริมาณน้ำฝนมากเพราะจะก่อให้เกิดอันตราย เช่น กิจกรรมล่องแพจะมีข้อจำกัด เพื่อเป็นการป้องกันการเกิดอันตราย ซึ่งอาจส่งผลกระทบต่อความพึงพอใจของนักท่องเที่ยว การเที่ยวถ้ำหรือน้ำตกในช่วงฝนตกหนักและฝนที่ตกสะสมก็ไม่สมควร เนื่องจากอาจจะทำให้เกิดน้ำท่วมฉับพลันและน้ำป่าไหลหลากจากปริมาณน้ำฝนมาก ก็จะก่อให้เกิดอันตรายได้ เช่นเดียวกับเหตุการณ์ในวันที่ 23 มิถุนายน พ.ศ. 2561 ที่มีนักฟุตบอลเยาวชนทีมหมูป่าอะคาเดมีแม่สายจำนวน 12 คน และผู้ช่วยผู้ฝึกสอนอีก 1 คน รวมทั้งสิ้น 13 คน ไปเที่ยวถ้ำหลวง ในวนอุทยานถ้ำหลวง-ขุนน้ำนางนอน อ.แม่สาย จ.เชียงราย แต่ระหว่างนั้นมีฝนตกหนัก ปริมาณน้ำฝนมากและระดับน้ำที่ท่วมสูงภายในถ้ำ เกิดน้ำหลากจนปิดปากถ้ำ จึงทำให้ไม่สามารถกลับออกมาได้ กลุ่มคนดังกล่าวจึงหลบเข้าไปภายในถ้ำอีกครั้ง เพื่อหนีน้ำท่วมนั้นจนเกิดการสูญหายขึ้นภายในถ้ำ การค้นหาช่วยเหลือเป็นไปได้ยากมาก ขึ้นอยู่กับปริมาณน้ำฝน นอกจากนี้ในช่วงฤดูฝนของทุกปีจะมีการปิดเส้นทางเข้าน้ำตกที่ลือชื่อในเขตรักษาพันธุ์สัตว์ป่าอุ้มผาง อ.อุ้มผาง จ.ตาก เนื่องจากการเดินทางไม่สะดวกและเป็น การป้องกันอันตรายที่อาจจะเกิดขึ้นเนื่องปริมาณน้ำฝนมาก เป็นต้น ควรศึกษาเกี่ยวกับการตกของฝน ปริมาณน้ำฝนมาก-น้อยก่อนการเดินทางไปท่องเที่ยวตามสถานที่ต่าง ๆ ว่าควรจะไปหรือไม่ เพื่อให้เกิดความปลอดภัยและเกิดความพึงพอใจในการเดินทางไปสถานที่เหล่านั้น และไม่ควรประมาทหากมีการเตือนภัยพิบัติ ควรปฏิบัติตามอย่างเคร่งครัด

4.6 สาเหตุที่ทำให้ฝนตกในประเทศไทย

4.6.1 ร่องความกดอากาศต่ำหรือร่องมรสุม (Monsoon Trough) เกิดจากบริเวณที่มีความกดอากาศต่ำ มีกระแสอากาศไหลขึ้น-ลงสลับกัน ร่องมรสุมจะอยู่ในเขตร้อนใกล้ ๆ เส้นศูนย์สูตร แนวร่องมรสุมจะอยู่ในแนวทิศตะวันตกและทิศตะวันออก ร่องมรสุมจะมีการเปลี่ยนแปลงตำแหน่งตามการเคลื่อนที่ของดวงอาทิตย์ เช่น เมื่อดวงอาทิตย์โคจรอ้อมไปทางทิศเหนือ ร่องมรสุมก็จะเคลื่อนที่ตามไปด้วย การเคลื่อนที่ของร่องมรสุมมีผลต่อการเปลี่ยนทิศทางการรับลม เช่น ร่องมรสุมที่เคลื่อนที่ไปทางด้านทิศเหนือ บริเวณที่รับลมทางด้านทิศเหนือจะเปลี่ยนไปเป็นการรับลมจากทางด้านทิศใต้ทันที ร่องมรสุมมีผลต่อการเกิดฝนตกอันเนื่องมาจากสาเหตุข้างต้น คือบริเวณที่ได้รับ ความร้อนจากดวงอาทิตย์และมีการคายความร้อนออกมามาก อากาศร้อนน้ำหนักเบาจึงลอยตัวขึ้น แล้วนำความชื้นในอากาศไปก่อตัวเป็นเมฆฝน บริเวณร่องมรสุมจึงมีเมฆมากและมีฝนตกหนัก

ส่วนประเทศไทยร่องมรสุมเกิดจากการปะทะกันของลมมรสุมตะวันตกเฉียงใต้และลมมรสุมตะวันออกเฉียงเหนือ มีผลทำให้เกิดฝนตกเป็นบริเวณกว้าง ถ้าแนวขนของร่องมรสุมทั้งสองชนกันยิ่งแคบจะเกิดเป็นพายุฝนฟ้าคะนองได้ง่ายและถ้าเกิดร่องมรสุมนาน จะส่งผลให้เกิดฝนตกนานทำให้เกิดน้ำท่วมได้ (Thai PBS, 2556)

4.6.2 ลมมรสุม (Monsoon) ประเทศไทยอยู่ภายใต้อิทธิพลของลมมรสุม 2 ชนิด คือลมมรสุมตะวันตกเฉียงใต้และลมมรสุมตะวันออกเฉียงเหนือ การเริ่มต้นและสิ้นสุดลมมรสุมทั้งสองชนิดอาจผันแปรไปจากปกติได้ในแต่ละปี มีรายละเอียดดังนี้

4.6.2.1 ลมมรสุมตะวันตกเฉียงใต้ เป็นลมมรสุมที่พัดปกคลุมประเทศไทย ระหว่างกลางเดือนพฤษภาคมถึงกลางเดือนตุลาคม โดยมีแหล่งกำเนิดจากบริเวณความกดอากาศสูงในซีกโลกใต้บริเวณมหาสมุทรอินเดีย ซึ่งพัดออกจากศูนย์กึ่งกลางเป็นลมตะวันออกเฉียงใต้และเปลี่ยนเป็นลมตะวันตกเฉียงใต้ เมื่อพัดข้ามเส้นศูนย์สูตรลมมรสุมนี้จะนำมวลอากาศชื้นจากมหาสมุทรอินเดียมาสู่ประเทศไทย ทำให้มีเมฆมากและฝนตกชุกทั่วไป โดยเฉพาะอย่างยิ่งตามบริเวณชายฝั่งทะเลและเทือกเขาด้านรับลมจะมีฝนตกมากกว่าบริเวณอื่น (วิรัช มณีสาร, 2538) ลมมรสุมตะวันตกเฉียงใต้นำพาความชื้นและฝนมาตก เพราะพัดมาจากมหาสมุทรอินเดีย

4.6.2.2 ลมมรสุมตะวันออกเฉียงเหนือ หลังจากหมดอิทธิพลของลมมรสุมตะวันตกเฉียงใต้แล้ว ประมาณกลางเดือนตุลาคม จะมีลมมรสุมตะวันออกเฉียงเหนือพัดปกคลุมประเทศไทยจนถึงกลางเดือนกุมภาพันธ์ ลมมรสุมนี้มีแหล่งกำเนิดจากบริเวณความกดอากาศสูงบนซีกโลกเหนือ แถบประเทศมองโกเลียและจีนพัดพาเอามวลอากาศเย็นและแห้งจากแหล่งกำเนิดเข้ามาปกคลุมประเทศไทย ทำให้ท้องฟ้าโปร่ง อากาศหนาวเย็นและแห้งแล้งทั่วไป โดยเฉพาะภาคเหนือและภาคตะวันออกเฉียงเหนือ ทำให้ฝนตกน้อย ส่วนภาคใต้จะมีฝนตกชุกโดยเฉพาะภาคใต้ฝั่งตะวันออก เนื่องจากลมมรสุมนี้นำความชื้นขึ้นจากอ่าวไทยเข้ามาปกคลุม (วิรัช มณีสาร, 2538) ลมมรสุมตะวันออกเฉียงเหนือนำพาความหนาวเย็นและแห้งแล้งมาให้ มีความชื้นน้อย เพราะพัดมาจากแผ่นดินจึงมีฝนตกตามบริเวณชายฝั่งเท่านั้น

4.6.3 การพาความร้อน (Convective) เนื่องจากในเวลากลางวันพื้นดินได้รับความร้อนจากดวงอาทิตย์ ทำให้อากาศผิวพื้นร้อน (มีความชื้น) อากาศขยายตัว ความกดอากาศต่ำทำให้ลอยตัวขึ้นไปยังด้านบน เมื่ออากาศร้อนลอยตัวขึ้นไปจะเจอกับอากาศเย็นและหากอากาศเย็นลงจนถึงจุดน้ำค้าง (Dew Point) จะทำให้อากาศกลายเป็นหยดน้ำเล็กๆ ๆ จำนวนมากเกิดเป็นเมฆ เมื่อหยดน้ำในเมฆเหล่านั้นมีขนาดใหญ่ขึ้นจนถึงจุดหนึ่ง ก็จะหนักเกินไปจนกระแสลมพุงเอาไว้ไม่ไหว ทำให้ตกลงมาเป็นฝน ฝนแบบนี้อาจจะตกเป็นแห่ง ๆ ได้ทุกวันตลอดหน้าฝน คือในช่วงกลางเดือนพฤษภาคมถึงกลางเดือนตุลาคม ซึ่งเป็นช่วงที่อากาศในประเทศไทยมีความชื้นมาก เพราะได้รับอิทธิพลจากลมมรสุมตะวันตกเฉียงใต้พัดผ่านมหาสมุทรอินเดียและนำความชื้นเข้ามาด้วย สำหรับใน

ภาคใต้อาจมีฝนชนิดนี้เกือบตลอดทั้งปี เพราะอยู่ใกล้ทะเลทำให้อากาศมีความชื้นสูง ฝนที่เกิดจากการพาความร้อนไม่จำเป็นต้องตกในตอนเย็นเท่านั้น ในกลางทะเลซึ่งความร้อนระบายนได้ช้ากว่าพื้นดิน ฝนจะตกในช่วงกลางคืนถึงเช้ามืด

4.6.4 พายุหมุนเขตร้อน (Tropical Cyclone) เป็นคำทั่วไปที่ใช้เรียกพายุหมุนหรือพายุไซโคลน พายุหมุนเขตร้อนเป็นปรากฏการณ์ธรรมชาติที่สามารถสร้างความเสียหายได้อย่างรุนแรงและเป็นบริเวณกว้าง มีลักษณะเด่น คือบริเวณที่มีลมสงบ อากาศโปร่งใส โดยอาจมีเมฆและฝนบ้างเล็กน้อยอยู่ที่ศูนย์กลางพายุ (ตาพายุ) ซึ่งถูกล้อมรอบด้วยพื้นที่บริเวณกว้างกินรัศมีหลายร้อยกิโลเมตร บริเวณที่รัศมีไปถึงนั้นจะมีฝนตกหนักและพายุลมแรง ลมแรงพัดเวียนเข้าหาศูนย์กลาง ดังนั้นในบริเวณที่พายุหมุนเขตร้อนเคลื่อนที่ผ่านครั้งแรกจะปรากฏลักษณะอากาศโปร่งใส เมื่อด้านหน้าของพายุหมุนเขตร้อนมาถึงจะเกิดลมแรง ฝนตกหนักและมีพายุฟ้าคะนอง ลมกระโชกแรง และอาจเกิดพายุทอร์นาโด (Tornado) ในขณะที่พายุมาถึงอากาศจะโปร่งใสอีกครั้งและเมื่อด้านหลังของพายุหมุนมาถึงอากาศจะเลวร้ายลงอีกครั้งและรุนแรงกว่าครั้งแรก (วิจักขณ์ นุ่มนึ่ง, 2554, หน้า 11) ทำให้ได้รับผลกระทบมากที่สุด ความเสียหายที่เกิดขึ้นจะแปรผันตามความรุนแรงของพายุ พายุหมุนที่พัดเข้าสู่ประเทศไทยส่วนมากก่อตัวในทะเลจีนใต้ แต่ก็มีบางครั้งที่เคลื่อนตัวมาจากมหาสมุทรแปซิฟิกเป็นพายุไต้ฝุ่น สำหรับประเทศไทยไม่ค่อยได้รับภัยจากพายุไต้ฝุ่น เนื่องด้วยทางด้านตะวันออกของประเทศเป็นทางที่พายุไต้ฝุ่นก่อตัวในมหาสมุทรแปซิฟิกและทะเลจีนใต้ แล้วเคลื่อนตัวเข้ามาปะทะเทือกเขาในประเทศ เวียดนาม ลาว จึงทำให้อ่อนกำลังลงเสียก่อนเคลื่อนลงมาถึงประเทศไทย พายุดีเปรสชัน เดือนกรกฎาคม-เดือนสิงหาคม จะเคลื่อนตัวมาจากทะเลจีนใต้เข้าสู่ประเทศไทยทางฝั่งเวียดนาม จากนั้นจะมีทางเดินเข้ามาทางตอนเหนือของภาคตะวันออกเฉียงเหนือและภาคเหนือเป็นส่วนมาก เดือนกันยายน-เดือนตุลาคม พายุจะเคลื่อนตัวลงมาทาง ตอนใต้ คือเข้าทางตอนใต้ของภาคตะวันออกเฉียงเหนือและตรงเข้าสู่ภาคกลาง ทำให้ภาคกลางมีฝนตกหนาแน่น ในช่วงปลายเดือนตุลาคม พายุนี้จะเข้าทางด้านแหลมอินโดจีนและในบางคราวนี้หลุดจากปลายแหลมอินโดจีน โดยไม่ได้ปะทะฝั่งอินโดนีเซียเลย เข้าสู่ประเทศไทยทางอ่าวไทยและปะทะฝั่งตะวันออกของอ่าวไทย สิ่งที่เกิดจากพายุดีเปรสชันนี้คือ ฝนตกหนักติดต่อกัน อาจจะติดต่อกันได้เป็นระยะเวลา 2-3 วัน ทางที่พายุดีเปรสชันผ่านจะทำให้ฝนตกปานกลางถึงตกหนักติดต่อกันตลอดทาง ที่พายุนี้ผ่านไปแต่บางครั้งความเร็วของลมที่มีกำลัง แรงอยู่ก็อาจทำความเสียหาย ประเทศไทยจะได้รับพายุดีเปรสชันจากฝั่งตะวันออกไม่น้อยกว่า 3-4 ลูก พายุดีเปรสชัน ทำให้เกิดฝนตกแผ่เป็นบริเวณกว้างเกือบทั่วประเทศ และตกเป็นระยะติดต่อกันได้ 2-3 วัน ทำให้แผ่นดินชุ่มชื้นโดยทั่วไป นับว่าเป็นประโยชน์มากในด้านกสิกรรมและจะมีโทษมหันต์ ถ้าน้ำฝนมีมากเกินไปทำให้เกิดอุทกภัยและก่อให้เกิดความเสียหายต่อชีวิตและทรัพย์สินเป็นอย่างมาก เช่น ประเทศไทยเมื่อปี พ.ศ.2554 เกิดมหาอุทกภัยจากการถูกพายุพัดกระหน่ำติด ๆ กัน 5 ลูก ได้แก่ พายุโซนร้อนไหหม่า พายุโซนร้อนนกเตน พายุโซนร้อนไหถ่าง พายุ

ใต้ฝุ่นเนซาดและพายุไซรอนร้อนนาลแก ภัยพิบัติในครั้งนั้นได้สร้างความเสียหายและความทุกข์ยากให้แก่คนไทยอย่างหนักจนกลายเป็นความทรงจำอันน่าหวาดผวายิ่งกว่าครั้งใด ๆ ที่เคยผ่านมา นับเป็นอุทกภัยที่รุนแรงเป็นประวัติการณ์ครั้งของประเทศไทย (ทศพร ศรีเพียงจันทร์, จิรัชญา บุญยงค์ และ ศศิวิมล คนคง, 2555, หน้า 25-27)

4.6.5 แนวพัดสอบของลม การเบียดตัวเข้าหากันของลม 2 ฝ่ายบริเวณใกล้พื้นโลก ทำให้อากาศบริเวณแนวเบียดตัวลอยขึ้นเบื้องบนตามแนวนั้น ซึ่งจะมีเมฆฝนเกิดขึ้นและในที่สุดจะตกลงมาเป็นฝน (Penname, 2007) เช่น ลมใต้ที่ร้อนขึ้นที่พัดผ่านบริเวณภาคใต้และอ่าวไทย มาพบกับลมตะวันออกเฉียงใต้ ซึ่งพัดมาจากทะเลจีนใต้ตอนล่างที่ถูกปกคลุม โดยบริเวณความกดอากาศสูงเหนือมหาสมุทรแปซิฟิก ในช่วงปลายฤดูหนาว จะทำให้เกิดแนวพัดสอบของลมบริเวณภาคกลางเหนือปากอ่าวไทยและการยกตัวของอากาศขึ้น ทำให้เกิดเป็นพายุฝนฟ้าคะนอง ซึ่งมีฝนตกหนักและฟ้าร้องฟ้าผ่าได้

4.6.6 คลื่นกระแสลมตะวันตก (Westerly Wave) คลื่นกระแสลมตะวันตกเกิดขึ้นที่ระดับบนคือ 5.5 กม. ถึง 12 กม. มีรูปร่างคล้ายคลื่น ลมนี้จะไม่สัมผัสร่างกายของคน แต่คลื่นกระแสลมตะวันตกจะเหนี่ยวนำหรือดึงดูดให้อากาศผิวพื้นลอยตัวขึ้นไปด้านบนและเนื่องจากโลกหมุนทำให้เกิดแรงโคริโอลิส (Coriolis Force) ลมจึงหมุนทวนเข็มนาฬิกาทำให้เกิดการก่ตัวของเมฆในแนวตั้งและทำให้เกิดเมฆฝนฟ้าคะนองหรือเมฆคิวมูโลนิมบัส แต่เมฆหรือฝนจะเกิดขึ้นหรือไม่ขึ้นอยู่กับอากาศผิวพื้นถ้ามีความชื้นเพียงพอ ก็จะทำให้เกิดเมฆและฝน โดยเฉพาะฝนฟ้าคะนองในบางพื้นที่ ฝนฟ้าคะนองที่เกิดขึ้นส่วนใหญ่จะเกิดบริเวณด้านหน้าของคลื่น แต่เมื่อคลื่นกระแสลมตะวันตกเคลื่อนผ่านไปอากาศด้านหลังคลื่นจะมีลักษณะจมตัว ทำให้อุณหภูมิจะลดลงและท้องฟ้าปลอดโปร่ง (Weerid Hooncharoen, 2015)

4.6.7 คลื่นกระแสลมตะวันออก (Easterly Wave) การเคลื่อนที่ระบบลมที่พัดจากทิศตะวันออกที่วิเคราะห์เห็นเป็นลักษณะของคลื่นในเขตร้อน แถบลมที่พัดเป็นลักษณะคลื่นจากทิศตะวันออกไปทางทิศตะวันตก โดยทั่วไปเคลื่อนที่ได้ช้ามากกว่าลมที่พัดปกติที่เป็นอยู่ แม้ว่าจะอธิบายคุณลักษณะที่ดีที่สุดในแง่ของคลื่นในด้านลม ระบบนี้ยังประกอบไปด้วยท้องคลื่นของหย่อมความกดอากาศต่ำ คลื่นกระแสลมฝ่ายตะวันออกไม่แผ่ไปทั่วแนวของเส้นศูนย์สูตรไปทางทิศตะวันตกของแนวร่องความกดอากาศต่ำ ในคลื่นกระแสลมฝ่ายตะวันออกเหนือมหาสมุทรมีการตรวจพบการลู่ออกได้ทั่วไป ชั้นความชื้นของอากาศที่ตื้นและอากาศดีเป็นพิเศษหรืออากาศจมตัวไม่มีเมฆท้องฟ้าแจ่มใส ชั้นความชื้นอากาศที่เพิ่มขึ้นอย่างรวดเร็วใกล้แนวร่องความกดอากาศต่ำและไปทางทิศตะวันออกของร่องความกดอากาศต่ำจะมีแนวลมพัดสอบที่รุนแรง โดยจะเห็นเมฆมากบนท้องฟ้า และเกิดฝนตกหนักปกคลุม รูปแบบของสภาพอากาศที่ไม่สมมาตรอาจแปรปรวนอย่างมากจากอิทธิพลลักษณะของภูมิประเทศ และรายวันถ้าคลื่นกระแสลมฝ่ายตะวันออกเคลื่อนผ่านไปยังพื้นที่ที่เป็นแผ่นดิน คลื่นกระแส

ลมฝ่ายตะวันออกในบางครั้งอาจจะเป็นตัวการในการพัฒนาจนกลายเป็นพายุหมุนเขตร้อนได้ ซึ่งอยู่ใกล้ ๆ เส้นศูนย์สูตร (วัฒนา กันบัว, 2558)

4.6.8 แนวปะทะอากาศ (Frontal) หมายถึงบริเวณที่มวลอากาศ 2 มวลที่มีสมบัติต่างกันและความเร็วในการเคลื่อนที่ต่างกันมาปะทะกัน เมื่อมวลอากาศทั้งสองมีสมบัติที่ต่างกัน ซึ่งมีอุณหภูมิและความชื้นต่างกันมากมาพบกัน จึงทำให้ไม่สามารถรวมกันได้อย่างรวดเร็ว ส่งผลให้เกิดการเปลี่ยนแปลงลักษณะของอากาศในบริเวณนั้น แนวปะทะอากาศมีความสำคัญมากต่อการเกิดพายุ และใช้เป็นข้อมูลพื้นฐานในการพยากรณ์อากาศ ส่วนหน้าของมวลอากาศจะมีการเปลี่ยนแปลงรูปร่างลักษณะของมวลอากาศที่อ่อนกว่าจะถูกดันตัวให้ลอยไปอยู่เหนือมวลอากาศเย็น เนื่องจากมวลอากาศอ่อนมีความหนาแน่นน้อยกว่ามวลอากาศเย็น แนวที่แยกมวลอากาศทั้งสองออกจากกันเรียกว่า แนวปะทะอากาศ ประเภทของแนวปะทะอากาศ (กรมอุตุนิยมวิทยา, ม.ป.ป, หน้า 50-68) ได้แก่

4.6.8.1 แนวปะทะอากาศร้อน (Warm Front) เป็นแนวปะทะอากาศที่มวลอากาศร้อนเคลื่อนที่ไปพบกับมวลอากาศเย็น มวลอากาศร้อนจะพัดทับไปบนมวลอากาศเย็น โดยมวลอากาศเย็นจะยังคงตัวบริเวณพื้นดิน มวลอากาศร้อนจะลอยตัวสูงขึ้น สภาพอากาศที่มีอยู่จริง ๆ ตามแนวปะทะอากาศร้อนนั้น ส่วนใหญ่ขึ้นอยู่กับลักษณะของมวลอากาศร้อนนั้น ๆ ก่อนที่จะถูกยกให้ลอยขึ้นไป ถ้ามวลอากาศร้อนที่ค่อย ๆ ลอยสูงขึ้นไปตามความลาดเอียงของมวลอากาศเย็นไปอย่างช้า ๆ อาจทำให้ฝนตกหนักและพายุฝนฟ้าคะนอง หรือเกิดฝนชุกฟ้าคะนอง (ฝนไล่ช้าง)

4.6.8.2 แนวปะทะอากาศเย็น (Cold Front) เป็นแนวปะทะที่อากาศเย็นเคลื่อนที่ไปแทนที่อากาศร้อน มวลอากาศเย็นเคลื่อนตัวลงมายังบริเวณที่มีละติจูดต่ำ มวลอากาศเย็นจะหนักมากกว่ามวลอากาศร้อน เมื่อมวลอากาศทั้งสองเคลื่อนที่มาพบกันมวลอากาศเย็นจะดันให้มวลอากาศร้อนที่มีความหนาแน่นน้อยกว่าลอยตัวสูงขึ้นอย่างรวดเร็ว ทำให้เกิดเป็นเมฆและฝนตกลงมา แนวปะทะอากาศเย็นอาจเห็นได้ชัดจากลักษณะของเมฆคิวมูโลนิมบัสจะก่อเป็นแนวอยู่ข้างหน้าของแนวปะทะอากาศเย็น ส่งผลให้มีฝนตกฉับพลันและอาจมีลมพัดแรงและเปลี่ยนทิศทันทีได้ แนวปะทะอากาศเย็นที่ชันมาก ๆ จะมีอยู่ระยะทางสั้น ๆ เฉพาะที่มีการยกตัวขึ้นของมวลอากาศเท่านั้น ดังนั้นฝนที่ตกในแนวปะทะอากาศเย็น จึงเป็นช่วงสั้น ๆ แต่รุนแรงมาก

4.6.8.3 แนวปะทะอากาศซ้อน (Occluded Front) เมื่อมวลอากาศเย็นเคลื่อนที่ในแนวทางติดกับแผ่นดิน จะดันให้มวลอากาศร้อนใกล้กับผิวโลกเคลื่อนที่ไปในแนวเดียวกันกับมวลอากาศเย็น มวลอากาศร้อนจะถูกมวลอากาศเย็นซ้อนตัวให้ลอยสูงขึ้นและเนื่องจากมวลอากาศเย็นเคลื่อนตัวได้เร็วกว่าจึงทำให้มวลอากาศร้อนซ้อนอยู่บนมวลอากาศเย็นเรียกลักษณะดังกล่าวได้อีกแบบว่า แนวปะทะอากาศปิด ส่งผลทำให้เกิดเมฆคิวมูโลนิมบัสและทำให้เกิดฝนตกหรือพายุฝนได้

4.6.8.4 แนวปะทะอากาศคงที่ (Stationary Front) เป็นแนวปะทะอากาศที่มวลอากาศร้อนและมวลอากาศเย็นเคลื่อนที่มาพบกัน โดยที่ไม่มีมวลอากาศใดเคลื่อนที่ไปแทนกัน ลมผิว

พื้นที่ในมวลอากาศทั้งสองจะพัดขนานกันหรือเกือบขนานกันหรือพัดออกจากแนวปะทะ ทำให้ไม่มีการเบียดเบียนหรือแทนที่ซึ่งกันและกัน จึงเกิดภาวะสมดุลของแนวปะทะอากาศขึ้น แต่จะเกิดในช่วงระยะเวลาใดเวลาหนึ่งเท่านั้น เมื่อมวลอากาศใดมีแรงผลักดันมากขึ้นจะทำให้ลักษณะของแนวปะทะอากาศเปลี่ยนไปเป็นแนวปะทะอากาศแบบอื่น ๆ ทั้งนี้ แนวปะทะอากาศคงที่มีลักษณะอากาศคล้ายกับบริเวณแนวปะทะอากาศอื่นแต่มีความรุนแรงน้อยกว่า

4.7 ปัญหาของการเปลี่ยนแปลงปริมาณน้ำฝน

การเปลี่ยนแปลงของสภาพภูมิอากาศส่งผลกระทบต่อทั่วโลกและส่งผลกระทบต่อปริมาณน้ำฝน ทำให้รูปแบบการตกของฝนและการกระจายตัวของฝนเปลี่ยนแปลงไปจากเดิม ปริมาณน้ำฝนที่ตกลงมาเปลี่ยนไป พื้นที่ที่ไม่เคยมีฝนตกก็ตก พื้นที่ที่ตกอยู่แล้วก็ตกหนักขึ้น บางพื้นที่ปริมาณฝนหายไปเลยก็มี (Singh et al., 2017) พื้นที่ลุ่มน้ำในประเทศไทยได้รับผลกระทบจากการเปลี่ยนแปลงของสภาพภูมิอากาศเช่นเดียวกับพื้นที่ลุ่มน้ำอื่น ๆ ทั่วโลก โดยเฉพาะอย่างยิ่งผลกระทบต่อปริมาณน้ำฝน ทำให้มีแนวโน้มเปลี่ยนแปลงไปจากอดีต โดยในปัจจุบันมีความรุนแรงและความถี่เพิ่มมากขึ้นในแต่ละรอบปี นอกจากนี้ยังมีงานวิจัยหลายงานชี้ให้เห็นการเปลี่ยนแปลงของสภาพภูมิอากาศที่ส่งผลกระทบต่อปริมาณน้ำฝน ทำให้ฝนไม่ตกต้องตามฤดูกาล ฝนตกล่าช้าหรือบางครั้งฝนตกในปริมาณน้อยทำให้เกิดความแห้งแล้งหรือเกิดพายุฝนจนน้ำท่วม (Almazroui, Balkhair, Islam, & Şen, 2017; Hettiarachchi, Wasko, & Sharma, 2018; Parajuli, Devkota, Adhikari, Dhakal, & Kayastha, 2015; Tahir, Hashim, & Yusof, 2018) ปัญหาของการเปลี่ยนแปลงปริมาณน้ำฝนที่พบมีดังนี้

4.7.1 ถ้าปริมาณน้ำฝนน้อยกว่าปกติเป็นสาเหตุของการเกิดภัยแล้ง ภัยแล้งคือ ภัยที่เกิดจากการขาดแคลนน้ำในพื้นที่ใดพื้นที่หนึ่งเป็นเวลานาน จนก่อให้เกิดความแห้งแล้ง (Drought) และส่งผลกระทบต่อชุมชน ซึ่งความแห้งแล้งเนื่องมาจากขาดฝนเป็นระยะเวลายาวนานกว่าปกติหรือมีฝนตกแต่ปริมาณน้ำฝนน้อยกว่าค่าปกติ อากาศร้อนและแห้งแล้งปกคลุมพื้นที่บริเวณกว้าง มีการระเหยของน้ำจากพื้นดินและพืชมาก ทำให้พืชขาดน้ำ ผลผลิตลดลง พืช สัตว์และคน อาจถึงตายได้ เพราะอากาศร้อนและขาดแคลนอาหาร องค์การอุตุนิยมวิทยาโลกกำหนดลักษณะของความแห้งแล้งไว้ว่าเป็นสภาวะที่ปริมาณฝนเฉลี่ยหรือปริมาณน้ำใต้ดินเฉลี่ยมีค่าต่ำกว่าปกติในช่วงระยะเวลาหนึ่ง และกำหนดว่าพื้นที่ประสบภัยแล้งคือ พื้นที่ที่ปริมาณฝนรวมรายปีต่ำกว่า 60% ของค่าปกติและมีความแห้งแล้งติดต่อกันตั้งแต่ 2 ปีขึ้นไป รวมทั้งพื้นที่ที่เกิดความแห้งแล้งมากกว่า 50% ของพื้นที่ทั้งหมด ผลกระทบที่เกิดจากภัยแล้ง เช่น พื้นดินขาดน้ำ พืชมีผลผลิตลดลงและอาจทำให้พืชตายได้ มนุษย์และสัตว์ขาดแคลนน้ำอุปโภคและบริโภค อาจมีผลกระทบต่อสุขภาพอนามัย การขาดแคลนน้ำในภาคอุตสาหกรรม ทำให้อุตสาหกรรมหยุดชะงักส่งผลกระทบต่อด้านเศรษฐกิจ ผลผลิตการเกษตรลด

น้อยลง ทำให้สินค้าบางอย่างขาดแคลน ราคาสินค้าสูงขึ้น รัฐต้องสูญเสียเงินงบประมาณช่วยผู้ประสบภัยแล้งมากขึ้น เป็นต้น

ในฐานะที่ประเทศไทยเป็นประเทศเกษตรกรรม ทรัพยากรน้ำจึงถือเป็นปัจจัยหนึ่งที่สำคัญต่อการพัฒนาประเทศ ปัญหาทรัพยากรน้ำอันดับต้น ๆ ของไทยที่สำคัญคือ ปัญหาการขาดแคลนน้ำและสถานะแห้งแล้ง ในประเทศไทยภาวะแห้งแล้งขาดน้ำ จะเกิดขึ้นในหน้าแล้งและหน้าร้อน มีสาเหตุมาจากฝนทิ้งช่วงเป็นเวลานาน ทำให้แหล่งน้ำตามธรรมชาติแห้งไม่เพียงพอต่อการอุปโภคบริโภคของประชาชน ซึ่งปรากฏการณ์ฝนทิ้งช่วงเป็นเวลานานนี้ก็เกิดเป็นผลต่อเนื่องมาจากสถานะที่โลกร้อนขึ้น ปัญหาภัยแล้งที่เกิดขึ้นในแต่ละพื้นที่นั้นส่งผลกระทบต่อการดำรงชีวิตของประชาชนในหลายด้าน เช่น ด้านเศรษฐกิจทำให้เกิดความสูญเสียผลผลิตทางการเกษตร ปศุสัตว์ การประมง ป่าไม้ และเศรษฐกิจทั่วไป ด้านสิ่งแวดล้อมโดยรวม ทำให้ขาดแคลนน้ำ ทำให้ระดับน้ำมีปริมาณลดลง พื้นที่ชุ่มน้ำลดลง การเกิดโรคภัยสัตว์ คุณภาพน้ำเปลี่ยนแปลง เกิดการกัดเซาะของดิน ปัญหาไฟป่าเพิ่มมากขึ้นส่งผลให้เกิดผลกระทบต่อสถานะอากาศ ด้านสังคมส่งผลกระทบต่อความเป็นอยู่ของประชาชนในด้านสุขภาพอนามัย ทำให้เกิดโรคระบาดต่าง ๆ เกิดปัญหาความขัดแย้ง เรื่องการใช้น้ำ ทำให้การจัดการคุณภาพชีวิตประชาชนลดลง (เสกศึก สำราญสุข และมนสิชา เพชรานนท์, 2560)

4.7.2 ถ้าปริมาณน้ำฝนมากกว่าปกติเป็นสาเหตุของการเกิดอุทกภัย อุทกภัยคือ ภัยและอันตรายที่เกิดจากสภาวะน้ำท่วมหรือน้ำท่วมฉับพลัน มีสาเหตุมาจากการเกิดฝนตกหนักหรือฝนต่อเนื่องเป็นเวลานาน ฝนที่มาเร็วกว่าปกติ ปริมาณน้ำฝนเฉลี่ยที่มากกว่าทุกปี นอกจากนี้อาจเกิดจากจำนวนพายุที่เคลื่อนตัวเข้าสู่ประเทศไทยที่มากกว่าปีอื่น ๆ ลักษณะของอุทกภัยมีความรุนแรงและรูปแบบต่าง ๆ กัน ขึ้นอยู่กับลักษณะภูมิประเทศและสิ่งแวดล้อมของแต่ละพื้นที่โดยมีลักษณะดังนี้ 1) น้ำป่าไหลหลากหรือน้ำท่วมฉับพลัน มักจะเกิดขึ้นในที่ราบต่ำหรือที่ราบลุ่มบริเวณใกล้ภูเขาต้นน้ำเกิดขึ้นเนื่องจากฝนตกหนักเหนือภูเขาต่อเนื่องเป็นเวลานาน ทำให้จำนวนน้ำสะสมมีปริมาณมากจนพื้นดินและต้นไม้ดูดซับไม่ไหวไหลบ่าลงสู่ที่ราบต่ำ เบื้องล่างอย่างรวดเร็ว มีอำนาจทำลายร้ายรุนแรงระดับหนึ่ง ทำให้บ้านเรือนพังทลายเสียหายและอาจทำให้เกิดอันตรายถึงชีวิตได้ 2) น้ำท่วมหรือน้ำท่วมขัง เป็นลักษณะของอุทกภัยที่เกิดขึ้นจากปริมาณน้ำสะสมจำนวนมาก ที่ไหลบ่าในแนวระนาบจากที่สูงไปยังที่ต่ำเข้าท่วมอาคารบ้านเรือน เรือกสวนไร่นาได้รับความเสียหายหรือเป็นสภาพน้ำท่วมขังในเขตเมืองใหญ่ที่เกิดจากฝนตกหนักต่อเนื่องเป็นเวลานาน มีสาเหตุมาจากระบบการระบายน้ำไม่ดีพอ มีสิ่งก่อสร้างกีดขวางทางระบายน้ำหรือเกิดน้ำทะเลหนุนสูงกรณีพื้นที่อยู่ใกล้ชายฝั่งทะเล และ 3) น้ำล้นตลิ่ง เกิดขึ้นจากปริมาณน้ำจำนวนมากที่เกิดจากฝนหนักต่อเนื่องที่ไหลลงสู่ลำน้ำหรือแม่น้ำมีปริมาณมากจนระบายลงสู่ลุ่มน้ำด้านล่างหรือออกสู่ปากน้ำไม่ทัน ทำให้เกิดสภาวะน้ำล้นตลิ่งเข้าท่วมเรือกสวน ไร่นาและบ้านเรือนตามสองฝั่งน้ำ จนได้รับความเสียหาย ถนนหรือสะพานอาจชำรุด ทางคมนาคมถูกตัดขาดได้ ผลกระทบที่เกิดจากอุทกภัย เช่น คนและสัตว์อาจได้รับอันตรายถึงชีวิตจาก

การจมน้ำตาย บ้านเรือนหรืออาคารสิ่งก่อสร้างที่ไม่แข็งแรงจะถูกกระแสน้ำที่ไหลเชี่ยวพัดทำลาย ระบบสาธารณูปโภคได้รับความเสียหาย พื้นที่การเกษตรและการปศุสัตว์ได้รับความเสียหาย รวมทั้งผลผลิตที่เก็บกักตุนหรือมีไว้เพื่อทำพันธุ์จะได้รับความเสียหาย ส่งผลกระทบต่อด้านเศรษฐกิจ รายได้ของประเทศลดลง ผลกำไรจากภารกิจต่าง ๆ ถูกกระทบกระเทือน รัฐต้องมีรายจ่ายสูงขึ้นจากการซ่อมบำรุงซ่อมแซมและช่วยเหลือผู้ประสบอุทกภัย เกิดข้าวยากหมากแพงทั่วไป ความเสียหายทางด้านสุขภาพอนามัยของประชาชน ทำให้เกิดโรคระบาดและสุขภาพจิตเสื่อม เป็นโรคเครียด เป็นต้น

ตัวแบบของสภาพภูมิอากาศจากหลาย ๆ ประเทศ ชี้ว่าภายในปี 2100 เหตุการณ์น้ำท่วมรุนแรง จะเกิดเพิ่มขึ้นหลายเท่าจากแต่ก่อน โดยมีโอกาสเกิด 3-6 ครั้ง ในช่วง 100 ปี ต่างจากสมัยก่อนที่เกิดเพียง 1 ครั้งต่อ 100 ปี เขตเอเชียตะวันออกเฉียงใต้มีแนวโน้มที่จะเกิดฝนตกหนักและน้ำท่วมบ่อยครั้งขึ้น ทั้งนี้ก็เนื่องจากผลกระทบของการเปลี่ยนแปลงสภาพภูมิอากาศ (ยูฟิน ไชยสมภาร และทวี ชัยพิมลผลิน, 2560) ภาวะโลกร้อน ทำให้มีการละลายของภูเขาน้ำแข็งแถบขั้วโลกที่เพิ่มมากขึ้น เป็นเหตุให้ปริมาณน้ำในแม่น้ำและทะเลเพิ่มขึ้นตามลำดับ ในช่วง 30 ปีที่ผ่านมา พื้นที่ชุมชนของไทยมักประสบกับปัญหาอุทกภัยบ่อยครั้ง โดยส่วนใหญ่จะเกิดในเขตชุมชนที่ตั้งอยู่ในพื้นที่เสี่ยงต่อการเกิดอุทกภัย โดยเฉพาะแถบชายฝั่งด้านตะวันออกและทางใต้ของประเทศไทยซึ่งตั้งอยู่ใกล้มหาสมุทร ในเขตเมืองใหญ่อย่างกรุงเทพมหานคร หาดใหญ่และเชียงใหม่ก็ประสบปัญหาน้ำท่วมเช่นกัน โดยเฉพาะช่วงหน้าฝน ทั้งนี้ก็เนื่องจากปริมาณน้ำมีมากกว่าที่กักเก็บและระบบระบายน้ำยังไม่มีประสิทธิภาพพอ

ในปี พ.ศ. 2554 เกิดเหตุการณ์มหาอุทกภัยในกรุงเทพมหานครและปริมณฑล สร้างความเสียหายอย่างใหญ่หลวงต่อเศรษฐกิจ สังคม และสิ่งแวดล้อมของกรุงเทพมหานคร สาเหตุการเกิดอุทกภัยครั้งใหญ่นี้มาจากหลายสาเหตุคือ 1) จากภัยธรรมชาติ เช่น ฝนตกหนัก น้ำท่วม น้ำเหนือไหลหลาก น้ำทะเลหนุน เป็นต้น 2) จากลักษณะทางภูมิศาสตร์และสภาพภูมิประเทศของกรุงเทพมหานครที่มีร่องมรสุมพาดผ่านและเป็นที่ราบลุ่มน้ำท่วมถึงได้ในฤดูน้ำหลาก 3) ลักษณะทางกายภาพของเมืองที่เปลี่ยนแปลงหรือปัญหาผังเมือง กล่าวคือมีการขยายตัวของชุมชนเมืองอย่างรวดเร็วโดยขาดการกำหนดผังเมืองและการควบคุมการใช้ที่ดินอย่างเพียงพอ มีปัญหาของระบบระบายน้ำ มีการรुक้าคลองสาธารณะทำให้ไม่สามารถระบายน้ำได้ ปัญหาแผ่นดินทรุดจากการสูบน้ำบาดาล และ 4) เรื่องของเทคนิคเชิงวิศวกรรมได้แก่ ระบบระบายน้ำและความสามารถในการระบายน้ำ การสร้างถนนและการวางผังเมืองที่ไม่เหมาะสม การสร้างแหล่งชุมชนและแหล่งอุตสาหกรรมที่ขวางทางน้ำไหลหรือพื้นที่ระบายน้ำตามธรรมชาติ การระบายน้ำออกเพื่อความมั่นคง ปลอดภัยต่อแหล่งเก็บกักน้ำ ความล้มเหลวของระบบควบคุมการระบายน้ำ เป็นต้น

ปัญหาการขาดแคลนน้ำและภัยพิบัติทางธรรมชาติ ทั้งอุทกภัยและปัญหาภัยแล้งมีแนวโน้มจะเกิดขึ้นบ่อยครั้งและทวีความรุนแรงขึ้น โดยความสามารถกักเก็บน้ำเพื่อนำมาใช้งานในฤดู

แล้งมีเพียง 74,000 ล้านลูกบาศก์เมตร สามารถใช้ได้จริงเพียงปีละ 55,000 ล้านลูกบาศก์เมตร สมองความต้องการใช้น้ำได้ เฉพาะในพื้นที่ชลประทานเท่านั้น ขณะที่ความต้องการใช้น้ำจะเพิ่มขึ้นจาก 57,452 ล้านลูกบาศก์เมตรต่อปี ในปี 2559 โดยภาคกลางมีความต้องการใช้น้ำมากที่สุด รองลงมาคือ ภาคตะวันออกเฉียงเหนือ ภาคเหนือและภาคใต้ ตามลำดับ ดังนั้นโอกาสที่ความรุนแรงของปัญหาการขาดแคลนน้ำและความขัดแย้งจากการแย่งชิงน้ำระหว่างลุ่มน้ำและระหว่างภาคการผลิตจะเพิ่มสูงขึ้นในทุกสาขาการผลิต ทั้งนี้หมู่บ้านที่มีความเสี่ยงต่อการเกิดภัยแล้งในระดับปานกลางถึงระดับรุนแรง สาเหตุสำคัญเกิดจากพื้นที่ที่เป็นป่าต้นน้ำถูกบุกรุกทำลาย การขาดแคลนน้ำจากการที่ปริมาณน้ำฝนมีความแปรปรวนในหลายพื้นที่ (ฐกร กาญจนจิรเดช และคณะ, 2561)

4.8 ปรากฏการณ์เอลนีโญ (El Niño) กับปริมาณน้ำฝนในประเทศไทย


เอลนีโญทำให้เกิดฝนตกหนักในตอนเหนือของทวีปอเมริกาใต้และเกิดความแห้งแล้งในเอเชียตะวันออกเฉียงใต้ (Yu, Zhong, Heilman, & Bian, 2017) เอลนีโญเป็นปรากฏการณ์หนึ่งที่เกิดจากความผิดปกติของอุณหภูมิที่ผิวน้ำทะเลบริเวณมหาสมุทรแปซิฟิก ซึ่งสืบเนื่องจากการเปลี่ยนแปลงของลมในบรรยากาศและการไหลเวียนของน้ำในมหาสมุทร ลมจะพัดผิวน้ำทะเลที่อุ่นบริเวณเส้นศูนย์สูตรทางมหาสมุทรแปซิฟิกตะวันออก ไหลไปแทนกระแสน้ำเย็นที่ไหลอยู่เดิมบริเวณเส้นศูนย์สูตรทางมหาสมุทรแปซิฟิกตะวันตกและบริเวณชายฝั่งตะวันตกเฉียงเหนือของทวีปอเมริกาใต้ ทำให้อากาศเหนือน้ำทะเลในบริเวณดังกล่าวเกิดการลอยตัวสูงขึ้นกลายเป็นเมฆฝน ส่งผลให้ทางตะวันตกของมหาสมุทรแปซิฟิกมีฝนตกชุกกว่าทางตะวันออกของมหาสมุทรแปซิฟิก (Shehu, Yelwa, Sawa, & Adegbehin, 2016) เอลนีโญเกิดขึ้นเนื่องจากพื้นผิวโลกรับความร้อนจากดวงอาทิตย์แตกต่างกัน โดยบริเวณเส้นศูนย์สูตรจะรับความร้อนมากกว่าขั้วโลกเหนือและขั้วโลกใต้ น้ำทะเลและอากาศจะเป็นตัวพาความร้อนจากเส้นศูนย์สูตรไปยังขั้วโลกทั้งสอง เกิดเป็นวงจรถ่ายเทความร้อนเกิดขึ้น น้ำทะเลระดับพื้นผิวจะร้อนจนระเหยกลายเป็นไอ เปิดให้น้ำทะเลที่อยู่ข้างใต้ขึ้นมาอยู่ในระดับพื้นผิวและระเหยกลายเป็นไอ เกิดอย่างนี้ไปเรื่อย ๆ ผลกระทบที่เกิดกับประเทศไทยเป็นผลกระทบทางอ้อมจากการเปลี่ยนแปลงของอุณหภูมิ น้ำทะเล เคลื่อนที่ออกไปทางตะวันออกของมหาสมุทรแปซิฟิกมากขึ้น ส่งผลให้อากาศเหนือบริเวณนี้เกิดการลอยตัวและเกิดเป็นเมฆฝน ทำให้อากาศบริเวณทางตะวันตกของมหาสมุทรแปซิฟิกมีการก่อตัวของเมฆฝนน้อยลง ดังนั้นในช่วงดังกล่าว ทำให้อากาศบริเวณทางตะวันตกของมหาสมุทรแปซิฟิกในบริเวณใกล้เส้นศูนย์สูตรมีความแห้งแล้งมากกว่าปกติ ปรากฏการณ์เอลนีโญเป็นตัวบ่งบอกถึงความแห้งแล้งในแถบเอเชียตะวันออกเฉียงใต้รวมถึงประเทศไทย โดยเฉพาะฤดูฝน กล่าวคือในช่วงฤดูฝนปริมาณฝนในแถบเอเชียตะวันออกเฉียงใต้รวมถึงประเทศไทย ส่วนใหญ่มีฝนลดลงซึ่งส่งผลต่อความเป็นอยู่ของมนุษย์และสิ่งมีชีวิตอื่น ๆ (ปริญ หล่อพิทยากร, 2560) ปรากฏการณ์เอลนีโญเกิดขึ้นเกือบทุกปีและส่งผลให้อากาศแปรปรวนมากกว่าในอดีต ดังนั้นการเตรียมพร้อมรับมือกับปัญหาภัยแล้งที่มีแนวโน้มเกิดบ่อยขึ้นและทวีความรุนแรงมากขึ้นมี

ความสำคัญอย่างยิ่ง เนื่องจากประชากรส่วนใหญ่ของประเทศไทยประกอบอาชีพเกษตรกรรมและต้องดำรงชีวิตอยู่ด้วยการอาศัยทรัพยากรธรรมชาติคือ แหล่งน้ำเป็นปัจจัยหลัก เช่น จากปรากฏการณ์เอลนีโญ ในปี พ.ศ. 2558-2559 ทำให้หลายประเทศทั่วโลกประสบกับปัญหาการขาดแคลนน้ำ ซึ่งถือว่าเป็นภัยที่มีความรุนแรงมากในรอบ 100 ปีที่ผ่านมา (ยุพิน ไชยสมภาร และทวี ชัยพิมลผลิน, 2560)

4.9 ปรากฏการณ์ลานีญา (La Niña) กับปริมาณน้ำฝนในประเทศไทย

ลานีญาทำให้เกิดความแห้งแล้งทางตอนเหนือของทวีปอเมริกาใต้และเกิดฝนตกหนักในเอเชียตะวันออกเฉียงใต้ (Feng & Wang, 2018) ปรากฏการณ์ลานีญามีลักษณะตรงข้ามกับปรากฏการณ์เอลนีโญ กล่าวคือ เป็นปรากฏการณ์ที่อุณหภูมิผิวน้ำทะเลบริเวณเส้นศูนย์สูตรในมหาสมุทรแปซิฟิกกลางและตะวันออกเฉียงใต้มีค่าต่ำกว่าปกติอุณหภูมิผิวน้ำในมหาสมุทรแปซิฟิกฝั่งประเทศไทยสูงขึ้น ในขณะที่อุณหภูมิในมหาสมุทรฝั่งอเมริกาเย็นลง ลมซึ่งเคลื่อนที่จากบริเวณที่มีอุณหภูมิอากาศต่ำกว่าไปสู่บริเวณที่มีอุณหภูมิอากาศสูงกว่า จึงพัดพาความชื้นจากฝั่งอเมริกามาสู่ประเทศไทยมากกว่าปกติ ทำให้เกิดฝนตกชุกในประเทศไทย มีผลทำให้ปริมาณน้ำฝนมากกว่าปกติ ปรากฏการณ์ลานีญาเป็นตัวที่บ่งบอกถึงความชุ่มชื้นในแถบเอเชียตะวันออกเฉียงใต้รวมถึงประเทศไทยโดยเฉพาะฤดูฝน ในช่วงฤดูฝนปริมาณฝนในแถบเอเชียตะวันออกเฉียงใต้รวมถึงประเทศไทยส่วนใหญ่มีฝนมากขึ้น ทำให้มีโอกาสเสี่ยงในการเกิดอุทกภัยมากขึ้น ส่งผลกระทบต่อภาคเกษตรกรรมและการดำรงชีวิตของสิ่งมีชีวิต (ปริญ หล่อพิทยากร, 2561)

ทั้งเอลนีโญและลานีญาเกิดจากความผกผันของกระแสอากาศโลกบริเวณเส้นศูนย์สูตรเหนือมหาสมุทรแปซิฟิก ซึ่งยังไม่สามารถระบุสาเหตุที่แน่ชัด ภาพถ่ายจากดาวเทียมโทเพกซ์/โพซีดอน (Topex/Poseidon) (NASA) ในภาพที่ 2-13 แสดงให้เห็นความต่างระดับของน้ำทะเลบนพื้นผิวมหาสมุทรแปซิฟิก สีขาวแสดงระดับน้ำซึ่งสูงกว่าระดับน้ำทะเลปานกลาง 14 เซนติเมตร สีม่วงหรือสีเข้มแสดงระดับน้ำซึ่งต่ำกว่าระดับน้ำทะเลประมาณ -18 เซนติเมตร ขณะที่เกิดลานีญา-เอลนีโญ



ภาพที่ 2-13 ความต่างระดับของน้ำทะเลบนพื้นผิวมหาสมุทรแปซิฟิกขณะที่เกิดลานีญา-เอลนีโญ

4.10 สถานการณ์ปริมาณน้ำฝน

ข้อมูลปริมาณน้ำฝนที่เก็บมาจากทั่วโลกพบว่า ปริมาณน้ำฝนเริ่มมีมากขึ้นเรื่อย ๆ ปริมาณน้ำฝนที่เพิ่มขึ้นอย่างมาก เนื่องจากการเปลี่ยนแปลงสภาพภูมิอากาศ นอกจากนั้นสำหรับประเทศไทยที่ได้รับอิทธิพลของแนวร่องมรสุมที่ไม่เหมือนกันในแต่ละพื้นที่ ส่งผลทำให้ในแต่ละพื้นที่มีปริมาณน้ำฝนที่แตกต่างกันออกไป (สุทธิศักดิ์ ศรลัมพ์ และธีรไฉย น้อยมาก, 2556)

4.11 การพยากรณ์ปริมาณน้ำฝน

การพยากรณ์ปริมาณน้ำฝนมีบทบาทสำคัญในหลากหลายสาขา เช่น การเกษตรกรรม การบิน การบริหารจัดการน้ำ การขนส่ง เป็นต้น (Tokle & Joshi, 2016; Wahyuni et al., 2018) โดยเฉพาะอย่างยิ่งการพยากรณ์ปริมาณน้ำฝนยังเป็นที่ต้องการอย่างมากในการเกษตรกรรม ซึ่งเป็นปัจจัยสำคัญต่อเศรษฐกิจของหลาย ๆ ประเทศ (Abdulkadir, Salami, & Kareem, 2012; Navid & Niloy, 2018) ดังนั้นความถูกต้องของการพยากรณ์จึงเป็นสิ่งที่สำคัญ การพยากรณ์ปริมาณน้ำฝนถือเป็นสิ่งที่ท้าทาย เนื่องจากความไม่แน่นอนของปรากฏการณ์ทางธรรมชาติ และเป็นเรื่องที่มีความซับซ้อน (เปรม รังสิวณิชพงศ์ และคณะ, 2558; Arya & Pai, 2018; Purnomo et al., 2017) การพยากรณ์ปริมาณน้ำฝนขึ้นอยู่กับหลายปัจจัยได้แก่ ตัวแปรที่ใช้ในการพยากรณ์ พิกัดทางภูมิศาสตร์ ภูมิประเทศ ภูมิภาค ฤดูกาล วิธีการที่นำมาใช้ในการสร้างตัวแบบพยากรณ์ซึ่งพิจารณาจากงานวิจัยที่ผ่านมา โดยมีรายละเอียดต่าง ๆ ดังนี้

4.11.1 ปริมาณน้ำฝน (Rainfall)

ปริมาณน้ำฝน หมายถึงระดับน้ำฝนในภาชนะที่รองรับน้ำฝน ทั้งนี้ภาชนะที่รองรับน้ำฝนจะต้องตั้งอยู่ในแนวระดับและวัดในช่วงเวลาที่กำหนด ขนาดของเม็ดฝนมีเส้นผ่านศูนย์กลางใหญ่กว่า 0.5 มิลลิเมตร หรือโดยเฉลี่ยประมาณ 2 มิลลิเมตร ความเร็วเฉลี่ยในการตกประมาณ 25 กม./ชม. ถ้าฝนที่ตกหนักขนาดของเม็ดฝนใหญ่จะเกิดขึ้นในเวลาสั้น ๆ แต่ฝนที่ตกเบาขนาดเม็ดฝนจะเล็ก จะมีเวลาในการตกยาวนานขึ้น (รังสรรค์ อากาศัพพะกุล, 2547, หน้า 178) ปริมาณน้ำฝนที่ตกลงมาในบริเวณนั้นตรวจวัดได้จากการใช้เครื่องมือวัดปริมาณน้ำฝน (Rain Gauge) หน่วยที่ใช้วัดปริมาณน้ำฝนเป็นหน่วยความสูง เช่น มิลลิเมตรหรือนิ้ว เป็นต้น นิยมใช้เป็นมิลลิเมตร (มม.)

4.11.2 ข้อมูลอุตุนิยมวิทยาที่เกี่ยวข้อง

4.11.2.1 พิกัดทางภูมิศาสตร์ของประเทศไทย

สถานที่แต่ละแห่งบนพื้นผิวโลกมีที่ตั้ง แตกต่างกันไปตามละติจูด ซึ่งมีผลต่อการได้รับแสงอาทิตย์และระยะเวลาในการรับแสงอาทิตย์ ทำให้เกิดการแปรผันของลมฟ้าอากาศ เช่น ในเขตละติจูดต่ำจะมีอากาศร้อน ส่วนบริเวณละติจูดสูงจะมีอากาศหนาวเย็นกว่า (ปานทิพย์ วัฒนวานิช, 2553, หน้า 113) ประเทศไทยตั้งอยู่ในคาบสมุทรอินโดจีน อยู่ทางทิศตะวันออกเฉียงใต้ของทวีปเอเชีย มีตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 5 องศา 37 ลิปดาถึง 20 องศา 28 ลิปดาเหนือ และมี

ตำแหน่งลองจิจูดที่ 97 องศา 21 ลิปดาถึง 105 องศา 37 ลิปดาตะวันออก จึงอยู่ในเขตร้อน ทำให้มี อุณหภูมิสูงตลอดปี มีทะเล ลมและฝนเป็นปัจจัยให้เกิดป่าดง ประกอบด้วยพันธุ์ไม้เขตร้อนและสัตว์ป่านานาชนิด นับว่าเป็นแหล่งที่มีความอุดมสมบูรณ์ด้วยอาหาร และทรัพยากรที่สำคัญแห่งหนึ่งของทวีปเอเชีย ประเทศไทยมีพิกัดภูมิศาสตร์ ดังนี้

4.11.2.2 จุดเหนือสุด พื้นที่อำเภอแม่สาย จังหวัดเชียงราย ละติจูด 99 องศา 58 ลิปดาตะวันออก

4.11.2.3 จุดใต้สุด พื้นที่อำเภอเบตง จังหวัดยะลา ละติจูดที่ 5 องศา 37 ลิปดาเหนือ และลองจิจูด 101 องศา 08 ลิปดาตะวันออก

4.11.2.4 จุดตะวันออกสุด พื้นที่อำเภอศรีเมืองใหม่ จังหวัดอุบลราชธานี ละติจูด 15 องศา 38 ลิปดาเหนือ และลองจิจูดที่ 105 องศา 37 ลิปดาตะวันออก

4.11.2.5 จุดตะวันตกสุด พื้นที่อำเภอแม่สะเรียง จังหวัดแม่ฮ่องสอน ละติจูด 18 องศา 34 ลิปดาเหนือและลองจิจูดที่ 97 องศา 21 ลิปดาตะวันออก

4.11.3 ลักษณะภูมิประเทศของประเทศไทย

ประเทศไทยเป็นประเทศเล็ก ลักษณะภูมิประเทศและลมฟ้าอากาศส่วนใหญ่ คล้ายคลึงกัน แตกต่างกันบ้างเพียงเล็กน้อย ลักษณะภูมิประเทศของประเทศไทยแบ่งออกเป็น 6 ลักษณะ Sweet Eyes (2012) กล่าวไว้ดังนี้

4.11.3.1 เขตที่ราบภาคกลาง เป็นที่ราบดินตะกอนที่หนาแน่นถือเป็นเขตที่ราบที่ใหญ่ที่สุดของประเทศไทยเป็นแหล่งเกษตรกรรมที่สำคัญ เนื่องจากดินบริเวณดังกล่าวเป็นดินตะกอนที่แม่น้ำพัดพามาทับถม ทำให้ดินมีความอุดมสมบูรณ์ เป็นบริเวณอยู่อาศัยน้ำสำคัญและเป็นเขตที่มีประชากรหนาแน่นที่สุดของประเทศอีกด้วยได้แก่ บริเวณที่ราบลุ่มแม่น้ำเจ้าพระยา แม่น้ำท่าจีน แม่น้ำแม่กลอง แม่น้ำป่าสักและแม่น้ำบางปะกง ฯลฯ

4.11.3.2 เขตภูเขาและที่ราบระหว่างภูเขาภาคเหนือ ภูมิประเทศส่วนใหญ่เป็นทิวเขา ภูเขาและที่ราบระหว่างเขา (แอ่งแผ่นดิน) ที่สูงเหล่านี้เป็นต้นกำเนิดของแม่น้ำลำธารหลายสายที่ไหลลงแม่น้ำโขงทางด้านเหนือลงสู่แม่น้ำเจ้าพระยาทางด้านใต้ และแม่น้ำสาละวินทางตะวันตก ที่ราบระหว่างเขาที่แม่น้ำไหลผ่านจะเกิดที่ราบดินตะกอนที่แม่น้ำไหลมาทับถมกัน ทำให้เกิดความอุดมสมบูรณ์เหมาะในการเพาะปลูกและการตั้งถิ่นฐานจนกลายเป็นแหล่งชุมชนที่สำคัญ เช่น ที่ราบลุ่มแม่น้ำปิง ลุ่มแม่น้ำวัง ลุ่มแม่น้ำยม ลุ่มแม่น้ำน่าน เป็นต้น

4.11.3.3 เขตที่ราบสูงภาคตะวันออกเฉียงเหนือ ภูมิประเทศแยกจากภาคเหนือและภาคกลางอย่างเด่นชัด โดยมีขอบสูงชันตามแนวทิวเขาเพชรบูรณ์ ทิวเขาพญาเย็นทางด้านตะวันตก ด้านใต้ตามแนวทิวเขาสันกำแพง ทิวเขาพนมดงรัก ตอนกลางเป็นแอ่งคล้ายกันกระหะเรียกว่า แอ่งโคราช มีแม่น้ำชีและแม่น้ำมูลไหลผ่าน และไหลลงสู่แม่น้ำโขงทางทิศตะวันออกที่จังหวัด

อุบลราชธานี ปัญหาสำคัญของเขตนี้คือ การขาดแคลนน้ำและดินขาดความอุดมสมบูรณ์ทำให้บางพื้นที่ไม่สามารถใช้ประโยชน์จากการเกษตรได้ เช่น ทุ่งกุลาร้องไห้ ซึ่งครอบคลุมพื้นที่ถึง 5 จังหวัด เป็นต้น

4.11.3.4 เขตภูเขาสูงภาคตะวันตก ลักษณะภูมิประเทศส่วนใหญ่เป็นทิวเขาและหุบเขาทิวเขายาวต่อเนื่องเรียงซ้อนกันในแนวเหนือใต้ ไม่มีที่ราบระหว่างเขาเหมือนภาคเหนือ ทิวเขาที่สำคัญ ได้แก่ ทิวเขาถนนธงชัย ตะนาวศรี ซึ่งเป็นแหล่งกำเนิดแม่น้ำสายสำคัญ คือ แม่น้ำแควใหญ่ (ศรีสวัสดิ์) แม่น้ำแควน้อย (ไทรโยค) ที่ไหลมาบรรจบกันเป็นแม่น้ำแม่กลอง

4.11.3.5 เขตภูเขาและที่ราบชายฝั่งภาคตะวันออก เป็นที่ราบลุ่มแม่น้ำทางตอนเหนือ เป็นทิวเขา ที่ราบลูกฟูกทางตอนกลางและที่ราบชายฝั่งทะเลทางใต้ มีทิวเขาจันทบุรีและทิวเขาตะนาวศรี วางตัวในแนวตะวันออกและตะวันตก ทำให้ภาคภาคตะวันออกตอนบนมีลักษณะภูมิประเทศเป็นที่ราบลุ่มแม่น้ำบางปะกงและตอนล่างเป็นที่ราบชายฝั่งทะเล ลักษณะชายฝั่งเว้าแหว่งเต็มไปด้วยเกาะน้อยใหญ่ มีหาดทรายที่สวยงาม ระหว่างทิวเขาจันทบุรีกับอ่าวไทยมีลักษณะเป็นที่ราบแคบ ๆ พื้นดินมีความอุดมสมบูรณ์เหมาะแก่การเพาะปลูกผลไม้

4.11.3.6 เขตภูเขา ที่ราบสูง ที่ราบชายฝั่งทะเลและหมู่เกาะต่าง ๆ ทางภาคใต้ มีลักษณะเป็นคาบสมุทรแคบ ๆ ยาวไปทางใต้มีทะเลขนานทั้งสองด้าน คือ ด้านอ่าวไทย (ตะวันออก) และด้านอันดามัน (ตะวันตก) ลมฟ้าอากาศส่วนใหญ่คล้ายคลึงกัน แตกต่างกันอย่างเล็กน้อย แต่แตกต่างกับภาคอื่น ๆ ของประเทศไทย ไม่ว่าจะเป็นด้านสภาพภูมิอากาศ ภูมิประเทศและทรัพยากร ลักษณะภูมิประเทศเป็นทิวเขา ประกอบด้วยทิวเขาสำคัญได้แก่ ทิวเขาภูเก็ต ทิวเขานครศรีธรรมราช และทิวเขาสันกาลาคีรี ที่ราบชายฝั่งอ่าวไทยและที่ราบชายฝั่งอันดามัน โดยที่ราบชายฝั่งอ่าวไทยอยู่ทางตะวันออกของภาคมีลักษณะเป็นอ่าวขนาดใหญ่กระจัดกระจาย ชายฝั่งค่อนข้างเรียบตรงและมีหาดทรายสวยงาม และยังมีส่วนที่เป็นหาดเลน และโคลนซึ่งเป็นป่าชายเลน ลักษณะเด่นคือ มีแหลมที่เกิดจากการทับถมของทรายและโคลน 2 แห่งได้แก่ แหลมตะลุมพุก จังหวัดนครศรีธรรมราช และแหลมตาชี จังหวัดปัตตานี และมีทะเลสาบสงขลาเป็นทะเลสาบน้ำเค็มที่เกิดจากคลื่นและกระแสน้ำพัดพาตะกอนทรายไปทับถมเป็นแนวสันทราย ส่วนที่ราบชายฝั่งอันดามันอยู่ทางตะวันตกของภาคมีลักษณะเป็นชายฝั่งแบบยุบตัว เป็นที่ราบแคบเนื่องจากมีชายเขาและหน้าผาดัดชายฝั่ง นอกจากนี้ยังมีชายฝั่งที่เว้าแหว่งมากและนอกฝั่งออกไปบริเวณพื้นน้ำมีลักษณะลาดลึกลงไปอย่างรวดเร็ว มีหาดทรายขาวแคบ ๆ และหมู่เกาะต่าง ๆ ทางภาคใต้ ภาคใต้มีเกาะและหมู่เกาะมากมาย โดยฝั่งอ่าวไทยมีเกาะสำคัญ เช่น เกาะสมุย เกาะพะงัน หมู่เกาะอ่างทอง เป็นต้น ส่วนฝั่งอันดามันมีเกาะภูเก็ตซึ่งเป็นเกาะที่ใหญ่ที่สุดในประเทศไทย หมู่เกาะพีพี หมู่เกาะสิมิลัน เกาะตะรุเตา เป็นต้น

4.11.4 การแบ่งภูมิภาคของประเทศไทยในทางอุตุนิยมวิทยา

การแบ่งภูมิภาคของประเทศไทยในทางอุตุนิยมวิทยา พิจารณาจากรูปแบบ ภูมิอากาศ โดยแบ่งเป็น 5 ภูมิภาค ตามกรมอุตุนิยมวิทยา (ม.ป.ป.) ดังนี้

4.11.4.1 ภาคเหนือ ประกอบด้วย 15 จังหวัดได้แก่ เชียงราย แม่ฮ่องสอน เชียงใหม่ ลำพูน ลำปาง พะเยา น่าน แพร่ อุตรดิตถ์ สุโขทัย ตาก กำแพงเพชร พิษณุโลก พิจิตร และ เพชรบูรณ์ ภูมิประเทศส่วนใหญ่เป็นเทือกเขา มีภูเขา ติดกันเป็นพืดในแนวเหนือ-ใต้ สลับกับหุบเขาทั้ง แแคบและกว้างมากมาย

4.11.4.2 ภาคตะวันออกเฉียงเหนือ ประกอบด้วย 20 จังหวัดได้แก่ หนองคาย บึงกาฬ เลย หนองบัวลำภู อุตรธานี สกลนคร นครพนม มุกดาหาร กาฬสินธุ์ ขอนแก่น มหาสารคาม ร้อยเอ็ด ยโสธร อำนาจเจริญ ชัยภูมิ นครราชสีมา บุรีรัมย์ สุรินทร์ ศรีสะเกษ และอุบลราชธานี มี ลักษณะภูมิประเทศเป็นที่ราบสูงและลาดต่ำไปทางทิศตะวันออกเฉียงใต้

4.11.4.3 ภาคกลาง ประกอบด้วย 18 จังหวัดได้แก่ นครสวรรค์ อุทัยธานี ชัยนาท สิงห์บุรี ลพบุรี อ่างทอง สระบุรี สุพรรณบุรี พระนครศรีอยุธยา กาญจนบุรี ราชบุรี นครปฐม นนทบุรี ปทุมธานี กรุงเทพมหานคร สมุทรปราการ สมุทรสงคราม และสมุทรสาคร ภูมิประเทศส่วนใหญ่เป็นที่ราบลุ่ม ระดับพื้นที่ลาดลงมาทางใต้ตามลำดับจนถึงอ่าวไทย ในภาคนี้มีภูเขาบ้างแต่ส่วนใหญ่เป็นภูเขาที่ไม่สูงมาก เว้นแต่ทางด้านตะวันตกใกล้ชายแดนประเทศพม่า

4.11.4.4 ภาคตะวันออก ประกอบด้วย 8 จังหวัดได้แก่ นครนายก ฉะเชิงเทรา ปราจีนบุรี สระแก้ว ชลบุรี ระยอง จันทบุรีและตราด ลักษณะภูมิประเทศเป็นเทือกเขาและที่ราบ

4.11.4.5 ภาคใต้ เป็นคาบสมุทรขนานด้วยทะเลสองด้าน ด้านตะวันตกขนานด้วยทะเลอันดามัน ด้านตะวันออกด้วยทะเลอ่าวไทยที่เป็นส่วนหนึ่งของทะเลจีนใต้ แบ่งภาคนี้เป็น 2 ส่วนคือ 1. ภาคใต้ฝั่งตะวันออก เป็นส่วนที่ราบชายฝั่งทะเลด้านตะวันออกติดกับทะเลอ่าวไทยซึ่งมีอาณาเขตกว้างขวาง ประกอบด้วย 10 จังหวัดได้แก่ เพชรบุรี ประจวบคีรีขันธ์ ชุมพร สุราษฎร์ธานี นครศรีธรรมราช พัทลุง สงขลา ปัตตานี ยะลา และนราธิวาส 2. ภาคใต้ฝั่งตะวันตกเป็นส่วนที่ราบ ด้านตะวันตกขนานกับชายฝั่งทะเลอันดามันและช่องแคบมะละกา ซึ่งเป็นบริเวณแคบกว่าที่ราบด้าน ตะวันออก ประกอบด้วย 6 จังหวัดได้แก่ ระนอง พังงา ภูเก็ต กระบี่ ตรัง และสตูล

4.11.5 ฤดูกาลของประเทศไทย

เนื่องจากประเทศไทยตั้งอยู่ในเขตอิทธิพลของมรสุม จึงทำให้ประเทศไทยมีฤดูกาลที่เด่นชัด 2 ฤดู คือ ฤดูฝนกับฤดูแล้ง (Wet and Dry Seasons) สลับกัน และสำหรับฤดูแล้งนั้น ถ้าพิจารณาให้ละเอียดลงไปสามารถแยกออกได้เป็น 2 ฤดูคือ ฤดูร้อนกับฤดูหนาว กรมอุตุนิยมวิทยา (ม.ป.ป.) แบ่งฤดูกาลของประเทศไทยเป็น 3 ฤดูคือ

4.11.5.1 ฤดูร้อน เริ่มประมาณกลางเดือนกุมภาพันธ์ถึงประมาณกลางเดือน พฤษภาคม ซึ่งเป็นช่วงที่เปลี่ยนจากมรสุมตะวันออกเฉียงเหนือเป็นมรสุมตะวันตกเฉียงใต้ (หรือที่

เปลี่ยนจากฤดูหนาวเข้าสู่ฤดูฝน) เป็นระยะที่ขั้วโลกเหนือหันเข้าหาดวงอาทิตย์ โดยเฉพาะในเดือนเมษายนประเทศไทยจะเป็นประเทศหนึ่งที่ตั้งอยู่ในบริเวณที่ลำแสงของดวงอาทิตย์ จะตั้งฉากกับผิวพื้นโลกในเวลาเที่ยงวัน ทำให้ได้รับความร้อนจากดวงอาทิตย์อย่างเต็มที่ จึงทำให้สภาวะอากาศร้อนอบอ้าวโดยทั่วไป ในฤดูนี้แม้ว่าประเทศไทยอากาศจะร้อนและแห้งแล้ง แต่ในบางครั้งอาจมีมวลอากาศเย็นจากประเทศจีนแผ่ลงมาถึงประเทศไทยตอนบนได้ ทำให้เกิดการปะทะกันระหว่างมวลอากาศเย็น ที่แผ่ลงมา กับมวลอากาศร้อนที่ปกคลุมอยู่เหนือประเทศไทย ซึ่งก่อให้เกิดพายุฝนฟ้าคะนองและลมกระโชกแรงหรืออาจมีลูกเห็บตกลงมาด้วย ก่อให้เกิดความเสียหายได้ พายุฝนฟ้าคะนองที่เกิดขึ้นในฤดูนี้มักเรียกว่า "พายุฤดูร้อน"

4.11.5.2 ฤดูฝน เริ่มประมาณกลางเดือนพฤษภาคมถึงประมาณกลางเดือนตุลาคม ฤดูนี้จะเริ่มเมื่อมรสุมตะวันตกเฉียงใต้ ซึ่งเป็นลมชื้นพัดปกคลุมประเทศไทย ขณะที่ร่องความกดอากาศต่ำ (แนวร่องที่ก่อให้เกิดฝน) พาดผ่านประเทศไทยทำให้มีฝนชุกทั่วไป ร่องความกดอากาศต่ำนี้ปกติจะเริ่มพาดผ่านภาคใต้ในเดือนเมษายน แล้วจึงเลื่อนขึ้นไปพาดผ่านภาคกลางและภาคตะวันออกเฉียงเหนือและตะวันออกเฉียงเหนือ ในเดือนพฤษภาคมและมีถุนายนตามลำดับ ประมาณปลายเดือนมิถุนายนจะเลื่อนขึ้นไปพาดผ่านบริเวณประเทศจีนตอนใต้ ทำให้ฝนในประเทศไทยลดลงระยะหนึ่งและเรียกว่าเป็นช่วงฝนทิ้ง ซึ่งอาจนานประมาณ 1-2 สัปดาห์ หรือบางปีอาจเกิดขึ้นรุนแรงและมีฝนน้อยนานนับเดือนได้ ประมาณเดือนสิงหาคมถึงพฤศจิกายนร่องความกดอากาศต่ำจะเลื่อนกลับลงมาทางใต้พาดผ่านบริเวณประเทศไทยอีกครั้งหนึ่ง โดยจะพาดผ่านตามลำดับจากภาคเหนือลงไปภาคใต้ ทำให้ช่วงเวลาดังกล่าวประเทศไทยจะมีฝนชุกต่อเนื่อง โดยประเทศไทยตอนบนจะตกชุกช่วงเดือนสิงหาคมถึงกันยายนและภาคใต้จะตกชุกช่วงเดือนตุลาคมถึงพฤศจิกายน ตลอดช่วงเวลาที่ร่องความกดอากาศต่ำเลื่อนขึ้นลงนี้ ประเทศไทยก็จะได้รับอิทธิพลของมรสุมตะวันตกเฉียงใต้ ที่พัดปกคลุมอยู่ตลอดเวลา เพียงแต่บางระยะอาจมีกำลังแรง บางระยะอาจมีกำลังอ่อน ขึ้นอยู่กับตำแหน่งของแนวร่องความกดอากาศต่ำ ประมาณกลางเดือนตุลาคมมรสุมตะวันออกเฉียงเหนือ ซึ่งเป็นลมหนาวจะเริ่มพัดเข้ามาปกคลุม ประเทศไทยแทนที่มรสุมตะวันตกเฉียงใต้ ซึ่งเป็นสัญญาณว่าได้เริ่มฤดูหนาวของประเทศไทยตอนบน เว้นแต่ทางภาคใต้จะยังคงมีฝนตกชุกต่อไปจนถึงเดือนธันวาคม ทั้งนี้เนื่องจากมรสุมตะวันออกเฉียงเหนือ ที่พัดลงมาจากประเทศจีนจะพัดผ่านทะเลจีนใต้และอ่าวไทยก่อนลงไปถึงภาคใต้ ซึ่งจะนำความชื้นลงไปด้วย เมื่อถึงภาคใต้ โดยเฉพาะภาคใต้ฝั่งตะวันออกจึงก่อให้เกิดฝนตกชุกดังกล่าวข้างต้น

4.11.5.3 ฤดูหนาว เริ่มประมาณกลางเดือนตุลาคมถึงประมาณกลางเดือนกุมภาพันธ์ เมื่อมรสุมตะวันออกเฉียงเหนือเริ่มพัดปกคลุมประเทศไทยประมาณกลางเดือนตุลาคม ซึ่งจะนำความหนาวเย็นมาสู่ประเทศไทย เป็นระยะที่ขั้วโลกใต้หันเข้าหาดวงอาทิตย์ ตำแหน่งลำแสงของ

ดวงอาทิตย์ทำมุมฉากกับผิวพื้นโลกขณะเที่ยงวันจะอยู่ทางซีกโลกใต้ ทำให้ลำแสงที่ตกกระทบกับพื้น
ในประเทศไทยเป็นลำแสงเฉียงตลอดเวลา

4.12 งานวิจัยที่เกี่ยวข้องกับปริมาณน้ำฝนและการพยากรณ์ปริมาณน้ำฝน

วรารคณา กิรติวิบูลย์ (2557) ศึกษาเกี่ยวกับการสร้างตัวแบบพยากรณ์ที่เหมาะสมที่สุด
ของปริมาณน้ำฝนจังหวัดสงขลาโดยใช้อนุกรมเวลา วิธีที่นำมาใช้ได้แก่ วิธีการทำให้เรียบแบบเอกซ์
โพเนนเชียล (Exponential) ที่มีฤดูกาลอย่างง่าย วิธีบ็อกซ์-เจนกินส์ (Box and Jenkins) และวิธีการ
แยกส่วนประกอบ (Decomposition Method) ของอนุกรมเวลา เปรียบเทียบความแม่นยำของค่า
พยากรณ์ โดยใช้ค่า RMSE ที่ต่ำที่สุดเป็นเกณฑ์ ผลการศึกษาพบว่า วิธีบ็อกซ์-เจนกินส์ ที่มีตัวแบบ
SARIMA (1, 0, 0) (1, 1, 1) ไม่มีพจน์ของค่าคงที่มีความเหมาะสมกับอนุกรมเวลาชุดนี้มากที่สุด

เปรม รังสิวนิซพงษ์ และคณะ (2558) ศึกษาการพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่าย
ประสาทเทียม การพยากรณ์ฝนรายฤดูกาลในลุ่มน้ำเจ้าพระยาโดยใช้โครงข่ายประสาทเทียมพบว่า
โครงข่ายประสาทเทียมเป็นวิธีการที่มีประสิทธิภาพในการทำนายเนื่องจากผลการพยากรณ์ปริมาณฝน
เฉลี่ยราย 3 เดือนของโครงข่ายมีความใกล้เคียงกับปริมาณฝนที่ได้จากการตรวจวัด สามารถพยากรณ์
ปริมาณฝนได้ล่วงหน้าสูงสุด 12 เดือน พิจารณาความแม่นยำจากค่า R และค่า RMSE โดยมีค่า $R =$
 0.917 และ $RMSE = 0.092$

ปริญ หล่อพิทยากร (2560) ศึกษาอิทธิพลของเอลนีโญที่มีผลต่อการแพร่กระจาย
ปริมาณฝนในช่วงฤดูฝนและฤดูแล้งบริเวณภาคตะวันออกเฉียงเหนือของประเทศไทย โดยใช้ข้อมูลปริมาณฝน
ในช่วงปีภาวะปกติ (มิถุนายน พ.ศ. 2546-มิถุนายน พ.ศ. 2547 และกุมภาพันธ์ พ.ศ. 2556-ธันวาคม
พ.ศ. 2556) และข้อมูลปริมาณฝนในช่วงภาวะเอลนีโญ (มิถุนายน พ.ศ. 2545-มีนาคม พ.ศ. 2546,
มิถุนายน พ.ศ. 2552-เมษายน พ.ศ. 2553 และกันยายน พ.ศ. 2557-เมษายน พ.ศ. 2559) สำหรับ
ข้อมูลปริมาณฝนรวมในฤดูฝนของปีภาวะเอลนีโญและภาวะปกติใช้ข้อมูลเดือนพฤษภาคมถึงตุลาคม
และข้อมูลปริมาณฝนรวมในฤดูแล้งของปีภาวะเอลนีโญและภาวะปกติใช้ข้อมูลเดือนพฤศจิกายนถึง
ธันวาคมและมกราคมถึงเมษายน นำข้อมูลปริมาณฝนรวมในช่วงฤดูฝนและฤดูแล้งในปีภาวะปกติและ
ปีภาวะเอลนีโญมาประมาณค่าการแพร่กระจายปริมาณฝนทั่วพื้นที่ภาคตะวันออกเฉียงเหนือ โดยใช้โปรแกรม
Arc GIS 10.0 นำข้อมูลการแพร่กระจายของฝนในปีภาวะปกติมาจำแนกเป็น 5 ชั้นของระดับปริมาณ
ฝนในช่วงฤดูฝนและฤดูแล้ง เป็นปริมาณฝนระดับต่ำมาก ระดับต่ำ ระดับปานกลาง ระดับสูงและ
ระดับสูงมาก ที่ใช้ค่าความเบี่ยงเบนมาตรฐานในการจำแนก จากนั้นวิเคราะห์ความแตกต่างของ
ปริมาณฝนระหว่างปีภาวะเอลนีโญและปีภาวะปกติในช่วงฤดูฝนและฤดูแล้งด้วยเทคนิคการซ้อนทับ
ภาพ (Overlay) และศึกษาถึงความแตกต่างของการแพร่กระจายปริมาณฝนช่วงฤดูฝนและฤดูแล้งใน
ปีภาวะเอลนีโญกับปีภาวะปกติ โดยใช้สถิติ t-test ที่ระดับความเชื่อมั่น 95 % ผลการศึกษาพบว่า
ปริมาณฝนในช่วงฤดูฝนของปีภาวะเอลนีโญลดลงจากปีภาวะปกติทุกพื้นที่ในบริเวณภาคตะวันออกเฉียง

ของประเทศไทย อย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 สำหรับในช่วงฤดูแล้งปริมาณฝนรวมในปี ภาวะเอลนีโญลดลงจากปีภาวะปกติในบริเวณจังหวัดจันทบุรีอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 แต่ปริมาณฝนรวมเพิ่มขึ้นจากปีภาวะปกติในบริเวณจังหวัดสระแก้ว ปราจีนบุรี ฉะเชิงเทรา ชลบุรี และระยอง อย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 ส่วนจังหวัดตราดไม่มีนัยสำคัญทางสถิติที่ระดับ 0.05 ดังนั้นในช่วงฤดูแล้งของปีภาวะเอลนีโญบริเวณพื้นที่จังหวัดสระแก้ว ปราจีนบุรี ฉะเชิงเทรา ชลบุรี ระยอง และตราดควรกักเก็บน้ำไว้ใช้ในช่วงฤดูฝนของปีภาวะเอลนีโญ รวมถึงในช่วงฤดูแล้งของ ภาวะเอลนีโญควรจะมีการผันน้ำบางส่วนในบางพื้นที่มาที่บริเวณจังหวัดจันทบุรี สำหรับในช่วงฤดูฝน ของปีภาวะเอลนีโญบริเวณภาคตะวันออกเฉียงเหนือที่ทำการเกษตรควรปลูกพืชที่ใช้น้ำน้อย เพื่อแก้ปัญหาการ ใช้น้ำเพื่อการเกษตรและบรรเทาปัญหาภัยแล้งได้บ้าง

เสกศึก สาราณสุข และมนสิชา เพชรานนท์ (2560) ศึกษาเพื่อค้นหาวิธีการจัดการภัย แล้งที่เหมาะสมในพื้นที่ที่เกิดภัยแล้งซ้ำซากของจังหวัดนครราชสีมาและประเมินวิธีการแก้ปัญหาภัย แล้งจังหวัดนครราชสีมาที่ดำเนินการอยู่ในปัจจุบัน พื้นที่ศึกษาคือ พื้นที่แล้งซ้ำซากในจังหวัด นครราชสีมาจำนวน 10 อำเภอ กำหนดรูปแบบวิธีการในการแก้ปัญหาภัยแล้งไว้ 2 รูปแบบได้แก่ 1) รูปแบบการแก้ปัญหาภัยแล้งโดยใช้สิ่งก่อสร้าง และ 2) รูปแบบการแก้ปัญหาภัยแล้งโดยใช้ไม่ใช้ สิ่งก่อสร้าง มีการส่งแบบสอบถามให้ผู้เชี่ยวชาญในด้านการบริหารจัดการน้ำและภัยแล้งในพื้นที่ จังหวัดนครราชสีมา จำนวน 17 คน ดำเนินการส่งแบบสอบถามทั้งหมดจำนวน 2 รอบ ผลของ การศึกษาสรุปได้ว่า วิธีการแก้ปัญหาภัยแล้ง (พื้นที่แล้งซ้ำซาก) จังหวัดนครราชสีมาจำนวน 10 อำเภอ (แบบใช้สิ่งปลูกสร้าง) ลำดับตามความเหมาะสมจากมากไปหาน้อยสามลำดับคือ การพัฒนา บำรุงรักษาแหล่งน้ำ การก่อสร้างโครงการแก้มลิงตามพระราชดำริ การสร้างอ่างเก็บน้ำขนาดเล็ก กลาง ใหญ่ วิธีการแก้ปัญหาภัยแล้ง (แบบไม่ใช้สิ่งปลูกสร้าง) ลำดับตามความเหมาะสมจากมากไปหา น้อยสามลำดับคือ การปลูกจิตสำนึกการอนุรักษ์และฟื้นฟูป่าไม้ การอนุรักษ์ฟื้นฟูแหล่งต้นน้ำและการ ปลูกจิตสำนึกการอนุรักษ์น้ำ รวมถึงรณรงค์การใช้น้ำอย่างประหยัด

อภิรักษ์ พืชโรภาสวัฒนกุล และคณะ (2560) ศึกษาผลกระทบของการเปลี่ยนแปลง สภาพภูมิอากาศได้แก่ อุณหภูมิเฉลี่ยและปริมาณน้ำฝนรวมที่มีต่อผลผลิตมันสำปะหลังในภาค ตะวันออกเฉียงเหนือ ผ่านตัวแบบ Panel Data และใช้วิธีการประมาณค่าแบบ Feasible Generalized Least Squares (FGLS) โดยใช้ข้อมูล Panel Data ของภาคตะวันออกเฉียงเหนือปี พ.ศ.2524-2558 เพื่อประมาณค่าสัมประสิทธิ์ของตัวแบบ ผลการวิเคราะห์พบว่า จากผลการ ประมาณค่าเฉลี่ยของผลผลิตมันสำปะหลังพบว่า อุณหภูมิเฉลี่ย ความแปรปรวนของอุณหภูมิเฉลี่ย ส่งผลกระทบต่อผลผลิตมันสำปะหลังอย่างมีนัยสำคัญทางสถิติ ในส่วนพื้นที่เพาะปลูกมัน สำปะหลัง ปัจจัยปริมาณน้ำฝนรวม ความแปรปรวนของปริมาณน้ำฝนและแนวโน้มเวลา ส่งผล ทางบวกต่อผลผลิตมันสำปะหลังอย่างมีนัยสำคัญทางสถิติ ข้อเสนอแนะจากการศึกษาเพื่อเพิ่มขีด

ความสามารถในการผลิตพืชมันสำปะหลัง หน่วยงานที่เกี่ยวข้องควรดำเนินนโยบายด้านการส่งเสริมและพัฒนาเทคโนโลยีการผลิตมันสำปะหลังให้สอดคล้องกับสภาพภูมิอากาศที่เปลี่ยนแปลง ตลอดจนสร้างความตระหนักในผลกระทบที่เกิดขึ้นจากการเปลี่ยนแปลงสภาพภูมิอากาศ เช่น เผยแพร่ข้อมูลข่าวสารการเตือนภัยพร้อมแนวทางการรับมือที่เหมาะสม

อุทัย เลหาวิเชียร และสุวรรณี แสงมหาชัย (2560) ศึกษาปัจจัยด้านการบริหารที่มีอิทธิพลต่อประสิทธิผลการป้องกันและแก้ไขปัญหามลพิษในเขตกรุงเทพมหานครในปี พ.ศ. 2554 วิเคราะห์อุปสรรคทางการบริหาร ตลอดจนนำเสนอแนวทางเชิงการบริหารในการป้องกันและแก้ไขปัญหามลพิษในเขตกรุงเทพมหานคร งานวิจัยนี้เป็นการวิจัยผสมผสาน (Mixed Methods) ผลการศึกษาพบว่า ผู้มีส่วนได้ส่วนเสีย การประสานงาน การสื่อสาร การควบคุม ปัจจัยทางการเมืองและการมีส่วนร่วมของชุมชนมีความสัมพันธ์ทางบวกกับประสิทธิผลการป้องกันและแก้ไขปัญหามลพิษในกรุงเทพมหานคร อย่างมีนัยสำคัญที่ระดับ < 0.01 ส่วนอุปสรรคทางการบริหารได้แก่ การปราศจากหน่วยงานที่รับผิดชอบโดยตรงในเรื่องการจัดการมลพิษ ไม่มีการจัดทำแผนแม่บท แผนยุทธศาสตร์เกี่ยวกับน้ำ ข้อเสนอแนะคือการป้องกันและแก้ไขปัญหามลพิษต้องให้ความสำคัญกับผู้มีส่วนได้ส่วนเสีย การประสานงาน การสื่อสาร การควบคุม ปัจจัยทางการเมือง และการมีส่วนร่วมของชุมชน ตลอดจนให้มีการจัดตั้งองค์การถาวรเพื่อรับผิดชอบด้านน้ำโดยตรง

ฐกร กาญจน์จิระเดช และคณะ (2561) ศึกษาเกี่ยวกับรูปแบบการมีส่วนร่วมของชุมชนในการบริหารจัดการน้ำของจังหวัดอุทัยธานีตามแนวปรัชญาเศรษฐกิจพอเพียงอย่างยั่งยืน วัตถุประสงค์คือ 1) เพื่อศึกษาสภาพปัญหาในปัจจุบันของการบริหารจัดการน้ำของจังหวัดอุทัยธานีตามแนวปรัชญาเศรษฐกิจพอเพียงอย่างยั่งยืน 2) เพื่อศึกษาการมีส่วนร่วมของชุมชนในการบริหารจัดการน้ำของจังหวัดอุทัยธานีตามแนวปรัชญาเศรษฐกิจพอเพียงอย่างยั่งยืนของทุกภาคส่วนที่เกี่ยวข้อง 3) เพื่อศึกษาแนวผันน้ำและแหล่งเก็บกักน้ำบริเวณที่ราบลุ่มเพื่อบรรเทาอุทกภัยและแก้ปัญหาวิกฤตการณ์น้ำจากการขาดแคลนน้ำ ในลุ่มน้ำของจังหวัดอุทัยธานีตามแนวทางปรัชญาเศรษฐกิจพอเพียง 4) เพื่อศึกษาระบบข้อมูลเกี่ยวกับการมีส่วนร่วมของชุมชนในการบริหารจัดการน้ำสู่ความยั่งยืนตามแนวปรัชญาเศรษฐกิจพอเพียงที่เน้นให้ทุกส่วนของสังคมรู้ถึงคุณค่าของน้ำ ใช้น้ำอย่างพอประมาณมีเหตุผล 5) เพื่อผลักดันการนำผลการวิจัยสู่การกำหนดนโยบายการพัฒนา รูปแบบการมีส่วนร่วมของชุมชนในการบริหารจัดการน้ำสู่ความยั่งยืน ตามแนวปรัชญาเศรษฐกิจพอเพียงของทุกภาคส่วนที่เกี่ยวข้อง ผลการวิจัยพบว่าระดับการมีส่วนร่วมของชุมชนในการบริหารจัดการน้ำของจังหวัดอุทัยธานีตามแนวปรัชญาเศรษฐกิจพอเพียงอย่างยั่งยืนตามเกณฑ์ที่กำหนดไว้ภาพรวมมีระดับการมีส่วนร่วมอยู่ในระดับปานกลาง แต่มีส่วนร่วมในการดำเนินการมากที่สุด รองลงมาเป็นการมีส่วนร่วมในการปรึกษาหารือปัญหาที่พบด้านการบริหารจัดการน้ำตามแนวปรัชญาเศรษฐกิจพอเพียงอย่าง

ยังยืนได้แก่ ประชาชนไม่ให้ความสำคัญกับการประชุมกลุ่มองค์กรหรือกลุ่มผู้ใช้น้ำไม่มีประสิทธิภาพในด้านการบริหารจัดการน้ำ

ปริญ หล่อพิทยากร (2561) ศึกษาอิทธิพลของลานีญาที่มีผลต่อการแพร่กระจายปริมาณฝนในช่วงฤดูฝนและฤดูแล้งบริเวณภาคตะวันออกเฉียงเหนือของประเทศไทย โดยใช้ข้อมูลปริมาณฝนในช่วงปีภาวะปกติ (มิถุนายน พ.ศ. 2546-มิถุนายน พ.ศ. 2547 และกุมภาพันธ์ พ.ศ. 2556-ธันวาคม พ.ศ. 2556) และข้อมูลปริมาณฝนในช่วงภาวะลานีญา (กรกฎาคม พ.ศ. 2550-มิถุนายน พ.ศ. 2551 และมิถุนายน พ.ศ. 2553-พฤษภาคม พ.ศ. 2554) สำหรับข้อมูลปริมาณฝนรวมในฤดูฝนของปีภาวะลานีญาและภาวะปกติใช้ข้อมูลเดือนพฤษภาคมถึงตุลาคมและข้อมูลปริมาณฝนรวมในฤดูแล้งของปีภาวะลานีญาและภาวะปกติใช้ข้อมูลเดือนพฤศจิกายนถึงธันวาคมและมกราคมถึงเมษายน นำข้อมูลปริมาณฝนรวมในช่วงฤดูฝนและฤดูแล้งในปีภาวะปกติและปีภาวะลานีญามาประมาณค่าการแพร่กระจายปริมาณฝนทั่วพื้นที่ภาคตะวันออกเฉียงเหนือ ด้วยโปรแกรม Arc GIS 10.0 จำแนกข้อมูลการแพร่กระจายของฝนในปีภาวะปกติด้วยค่าความเบี่ยงเบนมาตรฐานออกเป็น 5 ชั้นของระดับปริมาณฝนในช่วงฤดูฝนและฤดูแล้งได้แก่ ปริมาณฝนระดับต่ำมาก ระดับต่ำ ระดับปานกลาง ระดับสูงและระดับสูงมาก จากนั้นวิเคราะห์ความแตกต่างของปริมาณฝนระหว่างปีภาวะลานีญาและปีภาวะปกติในช่วงฤดูฝนและฤดูแล้งจากเทคนิคการซ้อนทับภาพ (Overlay) และศึกษาความแตกต่างของการแพร่กระจายปริมาณฝนช่วงฤดูฝนและฤดูแล้งในปีภาวะลานีญากับปีภาวะปกติ โดยใช้สถิติ t-test ที่ระดับความเชื่อมั่น 95 % ผลการศึกษาพบว่าปริมาณฝนรวมในช่วงฤดูฝนของปีภาวะลานีญา ส่วนใหญ่เพิ่มขึ้นจากปีภาวะปกติอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 ยกเว้นบริเวณจังหวัดสระแก้วที่ปริมาณฝนรวมลดลงมากที่สุดอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 สำหรับในช่วงฤดูแล้งปริมาณฝนรวมในปีภาวะลานีญาส่วนใหญ่เพิ่มขึ้นจากปีภาวะปกติอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 ยกเว้นบริเวณจังหวัดจันทบุรีปริมาณฝนรวมลดลงจากปีภาวะปกติแต่ไม่มีนัยสำคัญทางสถิติที่ระดับ 0.05 ดังนั้นในช่วงฤดูฝนของปีภาวะลานีญาบริเวณพื้นที่จังหวัดจันทบุรีควรมีพื้นที่กักเก็บน้ำเพื่อไว้ใช้ในช่วงฤดูแล้ง ควรทำเกษตรกรรมแบบใช้น้ำน้อย และทางตรงกันข้ามในช่วงฤดูแล้งของปีภาวะลานีญาบริเวณพื้นที่จังหวัดสระแก้วควรมีพื้นที่กักเก็บน้ำไว้ใช้ในช่วงฤดูฝน ภาวะลานีญาบริเวณจังหวัดสระแก้ว ควรทำเกษตรกรรมแบบใช้น้ำน้อยเพื่อลดปัญหาการขาดแคลนน้ำในพื้นที่ได้บ้าง

Gupta et al. (2014) ศึกษาเหมืองข้อมูลอนุกรมเวลาพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron) ด้วยการเรียนรู้แบบแพร่ย้อนกลับ (Back-propagation Algorithms) และเปรียบเทียบการตัวแบบพยากรณ์ด้วยวิธีการวิเคราะห์การถดถอยเชิงเส้น (Linear Regression) พิจารณาความแม่นยำของตัวแบบทั้ง 2 จากค่า MAE ค่า MSE และค่า R ผลการศึกษาพบว่าตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมมีความแม่นยำมากกว่าตัวแบบพยากรณ์ด้วยวิธีการวิเคราะห์การถดถอยเชิงเส้น

Yashwant and Sananse (2015) ศึกษาการพยากรณ์ปริมาณน้ำฝนรายเดือนโดยใช้โครงข่ายประสาทเทียมแบบ FFNN กับวิธี MRA จากนั้นนำผลการพยากรณ์จากวิธีทั้งสองมาเปรียบเทียบกันว่าตัวแบบจากวิธีไหนให้ผลการพยากรณ์ที่แม่นยำมากกว่ากัน ผลการศึกษาพบว่าตัวแบบที่ใช้โครงข่ายประสาทเทียมมีความแม่นยำในการพยากรณ์มากกว่าที่ใช้วิธี MRA พิจารณาจากค่า R และค่า MSE

Rasel and Imteaz (2016) ศึกษาการพยากรณ์ปริมาณน้ำฝนฤดูใบไม้ผลิโดยใช้โครงข่ายประสาทเทียม และวิธีการวิเคราะห์ถดถอยพหุคูณ (Multiple Linear Regression: MR) สร้างตัวแบบพยากรณ์โดยใช้ตัวแปรพยากรณ์เป็นตัวแปรด้านสภาพอากาศได้แก่ เอนโซ (El Nino Southern Oscillation: ENSO) เป็นการเปลี่ยนแปลงของอุณหภูมิผิวน้ำทะเลในแปซิฟิกเขตศูนย์สูตรและความผันแปรของระบบอากาศในซีกโลกใต้จึงหมายถึงความรวมถึงปรากฏการณ์ทั้งเอลนีโญ (El Nino) และลานีญา (La Nina) แซม (Southern Annular Mode: SAM) และโอไอดี (Indian Ocean Dipole: IOD) เป็นการวัดความแตกต่างของอุณหภูมิที่ผิวน้ำทะเลระหว่างฝั่งตะวันตกและฝั่งตะวันออกของมหาสมุทรอินเดีย การศึกษานี้ถือเป็นการศึกษาบริเวณรัฐเซาท์ออสเตรเลีย (South Australia: SA) จากนั้นทำการเปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์ปริมาณน้ำฝนที่ได้โดยใช้ค่า RMSE และค่าดัชนีความสอดคล้อง (Index of Agreement: d) ผลการศึกษาพบว่าตัวแบบพยากรณ์ปริมาณน้ำฝนที่สร้างจากโครงข่ายประสาทเทียมให้ผลการพยากรณ์ที่แม่นยำที่สุด

Hashim et al. (2017) ศึกษาการพยากรณ์ปริมาณน้ำฝนจากตัวแปรทางด้านสภาพอากาศโดยใช้โครงข่ายประสาทเทียม ในการศึกษาครั้งนี้ใช้ตัวแปรคืออุณหภูมิ ความกดอากาศ และความชื้นเป็นตัวแปรนำเข้า ผลลัพธ์ที่ได้เป็นปริมาณน้ำฝนที่จำแนกเป็นเปอร์เซ็นต์ โครงข่ายประสาทเทียมที่ใช้มีลักษณะเป็นโครงข่ายแบบหลายชั้น ขั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ LM และแบบแพร่ย้อนกลับ จากนั้นเปรียบเทียบประสิทธิภาพความแม่นยำของการพยากรณ์จากการใช้วิธีการเรียนรู้ที่ต่างกัน ผลการศึกษาพบว่าการใช้วิธีการเรียนรู้แบบ LM มีความแม่นยำมากกว่าแบบแพร่ย้อนกลับมีค่าเป็น 99.90% และ 95.67% ตามลำดับ และประสิทธิภาพความแม่นยำโดยรวมของการพยากรณ์ที่ใช้การเรียนรู้แบบ LM มีค่าเป็น 99.75%

Kurup, Deonarine, and Ansari (2017) ศึกษาการเกิดโรคมะลาเรียและผลกระทบของปริมาณน้ำฝน อุณหภูมิภายในเขตพื้นที่ที่ 7 และ 8 ของประเทศกายอานา (Guyana) เพื่อระบุความสัมพันธ์ระหว่างสภาพภูมิอากาศและการเกิดโรคมะลาเรียภายในเขตพื้นที่ที่ 7 และ 8 โดยเก็บรวบรวมข้อมูลจากกระทรวงสาธารณสุข กระทรวงเกษตรและสถาบันวิจัยโรคมะลาเรียระหว่างปีค.ศ. 2006-2013 ใช้การวิเคราะห์ความแปรปรวน (ANOVA) สถิติ T-test ไคสแควร์ (Chi Square) และการวิเคราะห์สหสัมพันธ์ (Correlation) ในการวิเคราะห์ข้อมูลทางสถิติ ผลการศึกษาพบว่า ชาติพันธุ์ อายุ และเพศ ส่งผลทำให้การเกิดโรคมะลาเรียมีเพิ่มมากขึ้นอย่างมีนัยสำคัญทางสถิติ และการเปลี่ยนแปลง

ของสภาพภูมิอากาศมีส่วนทำให้เกิดการเปลี่ยนแปลงปริมาณน้ำฝนและอุณหภูมิ ซึ่งส่งผลกระทบต่อ การเกิดโรคมลาลาเรียควบคู่ไปกับชาติพันธุ์ อายุและเพศ

Shaikh and Sawlani (2017) ศึกษาการพยากรณ์ปริมาณน้ำฝนบริเวณเมืองมุมไบ (Mumbai) โดยใช้โครงข่ายประสาทเทียมแบบ FFNN ประกอบด้วย 3 ชั้นได้แก่ ชั้นรับข้อมูลเข้า ชั้น ซ่อนและชั้นส่งข้อมูลออก ด้วยการเรียนรู้แบบแพร่ย้อนกลับ การสร้างตัวแบบพยากรณ์นี้ใช้โปรแกรม Matlab ที่มีตัวแปรนำเข้าได้แก่ ความชื้นเฉลี่ย อุณหภูมิเฉลี่ย ความเร็วลมเฉลี่ย ตัวแปรส่งออกได้แก่ ปริมาณน้ำฝนเฉลี่ย สำหรับข้อมูลที่ศึกษามาจากเว็บไซต์ของกรมอุตุนิยมวิทยาบริเวณเมืองมุมไบ ประเทศอินเดีย เป็นข้อมูลรายฤดูกาลตั้งแต่เดือนมิถุนายน-กันยายน ปีค.ศ. 2013-2015 งานวิจัยนี้จะ อธิบายชุดข้อมูลการเรียนรู้ และการทดสอบ พร้อมทั้งหาจำนวนชั้นซ่อน ผลงานวิจัยพบว่า ความ แม่นยำของตัวแบบพยากรณ์เมื่อพิจารณาจากค่า $MSE=0.579$ และมีจำนวนชั้นซ่อนจำนวน 2 ชั้น

Sihananto and Mahmudy (2017) ศึกษาการพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่าย ประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation Neural Network: BPNN) ซึ่งเป็นหนึ่งใน วิธีการที่ถูกนำมาใช้อย่างแพร่หลาย สำหรับพยากรณ์เหตุการณ์ในอนาคต และงานวิจัยนี้ยังใช้วิธี Nguyen-Windrow ในการกำหนดค่าน้ำหนักเริ่มต้นของโครงข่ายประสาทเทียม เพื่อลดเวลาในการ เรียนรู้ของโครงข่าย การวัดประสิทธิภาพของตัวแบบพิจารณาจากค่า MSE ซึ่งค่าที่ต่ำที่สุด คือ {0.02815; 0.01686; 0.01934; 0.03196} กำหนดจำนวนการทำซ้ำในแต่ละรอบเท่ากับ 50 รอบและ ชั้นซ่อนมีจำนวน 3 โหนด

Teong, Sukarno, Chang, Chee, Ho, and Dayou (2017) ศึกษาเกี่ยวกับผลกระทบ ของลมมรสุมที่มีต่อปริมาณน้ำฝนและรังสีดวงอาทิตย์ (Solar Radiation) ในเมืองโกตากินาบาลู (Kota Kinabalu) ซึ่งเป็นเมืองที่ตั้งอยู่ใกล้เส้นศูนย์สูตรในพื้นที่เขตร้อนมีฝนตกมาก อุณหภูมิสูง แดด จัดและความชื้นสูงตลอดทั้งปี ประชากรประกอบอาชีพทางการเกษตร การประมงและการท่องเที่ยว เป็นหลัก ซึ่งได้รับผลกระทบจากลมมรสุมเป็นอย่างมาก การศึกษานี้จะวิเคราะห์ความแปรปรวนราย เดือนของปริมาณน้ำฝนและรังสีดวงอาทิตย์ ตั้งแต่เดือนตุลาคมปีค.ศ. 2013 ถึงเดือนกันยายนปีค.ศ. 2014 โดยใช้ข้อมูลปริมาณน้ำฝนเฉลี่ยในแต่ละวันของเมืองโกตากินาบาลูที่รวบรวมจากกรม อุตุนิยมวิทยา ส่วนข้อมูลปริมาณรังสีดวงอาทิตย์ได้จากเครื่องวัดปริมาณรังสีดวงอาทิตย์ไพรานอมิเตอร์ (Pyranometer) รุ่น LI-200 ผลการศึกษาพบว่า ช่วงเวลาลมมรสุมตะวันตกเฉียงใต้ส่งผลทำ ให้เกิดพายุฝนและมีฝนตกหนัก แต่ทำให้ปริมาณรังสีดวงอาทิตย์ลดน้อยลง และยังแสดงให้เห็นว่า ระดับปริมาณรังสีดวงอาทิตย์กับปริมาณน้ำฝนมีความสัมพันธ์กัน แต่ไม่ได้แสดงว่ามีความสัมพันธ์กัน ในทิศทางตรงข้าม

Yu et al. (2017) ศึกษาเกี่ยวกับการเปรียบเทียบผลกระทบจากภาวะเอลนีโญและ ภาวะเอลนีโญโมโดกิ (El Niño Modoki) ที่ทำให้มีฝนตกหนักบริเวณแถว ๆ สหรัฐอเมริกา สาเหตุหลัก

ที่ทำให้เกิดน้ำท่วมฉับพลันมาจากการที่ฝนตกหนักในช่วงระยะเวลาสั้น ๆ ในงานวิจัยนี้จึงใช้ข้อมูล ปริมาณน้ำฝนรายชั่วโมงที่ได้จาก North America Land Data Assimilation System Phase 2 (NALDASP2) ตั้งแต่ปีค.ศ. 1979 ถึงปีค.ศ. 2013 เพื่อเปรียบเทียบความแตกต่างของฝนที่ตกหนัก บริเวณแถว ๆ สหรัฐอเมริกากับความอุ่นที่รุนแรงกว่าปกติในแถบแปซิฟิกตะวันออกที่รู้จักกันในชื่อ เอลนีโญและในแปซิฟิกตอนกลางชื่อเอลนีโญโมโดกิ ความอุ่นที่เกิดขึ้นในแปซิฟิกทั้งสองนั้นจะมีความ รุนแรงมากขึ้นในฤดูหนาว (เดือนพฤศจิกายนถึงเมษายน) มากกว่าในฤดูร้อน (เดือนพฤษภาคมถึง ตุลาคม) ส่วนในฤดูร้อนเอลนีโญมีความสัมพันธ์กับปริมาณน้ำฝนที่เพิ่มมากขึ้นบริเวณทางเหนือของ เทือกเขาร็อกกี (Rockies) และเอลนีโญโมโดกิมีความสัมพันธ์กับปริมาณน้ำฝนที่ลดลงบริเวณอินเตอร์ เมาน์เทนเวสต์ (Intermountain West) กล่าวโดยสรุปคือ เอลนีโญมีอิทธิพลต่อการตกของฝน มากกว่าเอลนีโญโมโดกิ

Tafoughalti et al. (2018) ศึกษาการเปลี่ยนแปลงของสภาพภูมิอากาศที่มีผลต่อ ปริมาณน้ำฝนซึ่งเป็นภัยคุกคามผลผลิตข้าวสาลี สภาพภูมิอากาศที่เปลี่ยนแปลงมีผลต่อสภาพแวดล้อม ของเมืองเกษตรกรรมอย่างมาก เมืองเมกเนส (Meknes) เป็นเมืองที่มีผลผลิตของข้าวสาลีเป็นสำคัญ แต่เนื่องจากเป็นพื้นที่ที่อ่อนไหวต่อความแปรปรวนของปริมาณน้ำฝนและการเปลี่ยนแปลงของสภาพ ภูมิอากาศ ดังนั้นการศึกษาเกี่ยวกับผลกระทบของการเปลี่ยนแปลงปริมาณน้ำฝนที่เป็นผลมาจากการ เปลี่ยนแปลงของสภาพภูมิอากาศจึงเป็นสิ่งที่สำคัญมากทางการเกษตร งานวิจัยนี้ศึกษาความ แปรปรวนของปริมาณน้ำฝนและผลกระทบที่มีต่อผลผลิตข้าวสาลี โดยใช้ข้อมูลปริมาณน้ำฝนราย เดือนจำนวน 30 ปีและข้อมูลผลผลิตข้าวสาลี 15 ปี การประเมินความแปรปรวนของปริมาณน้ำฝน โดยใช้ดัชนีความเข้มข้นของปริมาณฝน (Precipitation Concentration Index: PCI) และสัมประสิทธิ์ การแปรผัน พิจารณาความสัมพันธ์ระหว่างผลผลิตข้าวสาลีและปริมาณน้ำฝนโดยใช้ตัวแบบถดถอย ผลการวิจัยพบว่า ค่าสหสัมพันธ์ของผลผลิตข้าวสาลีที่มีความสัมพันธ์กับปริมาณน้ำฝนและมี ความสัมพันธ์มากในเดือนมกราคมถึงมีนาคม

ปริมาณน้ำฝนเป็นปัจจัยสำคัญในหลายสาขา ดังนั้นการพยากรณ์ปริมาณน้ำฝนจึงเป็น สิ่งที่สำคัญ แม้ว่าในปัจจุบันมีการนำเทคโนโลยีเข้ามาช่วยในการพยากรณ์มากมาย แต่ความแม่นยำก็ ไม่ถึง 100% และยังมีข้อผิดพลาด (Wahyuni et al., 2018) จากการศึกษาวิจัยที่เกี่ยวข้องกับ การพยากรณ์ปริมาณน้ำฝนด้วยตัวแบบพยากรณ์ในรูปแบบต่าง ๆ แสดงให้เห็นว่าตัวแบบพยากรณ์ ปริมาณน้ำฝนที่ใช้โครงข่ายประสาทเทียมเป็นที่นิยมและมีความแม่นยำในการพยากรณ์มากกว่าวิธี อื่น ๆ เพราะข้อมูลที่นำมาวิเคราะห์มีความซับซ้อน (เปรม รังสิวณิชพงศ์ และคณะ, 2558) โครงข่าย ประสาทเทียมที่นำมาใช้ส่วนมากมีลักษณะเป็นโครงข่ายประสาทเทียมแบบหลายชั้น (Rasel & Imteaz, 2016) โดยมีเทคนิคที่นำมาใช้ในการสร้างตัวแบบพยากรณ์ เช่น การใช้วิธีการเรียนรู้แบบ แพร่ย้อนกลับ แบบ LM เป็นต้น แต่ละเทคนิคที่แตกต่างกันทำให้ความเร็วและความแม่นยำในการ

พยากรณ์แตกต่างกันด้วย โดยมีการพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE ค่า MSE ค่า R ค่า RMSE และค่า R^2 เป็นต้น

ตอนที่ 5 ข้อมูลอุตุนิยมวิทยาที่เกี่ยวข้องกับปริมาณน้ำฝน

ข้อมูลอุตุนิยมวิทยาที่เกี่ยวข้องกับปริมาณน้ำฝนถูกนำมาใช้ในการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม จากกรมอุตุนิยมวิทยา ประเทศไทย อธิบายการเก็บบันทึกข้อมูลต่าง ๆ ดังนี้

1. ความชื้นสัมพัทธ์ (Relative Humidity)

ค่าความชื้นสัมพัทธ์ของอากาศในเวลา และสถานที่ต่าง ๆ มีผลต่อการเปลี่ยนแปลงปรากฏการณ์ของลมฟ้าอากาศอยู่มาก ถ้ามีค่าความชื้นสัมพัทธ์ของอากาศมาก และอุณหภูมิลดลงจนถึงจุดอิ่มตัวจะเกิดภาวะการกลั่นตัวกลายเป็นละอองหรือหยดน้ำ ปรากฏเป็นหยาดน้ำฟ้า (Precipitation) ในรูปแบบต่าง ๆ กัน เช่น หมอก เมฆ ฝน หิมะ น้ำค้างหรือลูกเห็บ การเกิดภาวะการกลั่นตัวนี้จะเป็นไปได้เร็วหรือช้าขึ้นอยู่กับค่าความชื้นสัมพัทธ์ของอากาศในบริเวณนั้นเป็นสำคัญ (ปานทิพย์ อัทธนวนิช, 2553, หน้า 112) เครื่องมือที่ใช้วัดค่าความชื้นสัมพัทธ์ได้แก่ ไฮโครมิเตอร์แบบกระเปาะเปียกและแห้ง (Wet and Dry Bulb Psychrometer) เป็นเครื่องมือพื้นฐานสำหรับวัดความชื้นอากาศ ประกอบด้วย เทอร์โมมิเตอร์ 2 อัน กระเปาะเทอร์โมมิเตอร์ที่หุ้มด้วยผ้าฝ้ายสลินที่ชุ่มน้ำเรียกว่า กระเปาะเปียก (Wet Bulb) ส่วนอีกกระเปาะเรียกว่า กระเปาะแห้ง (Dry Bulb) เทอร์โมมิเตอร์กระเปาะเปียกจะแสดงค่าอุณหภูมิต่ำกว่าเทอร์โมมิเตอร์กระเปาะแห้งเสมอ และไฮโกรกราฟ (Hygrograph) เป็นเครื่องมือที่บันทึกค่าการเปลี่ยนแปลงของความชื้นสัมพัทธ์ของบรรยากาศอย่างต่อเนื่องลงบนแผ่นกราฟ ความชื้นสัมพัทธ์มีหน่วยเป็นเปอร์เซ็นต์ (%) (รังสรรค์ อาภาศัพท์กุล, 2547, หน้า 134-136)

2. ความเร็วลม (Wind Speed) และทิศทางลม (Wind Direction)

ข้อมูลลมมีความสำคัญมากต่อการวิเคราะห์ความแปรปรวนของสภาพอากาศที่เกิดขึ้นในขณะนั้น เพื่อใช้ประกอบเป็นแนวทางการพยากรณ์อากาศที่จะเปลี่ยนแปลงในเวลาต่อมา ลมแต่ละระดับความสูงมีความเร็วและทิศทางที่แตกต่างกัน ในทางอุตุนิยมวิทยาการวัดลมกำหนดให้มีการวัดลมชั้นบน (Upper Wind) และลมผิวพื้น (Surface Wind) ที่ระดับความสูง 850 เฮกโตปาสกาลและระดับความสูง 200 เฮกโตปาสกาล ตามลำดับ เครื่องมือพื้นฐานตามสถานีตรวจอากาศสำหรับการวัดลมพื้นผิวเรียกว่า แอโรเวน (Aerovane) ประกอบด้วยใบพัดสามใบวัดความเร็วลม ใบจักรหมุนเป็นอัตราส่วนต่อความเร็วลม ลักษณะตัวเครื่องคล้ายเครื่องบินขนาดเล็กซึ่งทำหน้าที่เป็นศรลมปักอยู่ปลายยอดเสา เครื่องแบบนี้ใช้อาการหมุนของเครื่องกำเนิดไฟฟ้าต่อสายไฟมายังหน้าปัดบอกความเร็วซึ่งแบ่งสเกลไว้เป็นนอตหรือไมล์ทะเลต่อชั่วโมงและเมื่อศรลม (ตัวคล้ายรูปเครื่องบิน) หันไปตาม

ทิศทางของลมในทิศต่าง ๆ และส่งอาการของไฟฟ้ามายังหน้าปิดบอกทิศทางลมด้วย และเชื่อมต่อเข้ากับเครื่องมือที่ทำการบันทึก เครื่องวัดลมนี้เป็นการวัดลมที่พื้นดินและบอกทิศทางหรือความเร็วลมในตำแหน่งคงที่ โดยที่สิ่งกีดขวางต่าง ๆ จะมีอิทธิพลต่อลม ดังนั้นเครื่องมือที่ใช้วัดลมควรตั้งอยู่ในที่โล่งที่อากาศถ่ายเทได้สะดวก ไม่มีอาคารหรือสิ่งกีดขวางขนาดใหญ่บังลมและอยู่สูงจากพื้นดินประมาณ 10 เมตร (กรมอุตุนิยมวิทยา, 2556, หน้า 18) ความเร็วลมมีหน่วยเป็นเมตรต่อวินาที กิโลเมตรต่อชั่วโมง ไมล์ต่อชั่วโมง หรือน็อต (Knots) แถบมหาสมุทรแปซิฟิกเหนือด้านตะวันตกและทะเลจีนใต้แบ่งเกณฑ์ความเร็วลมสูงสุดบริเวณใกล้ศูนย์กลางที่ใช้ในการพิจารณาความรุนแรงของพายุหมุนเขตร้อนตามข้อตกลงระหว่างประเทศ ดังนี้

- พายุดีเปรสชัน (Depression) ความเร็วลมสูงสุดใกล้ศูนย์กลางไม่เกิน 34 น็อต (63 กม./ชม.)
- พายุโซนร้อน (Tropical Storm) ความเร็วลมใกล้ศูนย์กลาง 34 น็อต (63 กม./ชม.) ขึ้นไป แต่ไม่ถึง 64 น็อต (118 กม./ชม.)
- พายุไต้ฝุ่น (Typhoon) ความเร็วลมสูงสุดใกล้ศูนย์กลางตั้งแต่ 64 น็อตขึ้นไป (118 กม./ชม.)

สำหรับการวัดทิศทางลมนั้นถือเอาทิศที่ลมพัดเข้าหาสถานีเป็นเกณฑ์ โดยใช้วัดเป็นองศา ตามเข็มนาฬิกาถือทิศเหนือจริงของสถานีเป็นหลัก การวัดทิศทางลมเป็นองศา โดยกำหนดให้ทิศเหนือ (N) เท่ากับ 0 องศา (360 องศา) ทิศตะวันออก (E) 90 องศา ทิศใต้ (S) 180 องศา และทิศตะวันตก (W) 270 องศา (กรมอุตุนิยมวิทยา, 2556, หน้า 18-19) ลมที่พัดในแนวตะวันออก-ตะวันตก (Zonal Wind) คือลมตามแนวแกน x และลมที่พัดในแนวเหนือ-ใต้ (Meridional Wind) คือลมตามแนวแกน y การเรียกชื่อลมนั้นจะเรียกตามทิศทางที่ลมนั้น ๆ พัดมา เช่น ลมที่พัดจากทิศเหนือเรียกว่า ลมเหนือ ลมที่พัดมาจากทิศใต้เรียกว่า ลมใต้ เป็นต้น สำหรับลมชั้นบนตรวจวัดได้โดยใช้บอลลูนหยั่งอากาศ (Pilot Balloon) ประกอบด้วยบอลลูนที่บรรจุแก๊สไฮโดรเจนและกล้องทีโอดอลไลท์ (Theodolite) ทำหน้าที่วัดความเร็วและทิศทางลม อัตราการลอยตัวและข้อมูลของมุมแนวราบและมุมความสูงของบอลลูนที่บันทึกไว้นำไปคำนวณความเร็วและทิศทางลมของชั้นบนที่เกิดขึ้นนั้น ๆ (รังสรรค์ อากาศพิภวะกุล, 2547, หน้า 80-81)

3. การระเหย (Evaporation) ของน้ำ

การที่น้ำเปลี่ยนสถานะจากของเหลวกลายเป็นไออย่างช้า ๆ และเกิดขึ้นเฉพาะผิวหน้าของน้ำเท่านั้น นอกจากนั้นการระเหยยังสามารถเกิดได้ทุก ๆ อุณหภูมิที่ยังมีของน้ำนั้นอยู่ เช่น น้ำสามารถระเหยได้ที่อุณหภูมิ 0-100°C ที่ความดัน 1 บรรยากาศ การตรวจวัดการระเหยของน้ำนิยมใช้เครื่องวัดการระเหยแบบถาด (Evaporation Pan) ที่ประกอบด้วยถาดวัดน้ำระเหยรูปทรงกลม ลึก 10 นิ้ว ขนาดเส้นผ่าศูนย์กลางปากถาด 48 นิ้ว ทำด้วยสแตนเลส ตัวถาดตั้งอยู่บนฐานไม้รองรับ ซึ่ง

ตั้งอยู่บนผิวดิน ตะขอวัดน้ำระเหย (Micrometer Hook Gauge) ที่รองรับตะขอวัดน้ำ (บ่อน้ำนิ่ง (Stilling Well) เทอร์โมมิเตอร์ลอยน้ำ (วัดอุณหภูมิของน้ำ) และเครื่องวัดลมเหนือถาดน้ำระเหย (Anemometer) เพื่อใช้ประกอบการหาอัตราน้ำระเหย การตรวจวัดจะตรวจในช่วงเวลาเช้าทุกวัน เวลา 07.00 น. โดยทำการปรับระดับตะขอวัดน้ำให้ปลายแหลมของตะขอสัมผัสกับผิวน้ำพอดี โดยที่ค่าที่อ่านได้วันนี้ ลบออกจากค่าที่อ่านได้เมื่อวานนี้ เท่ากับปริมาณน้ำระเหย (ลบ.ซม.) ใน 24 ชม. อ่านตัวเลขของเครื่องวัดลมเหนือถาดน้ำระเหยวันนี้ ลบออกจากค่าที่อ่านได้เมื่อวานนี้ เท่ากับความเร็วลมใน 24 ชม. ความเร็วลมเฉลี่ยที่ได้นำไปประกอบเป็นตัวแปรการระเหยของน้ำ อ่านอุณหภูมิสูงสุด อุณหภูมิต่ำสุดของน้ำ จดบันทึกเพื่อใช้ประกอบเป็นตัวแปรการระเหยของน้ำ นอกจากนี้ยังมีเครื่องวัดน้ำระเหยแบบพิเช่ (Piche' Evaporimeter) มีลักษณะเป็นหลอดแก้วขนาดเล็กมีเส้นผ่าศูนย์กลาง 0.6 นิ้ว ยาวประมาณ 9 นิ้ว ปลายข้างหนึ่งเปิดเพื่อไว้เติมน้ำสะอาด แล้วใช้กระดาษกรองกลม ๆ แผ่นบาง ๆ มีขนาดจำกัดปิดไว้โดยมีเหล็กสปริงหนีบกดไว้ปิดแนบกับปลายด้านที่เปิด ส่วนอีกด้านหนึ่งปิดสนิท มีตะขอไว้สำหรับแขวน เครื่องวัดน้ำแบบพิเช่มีความไวต่อลมมาก จึงต้องติดตั้งไว้ในเรือนเทอร์โมมิเตอร์ (กรมอุตุนิยมวิทยา, 2556, หน้า 23)

4. อุณหภูมิอากาศ (Air Temperature)

อุณหภูมิอากาศเป็นปัจจัยพื้นฐานในการศึกษาสภาพอากาศ เนื่องจากอุณหภูมิอากาศมีเปลี่ยนแปลงในแต่ละช่วงเวลา ซึ่งสิ่งสำคัญที่สุดที่ทำให้เกิดการเปลี่ยนแปลงของอุณหภูมิอากาศในรอบวันคือ การหมุนรอบตัวเองของโลก ส่งผลทำให้มุมที่แสงอาทิตย์ตกกระทบพื้นผิวโลกเปลี่ยนแปลงไปคือ ช่วงเวลาเที่ยงวันดวงอาทิตย์อยู่สูงเหนือขอบฟ้ามากที่สุด ทำให้แสงอาทิตย์ตกกระทบพื้นโลกเป็นมุมฉากจึงมีความเข้มสูง แต่เวลาเช้าและเย็นดวงอาทิตย์อยู่ใกล้ขอบฟ้า แสงตกกระทบพื้นโลกเป็นมุมเฉียง ลำแสงครอบคลุมพื้นที่กว้างทำให้ความเข้มของแสงลดน้อยกว่าเวลาเที่ยง นอกจากนี้ ช่วงเวลาเที่ยงแสงอาทิตย์จะส่องผ่านบรรยากาศเป็นระยะทางไม่มาก แต่ในช่วงเวลาเช้าและเย็น แสงอาทิตย์ทำมุมลาดและเดินทางผ่านชั้นบรรยากาศเป็นระยะทางไกล ความเข้มของแสงจึงถูกบรรยากาศกรองให้ลดน้อยลง ส่งผลทำให้อุณหภูมิต่ำลงไปอีก ข้อมูลอุณหภูมิอากาศ อ่านจากเทอร์โมมิเตอร์ที่ติดตั้งอยู่ภายในเรือนเทอร์โมมิเตอร์ (Thermometer Screen) ในสนามอุตุนิยมวิทยา เทอร์โมมิเตอร์ที่ใช้ในการศึกษาสภาพอากาศเป็นเทอร์โมมิเตอร์ชนิดสูงสุด-ต่ำสุด" (Max-Min Thermometer) สามารถวัดค่าอุณหภูมิสูงสุดและต่ำสุดในรอบวันได้ โดยที่เรือนเทอร์โมมิเตอร์เป็นตู้สกรีนบานเกล็ดสองชั้น ทาด้วยสีขาว เพื่อให้อากาศถ่ายเทได้สะดวกและป้องกันความร้อนจากดวงอาทิตย์เข้าไปในตู้ มีประตูเปิดด้านหน้า การติดตั้งจะต้องหันด้านประตูไปทางทิศเหนือหรือทิศใต้เสมอ เพื่อไม่ให้แสงอาทิตย์ส่องเข้าไปเครื่องมือที่ติดตั้งอยู่ภายในตู้ในขณะทำการอ่านข้อมูล ตั้งอยู่สูงจากพื้นดิน 1.25-2.00 เมตร ให้พอดีกับระดับสายตาผู้ตรวจ (กรมอุตุนิยมวิทยา, 2556,

หน้า 14) หน่วยที่ใช้วัดอุณหภูมิอากาศในระบบเอสไอ (SI) คือ องศาเคลวิน (°K) หรือองศาเซลเซียส (°C) สำหรับระดับความสูงจากผิวโลกในระดับที่ต่างกันส่งผลให้อุณหภูมิอากาศมีค่าไม่เท่ากันด้วย นั่นคือ อุณหภูมิอากาศแปรผกผันกับความสูงจากระดับน้ำทะเลคือ ถ้าความสูงจากระดับน้ำทะเลเพิ่มมากขึ้น อุณหภูมิอากาศจะมีค่าลดลง (โดยที่ระดับความสูงจากระดับน้ำทะเล 0-10 กิโลเมตร อุณหภูมิอากาศจะลดลงเมื่อความสูงเพิ่มขึ้น)

- อุณหภูมิอากาศสูงสุด อ่านจากเทอร์โมมิเตอร์สูงสุดในเรือนเทอร์โมมิเตอร์ (ตู้สกรีน) เวลา 19.00 น. เป็นการวัดอุณหภูมิสูงสุดในแต่ละวัน การติดตั้งเทอร์โมมิเตอร์สูงสุดให้ทางตุ้มปรอท อยู่ต่ำกว่าปลายปรอทเล็กน้อย (5 องศาหรือ 1/4 นิ้ว) เพื่อป้องกันลำปรอทในหลอดแก้วไหลหลุด ออกไปจากคอคอดตึบ เนื่องจากการสั่นสะเทือน (กรมอุตุนิยมวิทยา, 2556, หน้า 15)

- อุณหภูมิอากาศต่ำสุด อ่านจากเทอร์โมมิเตอร์ต่ำสุดในตู้สกรีนเวลา 07.00 น. เป็นการวัดอุณหภูมิต่ำสุดในแต่ละวัน (กรมอุตุนิยมวิทยา, 2556, หน้า 16)

- อุณหภูมิอากาศเฉลี่ย แบ่งเป็น อุณหภูมิอากาศเฉลี่ยในแต่ละวัน (Daily Mean Temperature) ใช้ค่าอุณหภูมิอากาศสูงสุดและต่ำสุดรวมกันหารด้วยสอง อุณหภูมิอากาศเฉลี่ยของเดือน (Monthly Mean Temperature) ใช้ค่าเฉลี่ยอุณหภูมิอากาศของแต่ละวันรวมกันหารด้วยจำนวนวัน และอุณหภูมิอากาศเฉลี่ยของปี (Yearly Mean Temperature) ใช้ค่าอุณหภูมิอากาศของแต่ละเดือนรวมกันหารด้วยสิบสอง

ข้อมูลอุตุนิยมวิทยาที่เกี่ยวข้องกับปริมาณน้ำฝนได้แก่ ความชื้นสัมพัทธ์ ความเร็วลมและทิศทางลม การระเหยของน้ำ อุณหภูมิอากาศ ถูกนำมาใช้เป็นตัวแปรในการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม และนำมาใช้เป็นตัวแปรในการสร้างตัวแบบพยากรณ์ปริมาณน้ำฝน

สำหรับการศึกษาทำการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA เพื่อให้การคัดเลือกมีประสิทธิภาพที่ดีขึ้นหรือเป็นการลดปัญหาต่าง ๆ ที่เกิดขึ้น เช่น คัดเลือกได้โครโมโซมที่ไม่ดี การลู่อู่เข้าคำตอบที่ดีเฉพาะที่ แต่อาจจะไม่ใช่คำตอบที่ถูกต้อง และไม่เกิดความหลากหลายทางสายพันธุ์หลังจากผ่านกระบวนการคัดเลือกแล้ว นอกจากนี้ยังสามารถนำการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA ไปใช้ในการพยากรณ์ร่วมกับวิธีอื่น ๆ โดยเฉพาะอย่างยิ่งโครงข่ายประสาทเทียม เพื่อให้มีความแม่นยำในการพยากรณ์มากขึ้น การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ใช้หลักการ Normalized Geometric Ranking (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) และหลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991)

บทที่ 3

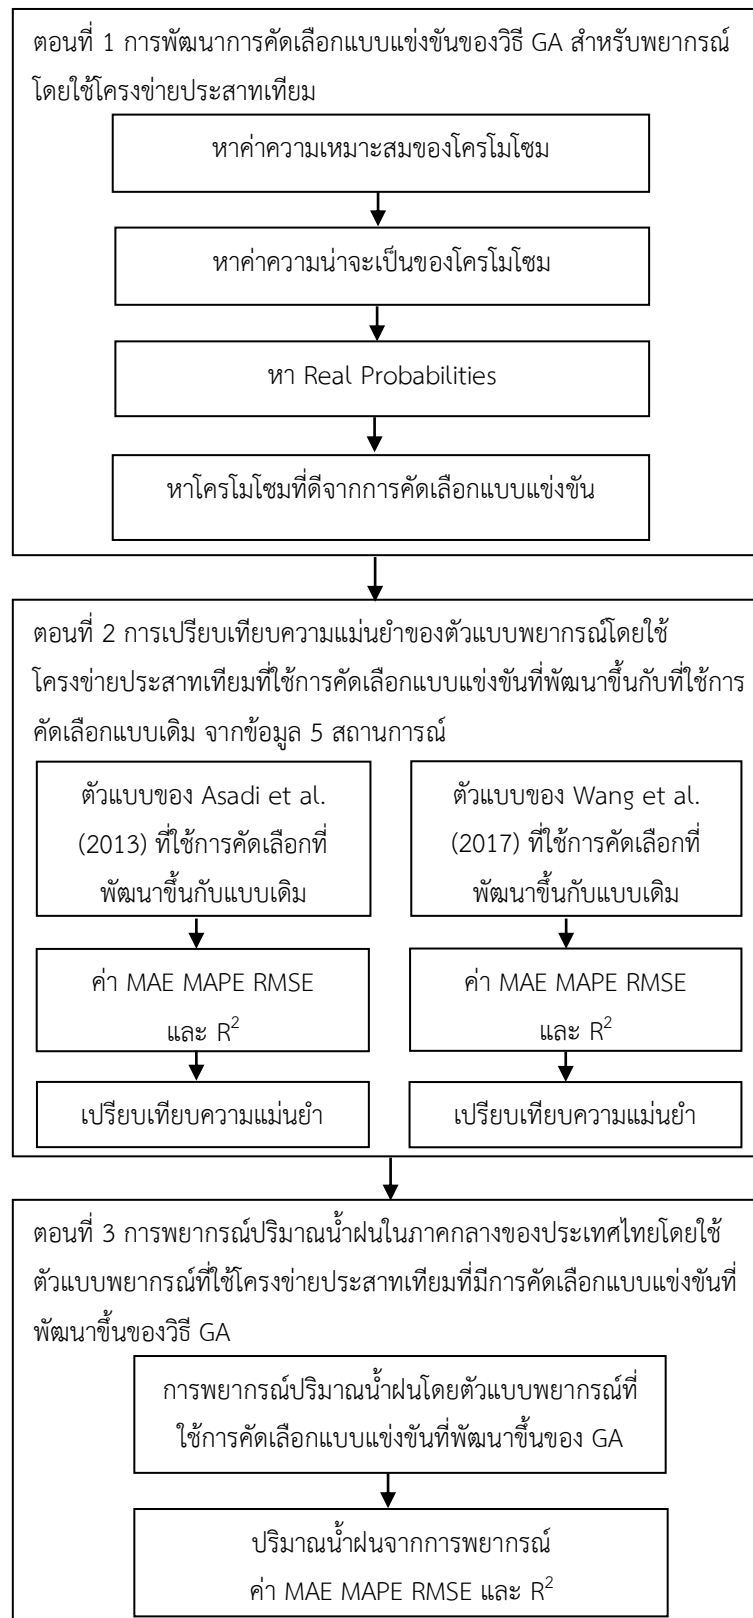
วิธีดำเนินการวิจัย

การวิจัยนี้เป็นการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ใช้หลักการ Normalized Geometric Ranking (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) และหลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991) จากนั้นเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม โดยเปรียบเทียบจากค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ที่ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามีความแม่นยำในการพยากรณ์ และค่าสัมประสิทธิ์ตัวกำหนด (Coefficient of Determination: R^2) จากข้อมูล 5 สถานการณ์ นอกจากนี้ยังได้นำตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA ไปพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย โดยมีขั้นตอนการวิจัย (ภาพที่ 3-1) ดังนี้

ตอนที่ 1 การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม

ตอนที่ 2 การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์

ตอนที่ 3 การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA



ภาพที่ 3-1 ขั้นตอนการวิจัย

ตอนที่ 1 การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้ โครงข่ายประสาทเทียม

สำหรับตอนที่ 1 เป็นการดำเนินการตามวัตถุประสงค์ข้อที่ 1 คือการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม ประกอบด้วยหลักการ Normalized Geometric Ranking (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) และหลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991) การดำเนินการของขั้นตอนนี้เป็นดังนี้

1. หาค่าความเหมาะสมของโครโมโซมแต่ละตัวในกลุ่มประชากร จากฟังก์ชันจุดประสงค์ที่กำหนดขึ้น สำหรับการวิจัยนี้โครโมโซมคือค่าน้ำหนักของแต่ละเส้นเชื่อมต่อระหว่างโหนด (Node) ของโครงข่ายประสาทเทียมและกำหนดฟังก์ชันจุดประสงค์เป็น

$$f_i = \frac{1}{SSE_i} \quad ; i=1, 2, 3, \dots, n$$

โดยที่ f_i คือค่าความเหมาะสมของโครโมโซมตัวที่ i

SSE_i คือผลรวมของค่าความคลาดเคลื่อนกำลังสองของโครโมโซมตัวที่ i

2. นำค่าความเหมาะสมมาจัดเรียง (Sort) ลำดับ (Rank) ของโครโมโซมแต่ละตัว โดยเรียงจากค่าความเหมาะสมที่ดีที่สุดให้เป็นลำดับที่ 1 และลำดับที่ n เป็นค่าความเหมาะสมที่แย่มากที่สุด เพื่อหาดัชนี (Index) ของลำดับของการจัดเรียง ซึ่งจะนำลำดับมาใช้ในการหาค่าการแจกแจงปรกติ (Normal Distribution) ของค่าความเหมาะสม จากนั้นนำค่าการแจกแจงปรกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว แทนตามตำแหน่งดัชนีของลำดับของการจัดเรียง

3. หาค่าการแจกแจงปรกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว จากหลักการ Normalized Geometric Ranking (Joines & Houck, 1994) ที่มีสูตรคือ

$$q'(1-q)^{r-1} \quad ; r=1, 2, 3, \dots, n$$

โดยที่ q แทนค่าความน่าจะเป็นในการเลือกโครโมโซมที่ดีที่สุด

r แทนค่าลำดับของโครโมโซมแต่ละตัว โดยลำดับที่ 1

เป็นค่าความเหมาะสมที่ดีที่สุด และลำดับที่ n

เป็นค่าความเหมาะสมที่แย่มากที่สุด

p แทนขนาดของประชากร

$$q' \quad \text{หาจาก} \quad q' = \frac{q}{1 - (1-q)^p}$$

4. นำค่าการแจกแจงปรกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว แทนตามตำแหน่งดัชนีของลำดับของการจัดเรียงที่ได้ตามขั้นตอนที่ 2. เสร็จกระบวนการจะได้เป็นค่า Ranking พร้อมจะนำไปใช้ในการคำนวณในกระบวนการต่อไป

5. หาค่าความน่าจะเป็น (Probabilities) ของแต่ละโครโมโซมโดยใช้ค่าความเหมาะสม จากหลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) ซึ่งได้จำนวนค่าความน่าจะเป็นเท่ากับจำนวนโครโมโซม โดยคำนวณจาก

$$p_i = \frac{f_i}{\sum_{i=1}^n f_i} \quad ; i=1, 2, 3, \dots, n$$

โดยที่ p_i แทนค่าความน่าจะเป็นเหมาะสมของโครโมโซมตัวที่ i
 f_i แทนค่าความเหมาะสมของโครโมโซมตัวที่ i

6. นำค่า Ranking จากขั้นตอนที่ 4. มาคูณกับค่าความน่าจะเป็นจากขั้นตอนที่ 5. ผลจากขั้นตอนนี้จะได้ค่า Real Probabilities ของแต่ละโครโมโซม n จำนวน และกำหนดค่าดัชนีให้กับค่า Real Probabilities ทุกจำนวน เพื่อให้พร้อมสำหรับนำไปใช้คัดเลือกโครโมโซมในขั้นตอนต่อไป

7. นำค่า Real Probabilities จากขั้นตอนที่ 6. เข้าสู่หลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991) เพื่อคัดเลือกโครโมโซมที่ดีที่สุดและไม่ตัดทิ้งไป โดยจะต้องกำหนดจำนวนของ Tournament (จำนวนหลักหรือคอลัมน์) ในแต่ละแถว ก่อนจำนวนเท่ากับ s หลัก ซึ่งเท่ากับจำนวนเส้นเชื่อมต่อระหว่างโหนดทั้งหมดของโครงข่ายประสาทเทียม และจำนวนแถวมีค่าเท่ากับ n แถว ซึ่งเท่ากับจำนวนโครโมโซมที่เป็นขนาดของประชากร (Population Size)

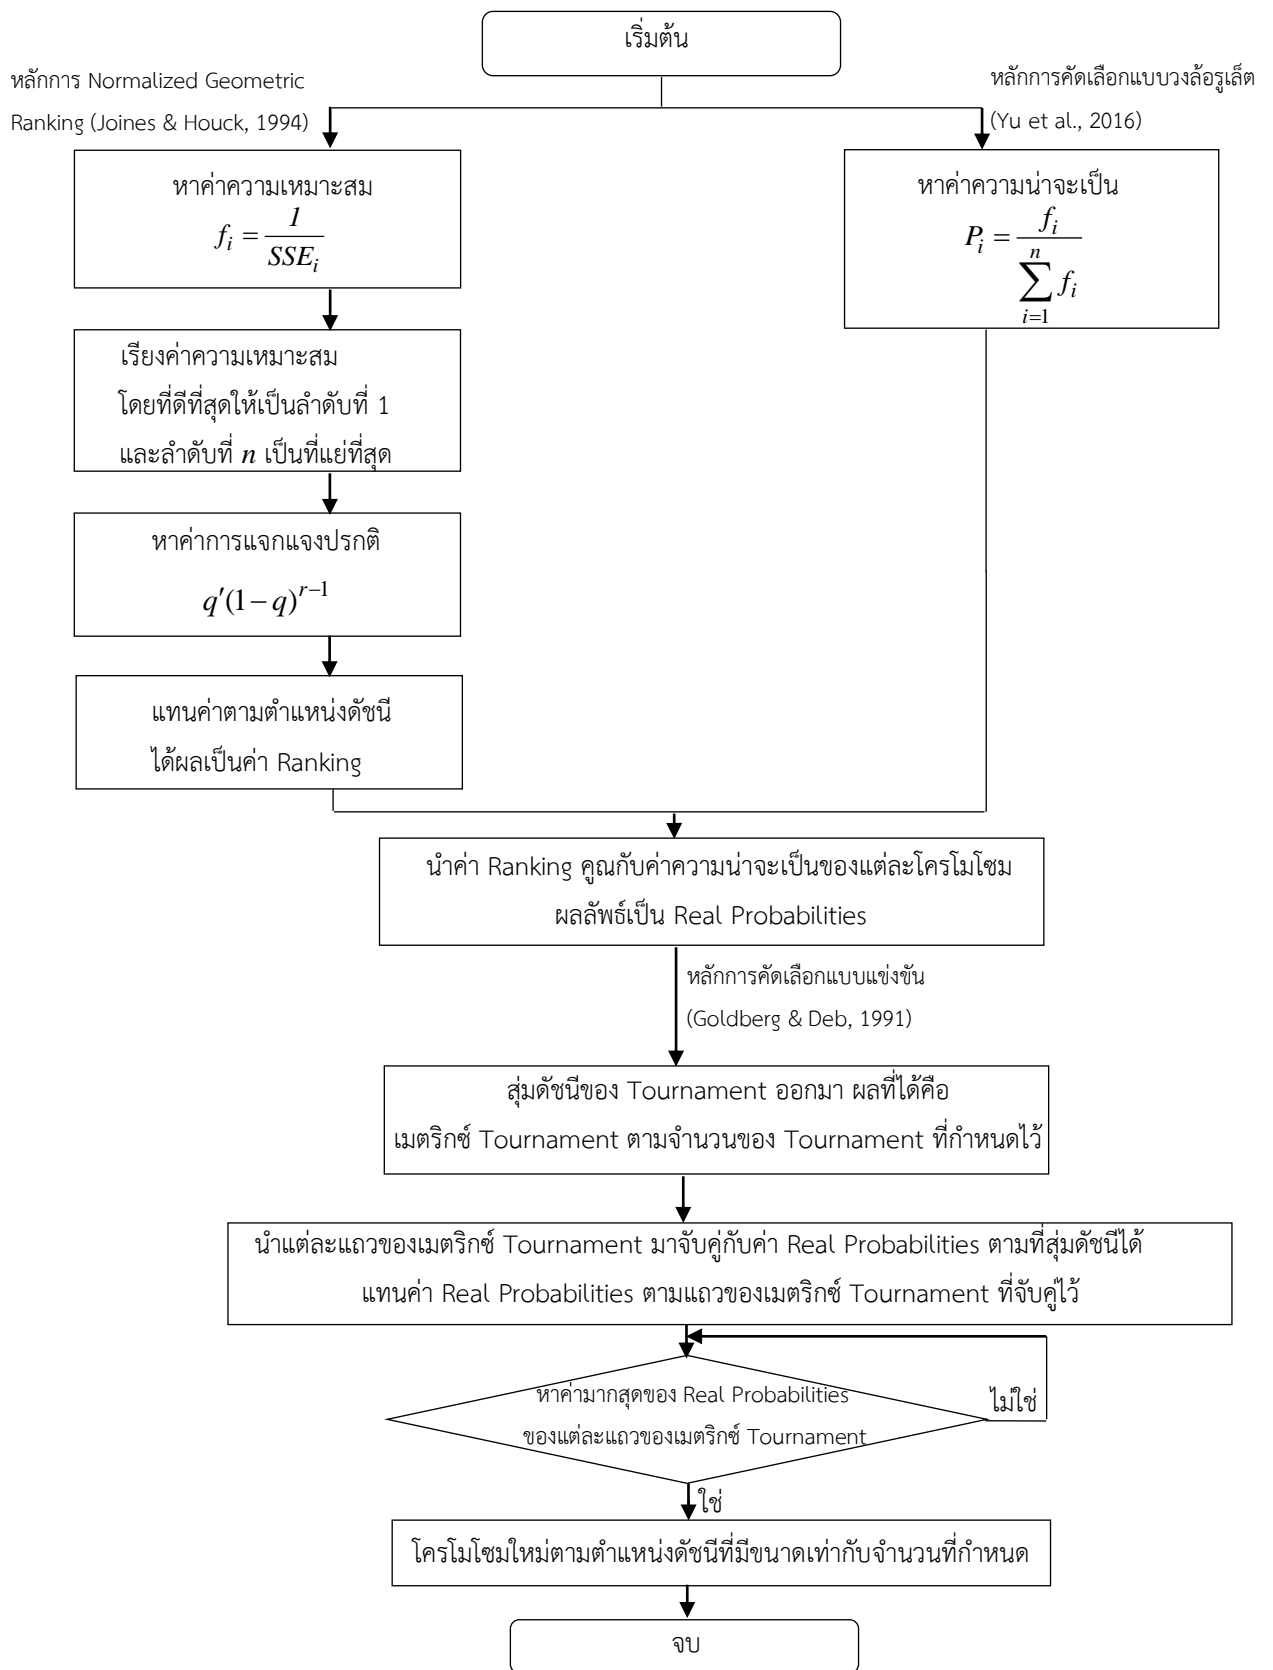
8. ทำการสุ่มดัชนีของ Tournament ออกมา ตามจำนวนที่กำหนดไว้ในขั้นตอนที่ 7. ผลที่ได้คือ เมตริกซ์ Tournament ที่มี n แถวและ s หลัก

9. นำค่า Real Probabilities มาเชื่อมโยงกับเมตริกซ์ Tournament โดยการนำแต่ละแถวของเมตริกซ์ Tournament มาจับคู่กับค่า Real Probabilities ตามที่สุ่มดัชนีได้

10. แทนค่า Real Probabilities ตามแถวของเมตริกซ์ Tournament ที่จับคู่ไว้ และหาค่ามากที่สุด (Max) ของค่า Real Probabilities ของแต่ละแถวของเมตริกซ์ Tournament นี้ ซึ่งจะเป็นตัวชนะ (Winner) ของการคัดเลือกแบบแข่งขัน ทำให้ได้ดัชนีของการคัดเลือกโครโมโซมที่ต้องการ เพื่อให้ได้โครโมโซมใหม่ที่ดี

11. เมื่อทำจบกระบวนการจะได้โครโมโซมที่ดีที่สุด ส่วนที่ไม่ดีก็จะโดนกำจัดออกไปเรื่อย ๆ ของแต่ละรอบการทำงาน โดยที่โครโมโซมนี้ก็จะถูกนำไปใช้ในกระบวนการการสลับสายพันธุ และการกลายพันธุ์ในขั้นตอนต่อไปของวิธี GA เมื่อครบรอบของจำนวนการดำเนินการทางพันธุกรรม (Genetic Operators) ของการหาค่าตอบในหนึ่งรุ่น (Generation) ที่กำหนดไว้ จะได้โครโมโซมที่ดีที่สุด ซึ่งก็คือได้น้ำหนักที่ดีของแต่ละเส้นเชื่อมต่อระหว่างโหนดของโครงข่ายประสาทเทียม สำหรับนำไปใช้ในขั้นตอนวิธีโครงข่ายประสาทเทียม

สำหรับการดำเนินการวิจัยในขั้นตอนนี้สามารถสรุปดังภาพที่ 3-2



ภาพที่ 3-2 ขั้นตอนการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม

ตอนที่ 2 การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์

สำหรับตอนที่ 2 เป็นการดำเนินการตามวัตถุประสงค์ข้อที่ 2 คือการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์แบบรายฤดูกาล โดยมีการตรวจสอบความแม่นยำของตัวแบบพยากรณ์จากค่า MAE MAPE RMSE และ R^2 การดำเนินการประกอบด้วย 2 ขั้นตอนได้แก่ การสังเคราะห์ตัวแปรที่มีผลต่อปริมาณน้ำฝนของประเทศไทยและการเปรียบเทียบตัวแบบพยากรณ์ของ Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ดังนี้

2.1 การสังเคราะห์ตัวแปรที่มีผลต่อปริมาณน้ำฝนของประเทศไทย เป็นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมมีขั้นตอนดังนี้

2.1.1 ศึกษาวรรณกรรมที่เกี่ยวข้องกับการพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม พบว่าตัวแปรพยากรณ์มีหลากหลาย เช่น ค่าดัชนีความผิวสภาพอุณหภูมิผิวน้ำทะเล บริเวณมหาสมุทรอินเดีย (DMI) ค่า SOI อุณหภูมิผิวน้ำทะเล (เปรม รังสิวานิชพงศ์ และคณะ, 2558) อุณหภูมิ ความชื้นสัมพัทธ์ การระเหย ปริมาณเมฆ (Kumar & Yadav, 2013) อุณหภูมิ ความชื้นสัมพัทธ์ ความเร็วลม ปริมาณเมฆ (Yashwant & Sananse, 2015) ค่าดัชนีพืชพรรณผลต่างแบบนอร์แมลไลซ์ (NDVI) ปริมาณน้ำฝน (Chanklan et al., 2017) อุณหภูมิ ความกดอากาศ ความชื้น (Hashim et al., 2017) ปริมาณน้ำฝน อุณหภูมิต่ำสุด อุณหภูมิสูงสุด (Samhitha & Srikanth, 2017) ความชื้นเฉลี่ย อุณหภูมิเฉลี่ย ความเร็วลมเฉลี่ย (Shaikh & Sawlani, 2017) อุณหภูมิอากาศ ความชื้นในอากาศ ความเร็วลม รังสีดวงอาทิตย์ (Wahyuni et al., 2018) เป็นต้น

2.1.2 วิเคราะห์ตัวแปรที่ใช้ในการพยากรณ์ปริมาณน้ำฝนของประเทศไทย ตัวแปรนำเข้า (X_i) ได้แก่ ความชื้นสัมพัทธ์ของอากาศ ความเร็วลมและทิศทางลมในแนวตะวันออก-ตะวันตก (ความเร็วลมตามแนวแกน x) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (ความเร็วลมตามแนวแกน y) การระเหยของน้ำ อุณหภูมิอากาศสูงสุด อุณหภูมิอากาศต่ำสุด และอุณหภูมิอากาศเฉลี่ย ตัวแปรส่งออก (y) ได้แก่ ปริมาณน้ำฝนในภาคกลางของประเทศไทย

2.1.3 ข้อมูลที่ใช้เป็นข้อมูลจริงของจังหวัดในภาคกลางของประเทศไทยเก็บรวบรวมจาก NCEP-NOAA (NOAA NCEP-NCAR, 2019) ตั้งแต่ 1 มกราคม พ.ศ. 2503 ถึง 31 มกราคม พ.ศ. 2561 เป็นข้อมูลของตัวแปรต่าง ๆ จากขั้นตอนที่ 2.1.2 ภายใต้อข้อมูล 5 สถานการณ์ตามขนาดของข้อมูลเป็น 5 แบบดังนี้ 300 400 500 1000 และ 1100 จำนวน แบบรายฤดูกาล 3 ฤดูกาลได้แก่

1) ฤดูร้อนคือ เดือนกุมภาพันธ์ มีนาคม เมษายน และพฤษภาคม 2) ฤดูฝนคือ เดือนมิถุนายน กรกฎาคม สิงหาคม และกันยายน 3) ฤดูหนาวคือ เดือนตุลาคม พฤศจิกายน ธันวาคม และมกราคม เพื่อใช้เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์

2.2 การเปรียบเทียบตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นแทนด้วยสัญลักษณ์ Asadi-GA(New)-ANN เมื่อใช้ GA กำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียง Asadi-GA-BPNN เมื่อใช้ GA ปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียมและตัวแบบของ Asadi et al. (2013) ที่ใช้การคัดเลือกแบบของวิธี GA แทนด้วยสัญลักษณ์ Asadi-GA-ANN สำหรับตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang et al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นแทนด้วยสัญลักษณ์ Wang-GA(New)-ANN เมื่อใช้ GA กำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียง Wang-GA-BPNN เมื่อใช้ GA ปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียมและตัวแบบของ Wang et al. (2017) ที่ใช้การคัดเลือกแบบเดิมของวิธี GA แทนด้วยสัญลักษณ์ Wang-GA-ANN มีขั้นตอนดังนี้

2.2.1 นำข้อมูลของตัวแปรต่าง ๆ ที่ได้จากขั้นตอนที่ 2.1.3 ของแต่ละสถานการณ์แบบรายฤดูกาล สร้างตัวแบบ Asadi-GA-ANN ซึ่งประกอบด้วยวิธี RA (MRA) ที่ใช้เทคนิค Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่าย พิจารณาจากค่า b ของตัวแปรพยากรณ์ (x_i) ได้แก่ ความชื้นสัมพัทธ์ของอากาศ (x_1) ความเร็วลมและทิศทางลมในแนวตะวันออก-ตะวันตก (ความเร็วลมตามแนวแกน x) (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (ความเร็วลมตามแนวแกน y) (x_3) การระเหยของน้ำ (x_4) อุณหภูมิอากาศสูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และ อุณหภูมิอากาศเฉลี่ย (x_7) จากสมการพยากรณ์ตัวแปรเกณฑ์ (Y') ได้แก่ปริมาณน้ำฝนในภาคกลางของประเทศไทยด้วยชุดของตัวแปรพยากรณ์ (x_i) และพิจารณาค่า R ซึ่งแสดงถึงความสัมพันธ์ระหว่างตัวแปรพยากรณ์กับตัวแปรเกณฑ์ โดยตัวแปรพยากรณ์ที่มีค่าน้ำหนักหรือสัมประสิทธิ์ถดถอย (b) น้อยกว่าที่จะถูกตัดทิ้งไป เพื่อลดจำนวนตัวแปรนำเข้าลง ผลลัพธ์ที่ได้คือ ตัวแปรนำเข้าสำหรับโครงข่ายประสาทเทียม ขั้นตอนต่อมาใช้วิธี K-means เพื่อแบ่งกลุ่มข้อมูลนำเข้า โดยที่วิธี K-means แบ่งกลุ่มข้อมูลนำเข้าออกเป็น 2 กลุ่ม วิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงในแต่ละเส้นเชื่อมของโครงข่ายที่ใช้การคัดเลือกแบบเดิม สำหรับนำไปใช้สร้างตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมแบบ FFNN จากนั้นสร้างตัวแบบ Asadi-GA(New)-ANN และ Asadi-GA-BPNN ซึ่งมีการนำวิธี K-means ออกเพื่อเป็นการลดขั้นตอนการสร้างตัวแบบรวมกับการเปลี่ยนการคัดเลือกแบบเดิมของวิธี GA เป็นการคัดเลือกแบบแข่งขันที่พัฒนาขึ้น (Asadi-GA(New)-ANN) และเปลี่ยนตำแหน่งการใช้วิธี GA จากที่ใช้ในการกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงในแต่ละ

เส้นเชื่อมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA มาใช้ในการปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียมแทน (Asadi-GA-BPNN) รูปแบบการทำงานของตัวแบบ Asadi-GA-ANN Asadi-GA(New)-ANN และ Asadi-GA-BPNN ดังตารางที่ 3-1

ตารางที่ 3-1 รูปแบบการทำงานของตัวแบบ Asadi-GA-ANN Asadi-GA(New)-ANN และ Asadi-GA-BPNN

ตัวแบบพยากรณ์	วิธี GA			โครงข่ายประสาทเทียม	
	การคัดเลือกโครโมโซม	การสลับสายพันธุ	การกลายพันธุ์	จำนวนโหนดในแต่ละชั้น	ฟังก์ชันการแปลง
1. Asadi-GA-ANN	แบบแบ่งเป็นช่วง	แบบสองตำแหน่ง	แบบหนึ่งตำแหน่ง	$n-4-4-1$	Log-sig, Log-sig, Tanh
2. Asadi-GA(New)-ANN	แบบแข่งขันที่พัฒนาขึ้น	แบบสองตำแหน่ง	แบบหนึ่งตำแหน่ง	$n-4-4-1$	Log-sig, Log-sig, Tanh
3. Asadi-GA-BPNN	แบบแข่งขันที่พัฒนาขึ้น	แบบสองตำแหน่ง	แบบหนึ่งตำแหน่ง	$n-4-4-1$	Log-sig, Log-sig, Tanh

จากตารางที่ 3-1 รูปแบบการทำงานของตัวแบบพยากรณ์โดยใช้โครงข่ายของ Asadi et al. (2013) ทั้ง 3 ตัวแบบได้แก่ ตัวแบบ Asadi-GA-ANN Asadi-GA(New)-ANN และ Asadi-GA-BPNN ส่วนวิธี GA กำหนดขนาดของประชากรเท่ากับ 100 จำนวน จำนวนการดำเนินการทางพันธุกรรม (Genetic Operators) ของการหาคำตอบในหนึ่งรุ่น (Generation) เท่ากับ 50 รอบ มีการคัดเลือกโครโมโซม (ค่าน้ำหนัก) แบ่งเป็น 2 วิธีคือ 1) ใช้การคัดเลือกแบบเดิมคือแบบแบ่งเป็นช่วง (Truncation Selection) 2) ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้น โดยตัวแบบพยากรณ์ทั้ง 3 มีการสลับสายพันธุแบบสองตำแหน่ง (Two-point Crossover) โดยกำหนดความน่าจะเป็นในการสลับสายพันธุเท่ากับ 0.85 และการกลายพันธุ์แบบหนึ่งตำแหน่ง (One-point Mutation) โดยกำหนดความน่าจะเป็นในการกลายพันธุ์เท่ากับ 0.05 และสำหรับในส่วนโครงข่ายประสาทเทียมประกอบด้วยชั้นรับข้อมูลเข้าจำนวน 1 ชั้น n โหนด (Node) เป็นตัวแปรนำเข้าที่ผ่านการคัดเลือกจากวิธี MRA ด้วยเทคนิค Stepwise จำนวน n ตัว ชั้นซ่อนจำนวน 2 ชั้น ชั้นละ 4 โหนด และชั้นส่งข้อมูลออกจำนวน 1 ชั้น 1 โหนดได้แก่ ตัวแปรปริมาณน้ำฝนในภาคกลางของประเทศไทย (y) กำหนดฟังก์ชัน (Transformation Function) ชั้นรับข้อมูลออก คือ ฟังก์ชันไฮเปอร์โบลิกแทนเจนต์ (Hyperbolic

Tangent Function: Tanh) และชั้นซ่อนแต่ละชั้น คือ ฟังก์ชันลอก-ซิกมอยด์ (Log-sigmoid Transfer Function: Log-sig) ขั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ Lavenberg Marquardt (LM) จำนวนการทำซ้ำในแต่ละรอบเท่ากับ 3000

2.2.2 นำข้อมูลของตัวแปรต่าง ๆ ที่ได้จากขั้นตอนที่ 2.1.3 ของแต่ละสถานการณ์แบบรายฤดูกาล สร้างตัวแบบ Wang-GA-ANN ซึ่งประกอบด้วยวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงในแต่ละเส้นเชื่อมของโครงข่ายที่ใช้การคัดเลือกแบบเดิม สำหรับนำไปใช้สร้างตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมแบบ BPNN จากนั้นสร้างตัวแบบ Wang-GA(New)-ANN และ Wang-GA-BPNN โดยเปลี่ยนการคัดเลือกแบบเดิมของวิธี GA เป็นการคัดเลือกแบบแข่งขันที่พัฒนาขึ้น (Wang-GA(New)-ANN) และเปลี่ยนตำแหน่งการใช้วิธี GA จากที่ใช้ในการกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงในแต่ละเส้นเชื่อมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA มาใช้ในการปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียมแทน (Wang-GA-BPNN) รูปแบบการทำงานของตัวแบบ Wang-GA-ANN Wang-GA(New)-ANN และ Wang-GA-BPNN ดังตารางที่ 3-2

ตารางที่ 3-2 รูปแบบการทำงานของตัวแบบ Wang-GA-ANN Wang-GA(New)-ANN และ Wang-GA-BPNN

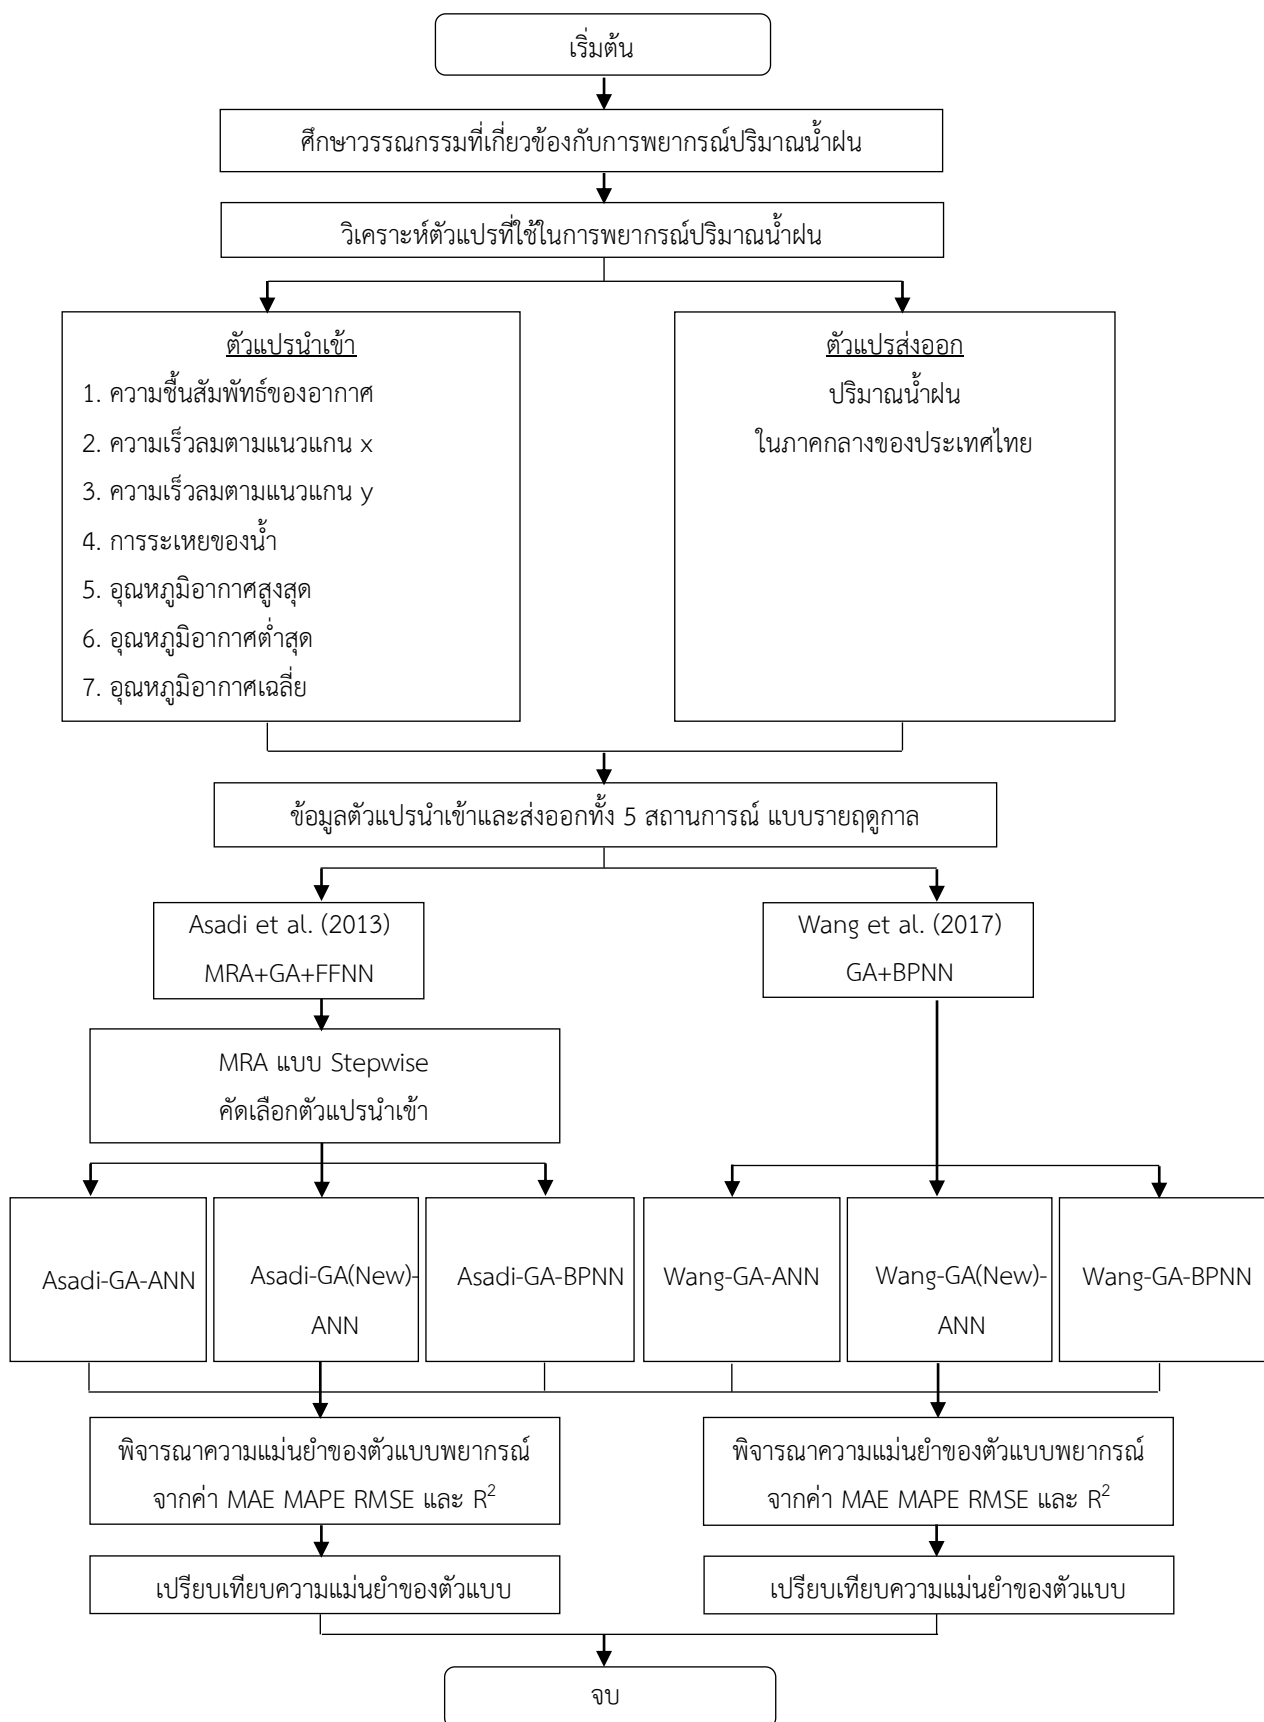
ตัวแบบพยากรณ์	วิธี GA			โครงข่ายประสาทเทียม	
	การคัดเลือกโครโมโซม	การสลับสายพันธุ	การกลายพันธุ์	จำนวนโหนดในแต่ละชั้น	ฟังก์ชันการแปลง
1. Wang-GA-ANN	แบบวงล้อรูเล็ต	Arithmetic	แบบนอน	7-11-1	Log-sig, Purelin
		Crossover	ยูนิฟอร์ม		
2. Wang-GA(New)-ANN	แบบแข่งขันที่พัฒนาขึ้น	Arithmetic	แบบนอน	7-11-1	Log-sig, Purelin
		Crossover	ยูนิฟอร์ม		
3. Wang-GA-BPNN	แบบแข่งขันที่พัฒนาขึ้น	Arithmetic	แบบนอน	7-11-1	Log-sig, Purelin
		Crossover	ยูนิฟอร์ม		

จากตารางที่ 3-2 รูปแบบการทำงานของตัวแบบพยากรณ์โดยใช้โครงข่ายของ Wang et al. (2017) ทั้ง 3 ตัวแบบได้แก่ ตัวแบบ Wang-GA-ANN Wang-GA(New)-ANN และ Wang-GA-BPNN ส่วนวิธี GA กำหนดขนาดของประชากรเท่ากับ 40 จำนวน จำนวนการดำเนินการทางพันธุกรรมของการหาคำตอบในหนึ่งรุ่นเท่ากับ 50 รอบ มีการคัดเลือกโครโมโซม (ค่าน้ำหนัก)

แบ่งเป็น 2 วิธีคือ 1) ใช้การคัดเลือกแบบเดิมคือแบบวงล้อรูเล็ต 2) ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้น โดยตัวแบบพยากรณ์ทั้ง 3 มีการสลับสายพันธุ์แบบ Arithmetic Crossover โดยกำหนดความน่าจะเป็นในการสลับสายพันธุ์เท่ากับ 0.7 และการกลายพันธุ์แบบนอนยูนิฟอร์ม (Non-uniform Mutation) โดยกำหนดความน่าจะเป็นในการกลายพันธุ์เท่ากับ 0.05 และสำหรับในส่วน of โครงข่ายประสาทเทียมประกอบด้วย ชั้นรับข้อมูลเข้าจำนวน 1 ชั้น 7 โหนดได้แก่ ตัวแปรนำเข้า ความชื้นสัมพัทธ์ของอากาศ (x_1) ความเร็วลมและทิศทางลมในแนวตะวันออก-ตะวันตก (ความเร็วลมตามแนวแกน x) (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (ความเร็วลมตามแนวแกน y) (x_3) การระเหยของน้ำ (x_4) อุณหภูมิอากาศสูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และ อุณหภูมิอากาศเฉลี่ย (x_7) ชั้นซ่อน 1 ชั้นจำนวน 11 โหนด และชั้นส่งข้อมูลออกจำนวน 1 ชั้น 1 โหนดได้แก่ ตัวแปรปริมาณน้ำฝนในภาคกลางของประเทศไทย (y) กำหนดฟังก์ชันชั้นรับข้อมูลออกคือ ฟังก์ชันเพียวลิน (Purelin Function: Purelin) และชั้นซ่อน คือ ฟังก์ชัน Log-sig ชั้นตอนวิธีการเรียนรู้ของโครงข่ายประสาทเทียมใช้แบบ Bayesian Regularization (BR) จำนวนการทำซ้ำในแต่ละรอบเท่ากับ 1000

2.2.3 เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมทั้ง 6 แบบ จากขั้นตอนที่ 2.2.1 และ 2.2.2 ของแต่ละฤดูกาล ภายใต้อข้อมูล 5 สถานการณ์ตามขนาดของข้อมูล พิจารณาความแม่นยำจากค่า MAE MAPE RMSE และ R^2

สำหรับการดำเนินการวิจัยในขั้นตอนนี้ ภายใต้อข้อมูล 5 สถานการณ์ตามขนาดของข้อมูล เป็น 5 แบบดังนี้ 300 400 500 1000 และ 1100 จำนวน แบบรายฤดูกาล 3 ฤดูกาล สามารถสรุปดังภาพที่ 3-3



ภาพที่ 3-3 ขั้นตอนการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์

ตอนที่ 3 การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบ พยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA

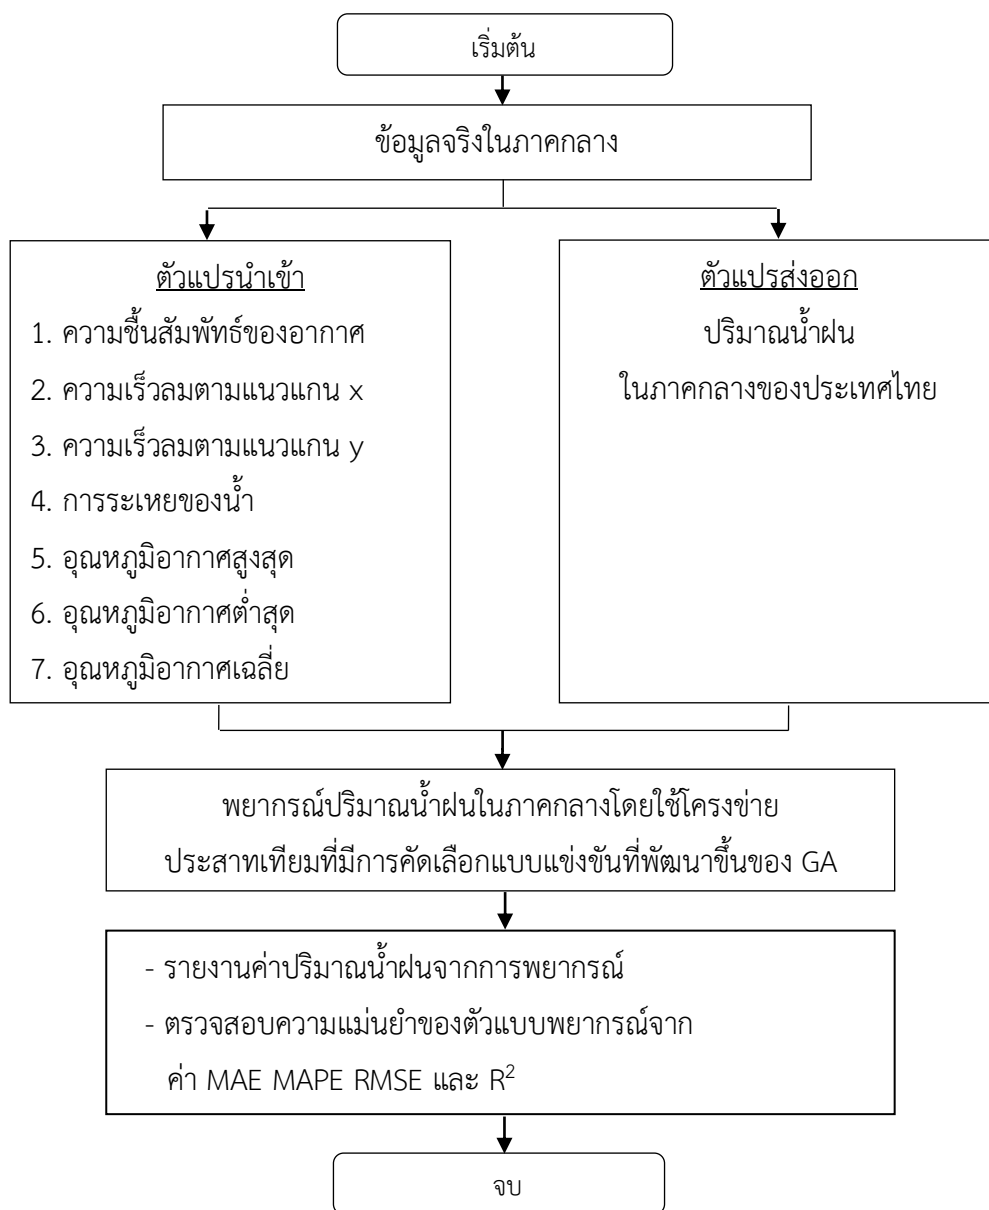
สำหรับตอนที่ 3 เป็นการดำเนินการตามวัตถุประสงค์ข้อที่ 3 คือการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA ขั้นตอนนี้เป็นกรนำการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA มาใช้จริง สำหรับพยากรณ์ปริมาณน้ำฝนร่วมกับการใช้โครงข่ายประสาทเทียมและวิธี GA เพื่อพยากรณ์ปริมาณน้ำฝนในอนาคตแบบรายฤดูกาลในภาคกลางของประเทศไทย จำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2062-2566 และเพื่อเป็นการตรวจสอบความแม่นยำของตัวแบบที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA การดำเนินการในขั้นตอนนี้เป็นดังนี้

1. นำข้อมูลจริงของจังหวัดในภาคกลางเก็บรวบรวมจาก NCEP-NOAA (NOAA NCEP-NCAR, 2019) ตั้งแต่ปี พ.ศ. 2532-2561 มาใช้สำหรับการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย ข้อมูลนำเข้าจำนวน 7 ตัวแปรได้แก่ ความชื้นสัมพัทธ์ของอากาศ (x_1) ความเร็วลมและทิศทางลมในแนวตะวันออก-ตะวันตก (ความเร็วลมตามแนวแกน x) (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (ความเร็วลมตามแนวแกน y) (x_3) การระเหยของน้ำ (x_4) อุณหภูมิอากาศสูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และอุณหภูมิอากาศเฉลี่ย (x_7) ข้อมูลส่งออกจำนวน 1 ตัวแปรได้แก่ ปริมาณน้ำฝนในภาคกลางของประเทศไทย (y)

2. นำข้อมูลตัวแปรต่าง ๆ จากขั้นตอนที่ 1. มาสร้างตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA สำหรับการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยแบบรายฤดูกาล 3 ฤดูกาลได้แก่ 1) ฤดูร้อนคือ เดือนกุมภาพันธ์ มีนาคม เมษายน และพฤษภาคม 2) ฤดูฝนคือ เดือนมิถุนายน กรกฎาคม สิงหาคม และกันยายน 3) ฤดูหนาวคือ เดือนตุลาคม พฤศจิกายน ธันวาคม และมกราคม ด้วยโปรแกรม Matlab

3. รายงานค่าปริมาณน้ำฝน และตรวจสอบความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย โดยใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA โดยพิจารณาจากค่า MAE MAPE RMSE ที่ควรมีค่าน้อย ๆ เข้าใกล้ 0-1 และค่า R^2 ที่มีค่ามาก ๆ เข้าใกล้ 1 และควรมีค่ามากกว่า 0.70 (สถาบันพัฒนาการชลประทาน, 2551)

สรุปการดำเนินการวิจัยในขั้นตอนนี้อยู่ที่ภาพที่ 3-4



ภาพที่ 3-4 ขั้นตอนการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA

บทที่ 4

ผลการวิจัย

ผลการวิจัยการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมสำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม นำเสนอตามวัตถุประสงค์ของการวิจัย โดยแบ่งเป็น 3 ตอน ดังนี้

ตอนที่ 1 ผลการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม

ตอนที่ 2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์

ตอนที่ 3 ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA ก่อนการนำเสนอผลการวิจัย ขอเสนอสัญลักษณ์ต่าง ๆ ที่ใช้ในการวิจัย ดังนี้

หลักการ NGR แทน หลักการ Normalized Geometric Ranking (Joines & Houck, 1994)

หลักการ RWS แทน หลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016)

หลักการ TS แทน หลักการคัดเลือกแบบแข่งขัน (Goldberg & Deb, 1991)

Asadi-GA(New)-ANN แทน ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม

Asadi-GA-BPNN แทน ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียม

Asadi-GA-ANN แทน ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) เมื่อใช้การคัดเลือกแบบเดิมของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม

Wang-GA(New)-ANN แทน ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang et al. (2017) เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม

Wang-GA-BPNN แทน ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang et al. (2017) เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียม

Wang-GA-ANN แทน ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang et al. (2017) เมื่อใช้การคัดเลือกแบบเดิมของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม

y	แทน ตัวแปรเกณฑ์หรือตัวแปรส่งออกคือปริมาณน้ำฝน
Y'	แทน คะแนนพยากรณ์ของตัวแปรเกณฑ์คือปริมาณน้ำฝนจากวิธี MRA
x_1	แทน ตัวแปรพยากรณ์หรือตัวแปรนำเข้าตัวที่ 1 คือความชื้นสัมพัทธ์ของอากาศ
x_2	แทน ตัวแปรพยากรณ์หรือตัวแปรนำเข้าตัวที่ 2 คือความเร็วลมตามแนวแกน x
x_3	แทน ตัวแปรพยากรณ์หรือตัวแปรนำเข้าตัวที่ 3 คือความเร็วลมตามแนวแกน y
x_4	แทน ตัวแปรพยากรณ์หรือตัวแปรนำเข้าตัวที่ 4 คือการระเหยของน้ำ
x_5	แทน ตัวแปรพยากรณ์หรือตัวแปรนำเข้าตัวที่ 5 คืออุณหภูมิอากาศสูงสุด
x_6	แทน ตัวแปรพยากรณ์หรือตัวแปรนำเข้าตัวที่ 6 คืออุณหภูมิอากาศต่ำสุด
x_7	แทน ตัวแปรพยากรณ์หรือตัวแปรนำเข้าตัวที่ 7 คืออุณหภูมิอากาศเฉลี่ย
MAE	แทน ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error)
MAPE	แทน ค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error)
RMSE	แทน รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error)
R^2	แทน ค่าสัมประสิทธิ์ตัวกำหนด (Coefficient of Determination)
b	แทน สัมประสิทธิ์ถดถอย (Regression Coefficient)
R	แทน ค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณ (Multiple Correlation Coefficient)

ตอนที่ 1 ผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม

ผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม ประกอบด้วยหลักการ NGR (Joines & Houck, 1994) หลักการ RWS (Yu et al., 2016) และหลักการ TS (Goldberg & Deb, 1991)

กำหนดขนาดของประชากร (Population Size) เท่ากับ 100 จำนวน ($n=100$) สำหรับของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ส่วนของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN เท่ากับ 40 จำนวน ($n=40$) จำนวนการดำเนินการทางพันธุกรรม (Genetic Operators) ของการหาคำตอบในหนึ่งรุ่น (Generation) เท่ากับ 50 รอบ และโครโมโซมคือค่าน้ำหนักของแต่ละเส้นเชื่อมต่อระหว่างโหนดของโครงข่ายประสาทเทียม

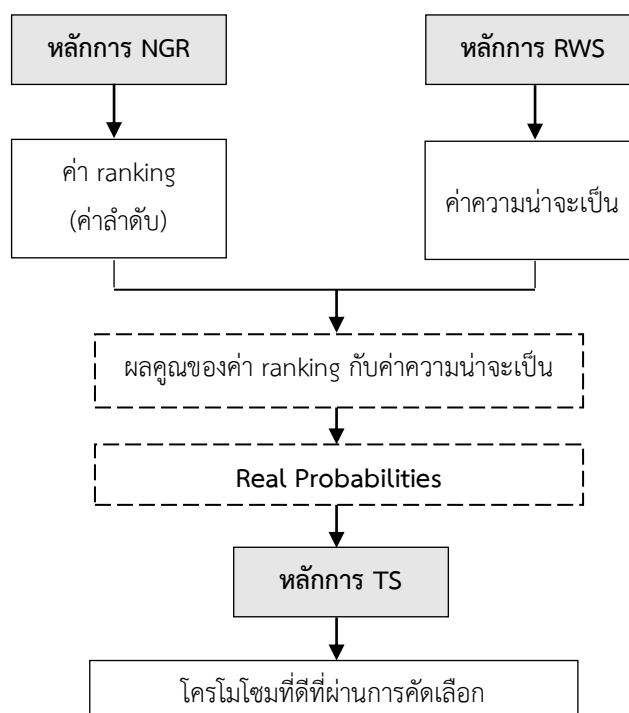
จากขั้นตอนของหลักการ NGR (Joines & Houck, 1994) ผลที่ได้คือ ค่า ranking หรือค่าลำดับของการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว $r=1, 2, 3, \dots, 100$ ของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และ $r=1, 2, 3, \dots, 40$ ของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ผ่านการจัดเรียง (Sort) ลำดับ (Rank) ของค่าความเหมาะสมของโครโมโซม โดยเรียงจากค่าความเหมาะสมที่ดีที่สุดให้เป็นลำดับที่ 1 และลำดับที่ 100 เป็นค่าความเหมาะสมที่แย่ที่สุดสำหรับของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ค่าความเหมาะสมที่ดีที่สุดให้เป็นลำดับที่ 1 ค่าความเหมาะสมที่แย่ที่สุดเป็นลำดับที่ 40

จากหลักการ RWS (Yu et al., 2016) ผลที่ได้คือ ค่าความน่าจะเป็นของค่าความเหมาะสมของแต่ละโครโมโซม ($i=1, 2, 3, \dots, 100$ และ $i=1, 2, 3, \dots, 40$)

เมื่อนำผลที่ได้จากหลักการทั้งสองข้างต้นมาคูณได้ ทำให้ได้ค่า Real Probabilities ของโครโมโซมแต่ละตัวทั้ง 100 จำนวนและ 40 จำนวน ซึ่งเป็นค่าความน่าจะเป็นที่แท้จริงของโครโมโซมแต่ละตัว เพื่อนำไปใช้ในการคัดเลือกโครโมโซมที่ดีโดยใช้หลักการ TS (Goldberg & Deb, 1991) ซึ่งจะมีการกำหนดจำนวนของ Tournament (จำนวนหลักหรือคอลัมน์) ในแต่ละแถว จำนวนเท่ากับ s หลัก เท่ากับจำนวนเส้นเชื่อมต่อระหว่างโหนดทั้งหมดของโครงข่ายประสาทเทียม และจำนวนแถวมีค่าเท่ากับ n แถว เท่ากับจำนวนโครโมโซมที่เป็นขนาดของประชากร ตัวแบบพยากรณ์ของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN กำหนดค่า s ที่เป็นผลมาจากการคัดเลือกตัวแปรนำเข้า และ $n = 100$ สำหรับตัวแบบพยากรณ์ของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN กำหนดค่า $s = 96$ และ $n = 40$ ขั้นตอนต่อมาทำการสุ่มดัชนีของ Tournament ตามจำนวนที่กำหนดไว้ ผลที่ได้คือ เมตริกซ์ Tournament นำค่า Real Probabilities มาเชื่อมโยงกับเมตริกซ์ Tournament โดยการนำแต่ละแถวของเมตริกซ์ Tournament มาจับคู่กับค่า Real Probabilities ตามที่สุ่มดัชนีได้ จากนั้นแทนค่า Real Probabilities ตามแถวของเมตริกซ์ Tournament ที่จับคู่ไว้ และหาค่ามากที่สุด (Max) ของค่า Real Probabilities ของแต่ละแถวของเมตริกซ์ Tournament นี้ ซึ่งจะเป็นผู้ชนะ (Winner) ของการคัดเลือกแบบแข่งขัน

จากหลักการ TS (Goldberg & Deb, 1991) ผลที่ได้คือ โครโมโซมที่ดีที่สุดที่ผ่านการคัดเลือกตามดัชนีของการคัดเลือกโครโมโซมที่ต้องการ สำหรับนำไปใช้ในกระบวนการการสลับสายพันธุ์ และการกลายพันธุ์ในขั้นตอนต่อไปของวิธี GA เมื่อครบจำนวนการดำเนินการทางพันธุกรรมของการหาคำตอบในหนึ่งรุ่นจำนวน 50 รอบ

ผลลัพธ์จากหลักการทั้ง 3 ทำให้ได้วิธีใหม่ในการคัดเลือกโครโมโซมที่ดีที่สุดที่พร้อมนำไปใช้สร้างตัวแบบพยากรณ์ร่วมกับโครงข่ายประสาทเทียมต่อไป ดังนั้นผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียมคือ โครโมโซมที่ดีที่สุด (ค่าน้ำหนักของแต่ละเส้นเชื่อมต่อระหว่างโหนดที่ดีที่สุดของโครงข่ายประสาทเทียม) เพื่อนำไปใช้สำหรับสร้างตัวแบบพยากรณ์ที่เหมาะสมในการพยากรณ์เรื่องต่าง ๆ ผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ดังภาพที่ 4-1



ภาพที่ 4-1 ผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA

ตอนที่ 2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ที่ใช้วิธีโครงข่ายประสาท

เทียมแบบ FFNN ร่วมกับวิธี GA และของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้วิธีโครงข่ายประสาทเทียมแบบ BPNN ร่วมกับวิธี GA โดยมีการตรวจสอบความแม่นยำของตัวแบบพยากรณ์จากค่า MAE MAPE RMSE และ R^2 โดยที่ค่า MAE MAPE และ RMSE ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามี ความแม่นยำในการพยากรณ์ ส่วนค่า R^2 ต้องมีค่ามาก ๆ เข้าใกล้ 1 และควรมากกว่า 0.7 (สถาบันพัฒนาการชลประทาน, 2551) จึงถือว่ามี ความแม่นยำในการพยากรณ์ ภายใต้อข้อมูล 5 สถานการณ์ ดังนี้

สถานการณ์ที่ 1 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้อข้อมูลขนาด 300 จำนวน

สถานการณ์ที่ 2 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้อข้อมูลขนาด 400 จำนวน

สถานการณ์ที่ 3 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้อข้อมูลขนาด 500 จำนวน

สถานการณ์ที่ 4 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้อข้อมูลขนาด 1000 จำนวน

สถานการณ์ที่ 5 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้อข้อมูลขนาด 1100 จำนวน

การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์สำหรับแต่ละสถานการณ์ ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมร่วมกับวิธี GA ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA แบ่งเป็น 3 ฤดูกาล ได้แก่ ฤดูร้อน ฤดูฝน และฤดูหนาว ดังนี้

2.1 สำหรับสถานการณ์ที่ 1 ภายใต้ข้อมูลขนาด 300 จำนวน แบบรายฤดูกาล แบ่งการแสดงผลเป็น 2 ส่วน ได้แก่

2.1.1 ข้อมูลพื้นฐาน ได้แก่ ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัว ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise

2.1.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

ผลการวิเคราะห์ข้อมูลสำหรับสถานการณ์ที่ 1 ภายใต้ข้อมูลขนาด 300 จำนวน แบบรายฤดูกาล แสดงผลดังนี้

2.1.1 ข้อมูลพื้นฐาน

ตารางที่ 4-1 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูกาลของข้อมูลขนาด 300 จำนวน

ตัวแปร	ค่าต่ำสุด			ค่าสูงสุด			ค่าเฉลี่ย			ส่วนเบี่ยงเบนมาตรฐาน		
	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว
y	1.60	4.62	0.54	10.428	16.99	7.55	6.00	11.54	3.74	1.57	2.06	1.27
x ₁	21.93	22.93	26.10	82.05	82.13	81.38	60.44	60.38	60.55	12.19	12.18	13.75
x ₂	-1.34	0.40	-2.50	1.04	4.72	-0.24	-0.09	1.44	-1.45	0.47	0.83	0.47
x ₃	-0.32	0.34	-2.62	1.55	2.05	0.25	0.67	0.88	-0.88	0.32	0.35	0.60
x ₄	5.88	4.20	4.80	26.43	9.86	15.85	12.39	5.41	9.17	3.44	0.97	2.10
x ₅	27.60	25.77	25.01	36.46	29.12	31.60	31.74	27.38	28.18	1.62	0.75	1.29
x ₆	17.71	20.38	13.24	25.47	26.19	25.20	21.29	23.01	19.12	1.69	1.38	2.78
x ₇	22.10	23.03	18.52	28.97	27.03	26.84	25.60	24.88	23.00	1.37	0.96	1.87

ตารางที่ 4-1 แสดงค่าสถิติพื้นฐานจำแนกตามฤดูกาลของข้อมูลขนาด 300 จำนวนดังนี้ ปริมาณน้ำฝนมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 11.54 มิลลิเมตร และมีส่วนเบี่ยงเบนมาตรฐานเท่ากับ 2.06 มิลลิเมตร ความชื้นสัมพัทธ์ของอากาศมีค่าเฉลี่ยสูงสุดในฤดูหนาวคิดเป็นร้อยละ 60.55 และส่วนเบี่ยงเบนมาตรฐานร้อยละ 13.75 ความเร็วลมตามแนวแกน x มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 1.44 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.88 เมตรต่อวินาที ความเร็วลมตามแนวแกน y มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 0.92 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.35 เมตรต่อวินาที การระเหยของน้ำมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 12.39 มิลลิเมตร และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 3.44 มิลลิเมตร อุณหภูมิอากาศสูงสุดมี

ค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 31.74 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.62 °C อุณหภูมิอากาศต่ำสุดมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 23.01 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.38 °C และอุณหภูมิอากาศเฉลี่ยมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 25.60 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.37 °C

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-2

ตารางที่ 4-2 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้อข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.100 (.082)	1						
x_3	.034 (.559)	.376** (.000)	1					
x_4	.027 (.641)	.557** (.000)	.439** (.000)	1				
x_5	-.005 (.930)	.370** (.000)	.384** (.000)	.440** (.000)	1			
x_6	.192** (.001)	.479** (.000)	-.148* (.010)	.087 (.134)	.281** (.000)	1		
x_7	.135* (.020)	.543** (.000)	.182** (.002)	.339** (.000)	.768** (.000)	.748** (.000)	1	
y	.069 (.230)	-.223** (.000)	-.520** (.000)	-.613** (.000)	-.682** (.000)	.197** (.001)	-.336** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-2 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้อข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ อุณหภูมิอากาศสูงสุด (-0.682) รองลงมาคือการระเหย

ของน้ำ (-0.613) ความเร็วลมตามแนวแกน y (-0.520) อุณหภูมิอากาศเฉลี่ย (-0.336) ความเร็วลมตามแนวแกน x (-0.223) และอุณหภูมิอากาศต่ำสุด (0.197) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือความชื้นสัมพัทธ์ของอากาศ (0.069)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-3

ตารางที่ 4-3 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้อข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน

Variable Entered										
Multiple R	.864									
Coefficient of Determination(R ²)	.747									
Adjusted R ²	.744									
Standard error of estimate	.795									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	550.425	4	137.606	217.995	.000					
Residual	186.215	295	.631							
Total	736.640	299								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	19.547	.992		19.709	.000					
X ₅	-.451	.062	-.466	-7.284	.000	-.682	-.390	-.213	.210	4.772
X ₆	.530	.057	.572	9.340	.000	.197	.478	.273	.229	4.376
X ₄	-.165	.015	-.361	-11.042	.000	-.613	-.541	-.323	.800	1.250
X ₇	-.326	.105	-.284	-3.097	.002	-.336	-.177	-.091	.102	9.793

จากตารางที่ 4-3 พบว่าตัวแปรพยากรณ์ได้แก่ การระเหยของน้ำ อุณหภูมิอากาศสูงสุด อุณหภูมิอากาศต่ำสุด และอุณหภูมิอากาศเฉลี่ย ทำให้ค่า R = .864 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 74.7% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วย

ค่า b ได้เป็น $y' = 19.547 - .165x_4 - .451x_5 + .530x_6 - .326x_7$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ อุณหภูมิอากาศต่ำสุด รองลงมาคือ อุณหภูมิอากาศสูงสุด อุณหภูมิอากาศเฉลี่ย และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้อัตราขนาด 300 จำนวน สำหรับฤดูร้อน ได้ตัวแปรนำเข้าคือ การระเหยของน้ำ อุณหภูมิอากาศสูงสุด อุณหภูมิอากาศต่ำสุด และอุณหภูมิอากาศเฉลี่ย ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 4-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-4

ตารางที่ 4-4 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้อัตราขนาด 300 จำนวน สำหรับฤดูฝน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.010 (.866)	1						
x_3	.125* (.030)	.611** (.000)	1					
x_4	.045 (.434)	.389** (.000)	.044 (.445)	1				
x_5	104 (.072)	-.017 (.765)	.431** (.000)	-.098 (.091)	1			
x_6	.147* (.011)	.690** (.000)	.699** (.010)	.489** (.000)	.511** (.000)	1		
x_7	.143* (.013)	.555** (.000)	.731** (.000)	.313** (.000)	.730** (.000)	.950** (.000)	1	
y	.084 (.147)	-.260** (.000)	-.262** (.000)	.436** (.000)	-.186** (.000)	.023 (.692)	-.080 (.169)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-4 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (0.436) รองลงมาคือ ความเร็วลมตามแนวแกน y (-0.262) ความเร็วลมตามแนวแกน x (-0.260) อุณหภูมิอากาศสูงสุด (-0.186) ความชื้นสัมพัทธ์ของอากาศ (0.084) และอุณหภูมิอากาศเฉลี่ย (-0.080) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ อุณหภูมิอากาศต่ำสุด (0.023)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-5

ตารางที่ 4-5 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน

Variable Entered										
Multiple R	.732									
Coefficient of Determination(R ²)	.537									
Adjusted R ²	.530									
Standard error of estimate	1.415									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	683.421	4	170.855	85.383	.000					
Residual	590.308	295	2.001							
Total	1273.729	299								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	27.334	3.355		8.146	.000					
X ₄	.753	.113	.354	6.638	.000	.436	.360	.263	.552	1.813
X ₂	-2.449	.178	-.976	-13.787	.000	-.260	-.626	-.546	.313	3.192
X ₅	-1.631	.186	-.590	-8.787	.000	-.186	-.455	-.348	.349	2.869
X ₆	1.230	.146	.825	8.432	.000	.023	.441	.334	.164	6.089

จากตารางที่ 4-5 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า $R = .732$ ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 53.7% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $y' = 27.334 - 2.449x_2 + .753x_4 - 1.631x_5 + 1.230x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ อุณหภูมิอากาศสูงสุด อุณหภูมิอากาศต่ำสุด และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 4-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูหนาว ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ อุณหภูมิอากาศต่ำสุด (0.646) รองลงมาคือ อุณหภูมิอากาศเฉลี่ย (0.639) ความเร็วลมตามแนวแกน x (0.591) อุณหภูมิอากาศสูงสุด (0.345) ความเร็วลมตามแนวแกน y (-0.159) และการระเหยของน้ำ (0.132) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.034) ดังตารางที่ 4-6

ตารางที่ 4-6 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์
ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.000 (.999)	1						
x_3	-.071 (.217)	.393** (.000)	1					
x_4	.083 (.150)	.286** (.000)	.035 (.549)	1				
x_5	.122* (.035)	.395** (.000)	.058 (.320)	-.011 (.846)	1			
x_6	.155** (.007)	.367** (.000)	-.474** (.000)	.146* (.011)	.378** (.000)	1		
x_7	.167** (.004)	.387** (.000)	-.415** (.000)	.091 (.116)	.596** (.000)	.966** (.000)	1	
y	.034 (.560)	.591** (.000)	-.159** (.006)	.132* (.022)	.345** (.000)	.646** (.000)	.639** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปร
นำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-7

ตารางที่ 4-7 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 300 จำนวน
สำหรับฤดูหนาว

Variable Entered										
Multiple R	.761									
Coefficient of Determination(R ²)	.580									
Adjusted R ²	.575									
Standard error of estimate	.826									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	278.204	3	92.735	135.996	.000					
Residual	201.840	296	.682							
Total	480.044	299								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	2.503	.603		4.154	.000					
x_6	.157	.027	.345	5.878	.000	.646	.323	.222	.413	2.422
x_2	1.489	.153	.547	9.739	.000	.591	.493	.367	.450	2.222
x_3	-.448	.126	-.211	-3.555	.000	-.159	-.202	-.134	.403	2.478

จากตารางที่ 4-7 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ทำให้ค่า R = .761 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 58% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 2.503 + 1.489x_2 - .448x_3 + .157x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุดตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 3-4-4-1

2.1.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA กับที่ใช้การคัดเลือกแบบเดิมของวิธี GA การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 แบบ พิจารณาจากค่า MAE MAPE RMSE และ R^2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-8 และตารางที่ 4-9

ตารางที่ 4-8 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.03430	0.56672	0.58014	1.33930	0.70081	0.73206
ค่า MAPE	0.18970	0.09731	0.09933	0.37502	0.17866	0.18731
ค่า RMSE	1.31110	0.70518	0.72014	1.65960	0.88592	0.93795
ค่า R^2	0.18441	0.76405	0.75394	0.46675	0.70921	0.67405

จากตารางที่ 4-8 กรณีข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.56672 ค่า MAPE เท่ากับ 0.09731 ค่า RMSE เท่ากับ 0.70518 และค่า R^2 เท่ากับ 0.76405 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.58014 ค่า MAPE เท่ากับ 0.09933 ค่า RMSE เท่ากับ 0.72014 และค่า R^2 เท่ากับ 0.75394 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.03430 ค่า MAPE เท่ากับ 0.18970 ค่า RMSE เท่ากับ 1.31110 และค่า R^2 เท่ากับ 0.18441 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจาก

ค่า MAE เท่ากับ 0.70081 ค่า MAPE เท่ากับ 0.17866 ค่า RMSE เท่ากับ 0.88592 และค่า R^2 เท่ากับ 0.70921 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.73206 ค่า MAPE เท่ากับ 0.18731 ค่า RMSE เท่ากับ 0.93795 และค่า R^2 เท่ากับ 0.67405 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.33930 ค่า MAPE เท่ากับ 0.37502 ค่า RMSE เท่ากับ 1.65960 และค่า R^2 เท่ากับ 0.46675 ตามลำดับ

ตารางที่ 4-9 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.33178	0.33071	0.33013	0.83470	0.82661	0.82501
ค่า MAPE	0.05444	0.05420	0.05407	0.19237	0.18992	0.18932
ค่า RMSE	0.43353	0.43176	0.43114	1.10810	1.10550	1.10420
ค่า R^2	0.91082	0.91155	0.91180	0.54509	0.54719	0.54823

จากตารางที่ 4-9 กรณีข้อมูลขนาด 300 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.33013 ค่า MAPE เท่ากับ 0.05407 ค่า RMSE เท่ากับ 0.43114 และค่า R^2 เท่ากับ 0.91180 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.33071 ค่า MAPE เท่ากับ 0.05420 ค่า RMSE เท่ากับ 0.43176 และค่า R^2 เท่ากับ 0.91155 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.33178 ค่า MAPE เท่ากับ 0.05444 ค่า RMSE เท่ากับ 0.43353 และค่า R^2 เท่ากับ 0.91082 ตามลำดับ ในทำนองเดียวกัน สำหรับชุดการทดสอบตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.82501 ค่า MAPE เท่ากับ 0.18932 ค่า RMSE เท่ากับ 1.10420 และค่า R^2 เท่ากับ 0.54823 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.82661 ค่า MAPE เท่ากับ 0.18992 ค่า RMSE เท่ากับ 1.10550 และค่า R^2 เท่ากับ 0.54719 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.83470 ค่า MAPE เท่ากับ 0.19237 ค่า RMSE เท่ากับ 1.10810 และค่า R^2 เท่ากับ 0.54509 ตามลำดับ

สำหรับฤดูร้อนข้อมูลขนาด 300 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ชุดการเรียนรู้ตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุด และชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุด ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-10 และตารางที่ 4-11

ตารางที่ 4-10 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้อข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.47190	0.54351	0.78250	1.26310	0.69410	0.78139
ค่า MAPE	0.14509	0.04839	0.07386	0.14923	0.06618	0.07973
ค่า RMSE	2.05050	0.69987	1.12340	1.98090	0.85318	1.12010
ค่า R^2	0.04063	0.88823	0.71203	0.07249	0.80356	0.66143

จากตารางที่ 4-10 กรณีข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.54351 ค่า MAPE เท่ากับ 0.04839 ค่า RMSE เท่ากับ 0.69987 และค่า R^2 เท่ากับ 0.88823 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.78250 ค่า MAPE เท่ากับ 0.07386 ค่า RMSE เท่ากับ 1.12340 และค่า R^2 เท่ากับ 0.71203 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.47190 ค่า MAPE เท่ากับ 0.14509 ค่า RMSE เท่ากับ 2.05050 และค่า R^2 เท่ากับ 0.04063 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.69410 ค่า MAPE เท่ากับ 0.06618 ค่า RMSE เท่ากับ 0.85318 และค่า R^2 เท่ากับ 0.80356 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.78139 ค่า MAPE เท่ากับ 0.07973 ค่า RMSE เท่ากับ 1.12010 และค่า R^2 เท่ากับ 0.66143 และตัวแบบ Asadi-

GA-ANN มีค่า MAE เท่ากับ 1.26310 ค่า MAPE เท่ากับ 0.14923 ค่า RMSE เท่ากับ 1.98090 และค่า R^2 เท่ากับ 0.07249 ตามลำดับ

ตารางที่ 4-11 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.34965	0.32962	0.34597	0.94811	0.84713	0.86158
ค่า MAPE	0.03204	0.02978	0.03094	0.10085	0.08729	0.09100
ค่า RMSE	0.46946	0.43291	0.45086	1.43300	1.17650	1.25410
ค่า R^2	0.94971	0.95724	0.95362	0.44583	0.62646	0.57560

จากตารางที่ 4-11 กรณีข้อมูลขนาด 300 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.32962 ค่า MAPE เท่ากับ 0.02978 ค่า RMSE เท่ากับ 0.43291 และค่า R^2 เท่ากับ 0.95724 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.34597 ค่า MAPE เท่ากับ 0.03094 ค่า RMSE เท่ากับ 0.45086 และค่า R^2 เท่ากับ 0.95362 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.34965 ค่า MAPE เท่ากับ 0.03204 ค่า RMSE เท่ากับ 0.46946 และค่า R^2 เท่ากับ 0.94971 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.84713 ค่า MAPE เท่ากับ 0.08729 ค่า RMSE เท่ากับ 1.17650 และค่า R^2 เท่ากับ 0.62646 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.86158 ค่า MAPE เท่ากับ 0.09100 ค่า RMSE เท่ากับ 1.25410 และค่า R^2 เท่ากับ 0.57560 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.94811 ค่า MAPE เท่ากับ 0.10085 ค่า RMSE เท่ากับ 1.43300 และค่า R^2 เท่ากับ 0.44583 ตามลำดับ

สำหรับฤดูฝนข้อมูลขนาด 300 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด และชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-12 และตารางที่ 4-13

ตารางที่ 4-12 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	0.74759	0.53371	0.56044	0.77458	0.46668	0.62347
ค่า MAPE	0.25682	0.18463	0.19425	0.18512	0.10665	0.15727
ค่า RMSE	0.93226	0.67750	0.73065	0.99092	0.64061	0.78521
ค่า R^2	0.43706	0.70269	0.65422	0.42134	0.76491	0.62785

จากตารางที่ 4-12 กรณีข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.53371 ค่า MAPE เท่ากับ 0.18463 ค่า RMSE เท่ากับ 0.67750 และค่า R^2 เท่ากับ 0.70269 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.56044 ค่า MAPE เท่ากับ 0.19425 ค่า RMSE เท่ากับ 0.73065 และค่า R^2 เท่ากับ 0.65422 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.74759 ค่า MAPE เท่ากับ 0.25682 ค่า RMSE เท่ากับ 0.93226 และค่า R^2 เท่ากับ 0.43706 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.46668 ค่า MAPE เท่ากับ 0.10665 ค่า RMSE เท่ากับ 0.64061 และค่า R^2 เท่ากับ 0.76491 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.62347 ค่า MAPE เท่ากับ 0.15727 ค่า RMSE เท่ากับ 0.78521 และค่า R^2 เท่ากับ 0.62785 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.77458 ค่า MAPE เท่ากับ 0.18512 ค่า RMSE เท่ากับ 0.99092 และค่า R^2 เท่ากับ 0.42134 ตามลำดับ

ตารางที่ 4-13 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.28833	0.27842	0.28287	0.56888	0.54755	0.55412
ค่า MAPE	0.09695	0.09213	0.09361	0.14491	0.14327	0.14502
ค่า RMSE	0.37524	0.36270	0.36305	0.74395	0.70371	0.70615
ค่า R^2	0.90880	0.91479	0.91463	0.68294	0.71631	0.71434

จากตารางที่ 4-13 กรณีข้อมูลขนาด 300 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.27842 ค่า MAPE เท่ากับ 0.09213 ค่า RMSE เท่ากับ 0.36270 และค่า R^2 เท่ากับ 0.91479 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.28287 ค่า MAPE เท่ากับ 0.09361 ค่า RMSE เท่ากับ 0.36305 และค่า R^2 เท่ากับ 0.91463 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.28833 ค่า MAPE เท่ากับ 0.09695 ค่า RMSE เท่ากับ 0.37524 และค่า R^2 เท่ากับ 0.90880 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.54755 ค่า MAPE เท่ากับ 0.14327 ค่า RMSE เท่ากับ 0.70371 และค่า R^2 เท่ากับ 0.71631 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.55412 ค่า MAPE เท่ากับ 0.14502 ค่า RMSE เท่ากับ 0.70615 และค่า R^2 เท่ากับ 0.71434 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.56888 ค่า MAPE เท่ากับ 0.14491 ค่า RMSE เท่ากับ 0.74395 และค่า R^2 เท่ากับ 0.68294 ตามลำดับ

สำหรับฤดูหนาวข้อมูลขนาด 300 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด และชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุด

2.2 สำหรับสถานการณ์ที่ 2 ภายใต้ข้อมูลขนาด 400 จำนวน แบบรายฤดูกาล แบ่งการแสดงผลเป็น 2 ส่วน ได้แก่

2.2.1 ข้อมูลพื้นฐาน ได้แก่ ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัว ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise

2.2.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

ผลการวิเคราะห์ข้อมูลสำหรับสถานการณ์ที่ 2 ภายใต้ข้อมูลขนาด 400 จำนวน แบบรายฤดูกาล แสดงผลดังนี้

2.2.1 ข้อมูลพื้นฐาน

ตารางที่ 4-14 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูกาลของข้อมูลขนาด 400 จำนวน

ตัวแปร	ค่าต่ำสุด			ค่าสูงสุด			ค่าเฉลี่ย			ส่วนเบี่ยงเบนมาตรฐาน		
	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว
y	1.56	4.62	0.54	10.78	16.99	7.55	5.82	11.33	3.72	1.66	1.93	1.25
x ₁	20.75	22.93	23.55	82.05	82.13	83.70	59.84	59.79	59.92	11.99	12.49	12.43
x ₂	-0.10	0.40	-2.50	1.22	4.72	-0.18	0.00	1.44	-1.37	0.44	0.78	0.49
x ₃	-0.13	0.19	-2.62	2.17	2.05	0.63	0.82	0.87	-0.75	0.36	0.34	0.62
x ₄	5.35	4.20	4.77	26.43	9.86	15.85	12.18	5.41	8.93	3.40	0.97	2.21
x ₅	26.76	25.70	23.98	36.46	29.12	31.44	31.24	27.27	28.02	1.79	0.75	1.31
x ₆	17.71	20.34	13.24	26.37	26.21	25.02	21.55	22.87	18.88	1.94	1.40	2.63
x ₇	22.05	22.86	18.52	28.97	27.03	26.50	25.91	24.76	22.81	1.35	0.96	1.81

ตารางที่ 4-14 แสดงค่าสถิติพื้นฐานจำแนกตามฤดูกาลของข้อมูลขนาด 400 จำนวน ดังนี้ ปริมาณน้ำฝนมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 11.33 มิลลิเมตร และมีส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.93 มิลลิเมตร ความชื้นสัมพัทธ์ของอากาศมีค่าเฉลี่ยสูงสุดในฤดูหนาวคิดเป็นร้อยละ 59.92 และส่วนเบี่ยงเบนมาตรฐานร้อยละ 12.43 ความเร็วลมตามแนวแกน x มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 1.44 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.78 เมตรต่อวินาที ความเร็วลมตามแนวแกน y มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 0.87 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.34 เมตรต่อวินาที การระเหยของน้ำมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 12.18 มิลลิเมตร และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 3.40 มิลลิเมตร อุณหภูมิอากาศสูงสุดมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 31.24 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.79 °C อุณหภูมิอากาศต่ำสุดมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 22.87 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.40 °C และ

อุณหภูมิอากาศเฉลี่ยมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 25.91 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.35 °C

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-15

ตารางที่ 4-15 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้อข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.060 (.234)	1						
x_3	.030 (.545)	.434** (.000)	1					
x_4	-.002 (.962)	.496** (.000)	.257** (.000)	1				
x_5	-.041 (.409)	.123* (.014)	-.052 (.300)	.437** (.000)	1			
x_6	.219** (.000)	.524** (.000)	.139** (.005)	.133** (.008)	.043 (.391)	1		
x_7	.118* (.019)	.512** (.000)	.133** (.008)	.395** (.000)	.652** (.000)	.759** (.000)	1	
y	.102* (.041)	-.353** (.000)	-.484** (.000)	-.593** (.000)	-.454** (.000)	-.075 (.132)	-.421** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-15 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้อข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (-0.593) รองลงมาคือ ความเร็วลมตามแนวแกน y (-0.484) อุณหภูมิอากาศสูงสุด (-0.454) อุณหภูมิอากาศเฉลี่ย (-0.421) ความเร็ว

ลมตามแนวแกน x (-0.353) และความชื้นสัมพัทธ์ของอากาศ (0.102) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ อุณหภูมิอากาศต่ำสุด (-0.075)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-16

ตารางที่ 4-16 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายได้ข้อมูลขนาด 400 จำนวนสำหรับฤดูร้อน

Variable Entered	
Multiple R	.749
Coefficient of Determination(R ²)	.562
Adjusted R ²	.557
Standard error of estimate	1.108

Analysis of Variance					
	Sum of Squares	df	Mean Square	F	Sig.
Regression	620.994	4	155.249	126.514	.000
Residual	484.713	395	1.227		
Total	1105.707	399			

Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	17.881	1.081		16.535	.000					
x ₄	-.170	.019	-.347	-8.916	.000	-.593	-.409	-.297	.731	1.368
x ₃	-1.918	.163	-.414	-11.796	.000	-.484	-.510	-.393	.900	1.111
x ₅	-.296	.035	-.319	-8.458	.000	-.454	-.392	-.282	.779	1.284
x ₁	.014	.005	.101	3.022	.003	.102	.150	.101	.997	1.003

จากตารางที่ 4-16 พบว่าตัวแปรพยากรณ์ได้แก่ ความชื้นสัมพัทธ์ของอากาศ ความเร็วลมตามแนวแกน y การระเหยของน้ำ และอุณหภูมิอากาศสูงสุด ทำให้ค่า R = .749 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 56.2% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $y' = 17.881 + .014 x_1 - 1.918 x_3 - .170 x_4 - .296 x_5$ ซึ่งตัวแปร

พยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน y รองลงมาคือ อุณหภูมิอากาศสูงสุด การระเหยของน้ำ และความชื้นสัมพัทธ์ของอากาศ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน ได้ตัวแปรนำเข้าคือ ความชื้นสัมพัทธ์ของอากาศ ความเร็วลมตามแนวแกน y การระเหยของน้ำ และอุณหภูมิอากาศสูงสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 4-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-17

ตารางที่ 4-17 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.019 (.706)	1						
x_3	.098 (.051)	.544** (.000)	1					
x_4	.060 (.231)	.398** (.000)	.048 (.342)	1				
x_5	.113* (.024)	-.008 (.874)	.405** (.000)	-.120* (.017)	1			
x_6	.146** (.003)	.674** (.000)	.622** (.000)	.461** (.000)	.527** (.000)	1		
x_7	.144** (.004)	.548** (.000)	.652** (.000)	.301** (.000)	.744** (.000)	.946** (.000)	1	
y	.078 (.120)	-.349** (.000)	-.336** (.000)	.397** (.000)	-.132** (.008)	.005 (.915)	-.083 (.098)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-17 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (0.397) รองลงมาคือ ความเร็วลมตามแนวแกน x (-0.349) ความเร็วลมตามแนวแกน y (-0.336) อุณหภูมิอากาศสูงสุด (-0.132) อุณหภูมิอากาศเฉลี่ย (-0.083) และความชื้นสัมพัทธ์ของอากาศ (0.078) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ อุณหภูมิอากาศต่ำสุด (0.005)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-18

ตารางที่ 4-18 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน

Variable Entered										
Multiple R	.779									
Coefficient of Determination(R ²)	.606									
Adjusted R ²	.601									
Standard error of estimate	1.220									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	902.015	5	180.403	121.294	.000					
Residual	586.005	394	1.487							
Total	1488.020	399								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients		Statistical Significance			Collinearity Statistics				
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	19.394	2.624		7.390	.000					
X ₄	.657	.086	.330	7.626	.000	.397	.359	.241	.534	1.871
X ₂	-2.472	.139	-1.004	-17.820	.000	-.349	-.668	-.563	.315	3.174
X ₆	1.241	.105	.897	11.795	.000	.005	.511	.373	.173	5.782
X ₅	-1.308	.136	-.510	-9.592	.000	-.132	-.435	-.303	.354	2.829
X ₃	-.887	.256	-.157	-3.466	.001	-.336	-.172	-.110	.448	2.047

จากตารางที่ 4-18 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า $R = .779$ ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 60.6% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 19.394 - 2.472 x_2 - .887 x_3 + .657 x_4 - 1.308 x_5 + 1.241 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ อุณหภูมิอากาศสูงสุด อุณหภูมิอากาศต่ำสุด ความเร็วลมตามแนวแกน y และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 5-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-19

ตารางที่ 4-19 ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์
ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	-0.014 (.781)	1						
x_3	-0.095 (.058)	.474** (.000)	1					
x_4	.066 (.191)	.177** (.000)	-.086 (.084)	1				
x_5	.054 (.279)	.219** (.000)	-.133** (.008)	.097 (.051)	1			
x_6	.156** (.002)	.319** (.000)	-.460** (.000)	.172** (.001)	.435** (.000)	1		
x_7	.142** (.004)	.239** (.000)	-.449** (.000)	.144** (.004)	.651** (.000)	.963** (.000)	1	
y	.125* (.012)	.555** (.000)	-.037 (.461)	-.050 (.316)	.283** (.000)	.610** (.000)	.582** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-19 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ อุณหภูมิอากาศต่ำสุด (0.610) รองลงมาคือ อุณหภูมิอากาศเฉลี่ย (0.582) ความเร็วลมตามแนวแกน x (0.555) อุณหภูมิอากาศสูงสุด (0.283) ความชื้นสัมพัทธ์ของอากาศ (0.125) และการระเหยของน้ำ (-0.050) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความเร็วลมตามแนวแกน y (-0.037)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-20

ตารางที่ 4-20 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน
สำหรับฤดูหนาว

Variable Entered										
Multiple R	.752									
Coefficient of Determination(R ²)	.565									
Adjusted R ²	.561									
Standard error of estimate	.830									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	353.766	4	88.442	128.274	.000					
Residual	272.342	395	.689							
Total	626.108	399								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	1.462	.424		3.447	.001					
x_6	.237	.017	.498	13.923	.000	.610	.574	.462	.861	1.161
x_2	1.112	.090	.436	12.313	.000	.555	.527	.409	.878	1.139
x_4	-.123	.019	-.218	-6.396	.000	-.050	-.306	-.212	.951	1.051
x_1	.007	.003	.068	2.009	.045	.125	.101	.067	.969	1.032

จากตารางที่ 4-20 พบว่าตัวแปรพยากรณ์ได้แก่ ความชื้นสัมพัทธ์ของอากาศ ความเร็วลมตามแนวแกน x การระเหยของน้ำ และอุณหภูมิอากาศต่ำสุด ทำให้ค่า R = .752 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 56.5% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 1.462 + 0.007x_1 + 1.112x_2 - 0.123x_4 + 0.237x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ อุณหภูมิอากาศต่ำสุด การระเหยของน้ำ และความชื้นสัมพัทธ์ของอากาศ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน ได้ตัวแปรนำเข้าคือ ความชื้นสัมพัทธ์ของอากาศ ความเร็วลมตามแนวแกน x การระเหยของน้ำ และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้าง

ตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 4-4-4-1

2.2.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA กับที่ใช้การคัดเลือกแบบเดิมของวิธี GA การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 แบบ พิจารณาจากค่า MAE MAPE RMSE และ R^2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-21 และตารางที่ 4-22

ตารางที่ 4-21 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.29590	0.67502	0.71141	1.47360	0.78683	0.91198
ค่า MAPE	0.24994	0.11878	0.12719	0.46117	0.19897	0.25233
ค่า RMSE	1.59030	0.86439	0.90254	1.92820	1.04910	1.22000
ค่า R^2	0.00438	0.70587	0.67933	0.37212	0.59311	0.44978

จากตารางที่ 4-21 กรณีข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.67502 ค่า MAPE เท่ากับ 0.11878 ค่า RMSE เท่ากับ 0.86439 และค่า R^2 เท่ากับ 0.70587 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.71141 ค่า MAPE เท่ากับ 0.12719 ค่า RMSE เท่ากับ 0.90254 และค่า R^2 เท่ากับ 0.67933 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.29590 ค่า MAPE

เท่ากับ 0.24994 ค่า RMSE เท่ากับ 1.59030 และค่า R^2 เท่ากับ 0.00438 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.78683 ค่า MAPE เท่ากับ 0.19897 ค่า RMSE เท่ากับ 1.04910 และค่า R^2 เท่ากับ 0.59311 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.91198 ค่า MAPE เท่ากับ 0.25233 ค่า RMSE เท่ากับ 1.22000 และค่า R^2 เท่ากับ 0.44978 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.47360 ค่า MAPE เท่ากับ 0.46117 ค่า RMSE เท่ากับ 1.92820 และค่า R^2 เท่ากับ 0.37212 ตามลำดับ

ตารางที่ 4-22 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.50750	0.42197	0.45421	0.80012	0.65886	0.65983
ค่า MAPE	0.08785	0.07418	0.07881	0.21673	0.16621	0.16692
ค่า RMSE	0.64797	0.53691	0.59715	1.11250	0.93694	0.93898
ค่า R^2	0.83471	0.88652	0.85963	0.54249	0.67549	0.67407

จากตารางที่ 4-22 กรณีข้อมูลขนาด 400 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.42197 ค่า MAPE เท่ากับ 0.07418 ค่า RMSE เท่ากับ 0.53691 และค่า R^2 เท่ากับ 0.88652 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.45421 ค่า MAPE เท่ากับ 0.07881 ค่า RMSE เท่ากับ 0.59715 และค่า R^2 เท่ากับ 0.85963 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.50750 ค่า MAPE เท่ากับ 0.08785 ค่า RMSE เท่ากับ 0.64797 และค่า R^2 เท่ากับ 0.83471 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.65886 ค่า MAPE เท่ากับ 0.16621 ค่า RMSE เท่ากับ 0.93694 และค่า R^2 เท่ากับ 0.67549 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.65983 ค่า MAPE เท่ากับ 0.16692 ค่า RMSE เท่ากับ 0.93898 และค่า R^2 เท่ากับ 0.67407 และตัวแบบ Wang-

GA-ANN มีค่า MAE เท่ากับ 0.80012 ค่า MAPE เท่ากับ 0.21673 ค่า RMSE เท่ากับ 1.11250 และค่า R^2 เท่ากับ 0.54249 ตามลำดับ

สำหรับฤดูร้อนข้อมูลขนาด 400 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-23 และตารางที่ 4-24

ตารางที่ 4-23 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.28800	0.55556	0.59301	1.38730	0.78047	0.81321
ค่า MAPE	0.12759	0.05047	0.05434	0.14983	0.07119	0.07551
ค่า RMSE	1.85980	0.71152	0.75414	2.01380	0.97811	1.01250
ค่า R^2	0.05108	0.86111	0.84397	0.04819	0.75551	0.73803

จากตารางที่ 4-23 กรณีข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.55556 ค่า MAPE เท่ากับ 0.05047 ค่า RMSE เท่ากับ 0.71152 และค่า R^2 เท่ากับ 0.86111 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.59301 ค่า MAPE เท่ากับ 0.05434 ค่า RMSE เท่ากับ 0.75414 และค่า R^2 เท่ากับ 0.84397 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.28800 ค่า MAPE เท่ากับ 0.12759 ค่า RMSE เท่ากับ 1.85980 และค่า R^2 เท่ากับ 0.05108 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจาก

ค่า MAE เท่ากับ 0.78047 ค่า MAPE เท่ากับ 0.07119 ค่า RMSE เท่ากับ 0.97811 และค่า R^2 เท่ากับ 0.75551 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.81321 ค่า MAPE เท่ากับ 0.07551 ค่า RMSE เท่ากับ 1.01250 และค่า R^2 เท่ากับ 0.73803 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.38730 ค่า MAPE เท่ากับ 0.14983 ค่า RMSE เท่ากับ 2.01380 และค่า R^2 เท่ากับ 0.04819 ตามลำดับ

ตารางที่ 4-24 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.46898	0.45352	0.46311	0.80544	0.73455	0.75717
ค่า MAPE	0.04291	0.04180	0.04231	0.07285	0.06689	0.07019
ค่า RMSE	0.61028	0.59294	0.60120	1.09850	0.93195	1.04650
ค่า R^2	0.89782	0.90355	0.90084	0.69161	0.77804	0.72014

จากตารางที่ 4-24 กรณีข้อมูลขนาด 400 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.45352 ค่า MAPE เท่ากับ 0.04180 ค่า RMSE เท่ากับ 0.59294 และค่า R^2 เท่ากับ 0.90355 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.46311 ค่า MAPE เท่ากับ 0.04231 ค่า RMSE เท่ากับ 0.60120 และค่า R^2 เท่ากับ 0.90084 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.46898 ค่า MAPE เท่ากับ 0.04291 ค่า RMSE เท่ากับ 0.61028 และค่า R^2 เท่ากับ 0.89782 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.73455 ค่า MAPE เท่ากับ 0.06689 ค่า RMSE เท่ากับ 0.93195 และค่า R^2 เท่ากับ 0.77804 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.75717 ค่า MAPE เท่ากับ 0.07019 ค่า RMSE เท่ากับ 1.04650 และค่า R^2 เท่ากับ 0.72014 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.80544 ค่า MAPE เท่ากับ 0.07285 ค่า RMSE เท่ากับ 1.09850 และค่า R^2 เท่ากับ 0.69161 ตามลำดับ

สำหรับฤดูฝนข้อมูลขนาด 400 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-25 และตารางที่ 4-26

ตารางที่ 4-25 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.03390	0.49923	0.63615	0.98363	0.65227	0.70515
ค่า MAPE	0.34212	0.15003	0.19368	0.42655	0.23139	0.25891
ค่า RMSE	1.27180	0.65079	0.80702	1.20550	0.82844	0.86780
ค่า R^2	0.00223	0.73873	0.59823	0.25657	0.40709	0.34941

จากตารางที่ 4-25 กรณีข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.49923 ค่า MAPE เท่ากับ 0.15003 ค่า RMSE เท่ากับ 0.65079 และค่า R^2 เท่ากับ 0.73873 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.63615 ค่า MAPE เท่ากับ 0.19368 ค่า RMSE เท่ากับ 0.80702 และค่า R^2 เท่ากับ 0.59823 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.03390 ค่า MAPE เท่ากับ 0.34212 ค่า RMSE เท่ากับ 1.27180 และค่า R^2 เท่ากับ 0.00223 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.65227 ค่า MAPE เท่ากับ 0.23139 ค่า RMSE เท่ากับ 0.82844 และค่า R^2 เท่ากับ 0.40709 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.70515 ค่า MAPE เท่ากับ 0.25891 ค่า RMSE เท่ากับ 0.86780 และค่า R^2 เท่ากับ 0.34941 และตัวแบบ Asadi-

GA-ANN มีค่า MAE เท่ากับ 0.98363 ค่า MAPE เท่ากับ 0.42655 ค่า RMSE เท่ากับ 1.20550 และค่า R^2 เท่ากับ 0.25657 ตามลำดับ

ตารางที่ 4-26 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.38436	0.37714	0.38371	0.49911	0.49586	0.49679
ค่า MAPE	0.11601	0.11286	0.11592	0.18809	0.18712	0.18732
ค่า RMSE	0.50969	0.50419	0.50888	0.64135	0.63571	0.63748
ค่า R^2	0.83975	0.84318	0.84025	0.64466	0.65087	0.64893

จากตารางที่ 4-26 กรณีข้อมูลขนาด 400 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.37714 ค่า MAPE เท่ากับ 0.11286 ค่า RMSE เท่ากับ 0.50419 และค่า R^2 เท่ากับ 0.84318 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.38371 ค่า MAPE เท่ากับ 0.11592 ค่า RMSE เท่ากับ 0.50888 และค่า R^2 เท่ากับ 0.84025 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.38436 ค่า MAPE เท่ากับ 0.11601 ค่า RMSE เท่ากับ 0.50969 และค่า R^2 เท่ากับ 0.83975 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.49586 ค่า MAPE เท่ากับ 0.18712 ค่า RMSE เท่ากับ 0.63571 และค่า R^2 เท่ากับ 0.65087 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.49679 ค่า MAPE เท่ากับ 0.18732 ค่า RMSE เท่ากับ 0.63748 และค่า R^2 เท่ากับ 0.64893 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.49911 ค่า MAPE เท่ากับ 0.18809 ค่า RMSE เท่ากับ 0.64135 และค่า R^2 เท่ากับ 0.64466 ตามลำดับ

สำหรับฤดูหนาวข้อมูลขนาด 400 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด

2.3 สำหรับสถานการณ์ที่ 3 ภายใต้ข้อมูลขนาด 500 จำนวน แบบรายฤดูกาล แบ่งการแสดงผลเป็น 2 ส่วน ได้แก่

2.3.1 ข้อมูลพื้นฐาน ได้แก่ ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัว ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise

2.3.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

ผลการวิเคราะห์ข้อมูลสำหรับสถานการณ์ที่ 3 ภายใต้ข้อมูลขนาด 500 จำนวน แบบรายฤดูกาล แสดงผลดังนี้

2.3.1 ข้อมูลพื้นฐาน

ตารางที่ 4-27 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูกาลของข้อมูลขนาด 500 จำนวน

ตัวแปร	ค่าต่ำสุด			ค่าสูงสุด			ค่าเฉลี่ย			ส่วนเบี่ยงเบนมาตรฐาน		
	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว
y	2.01	4.62	1.02	10.78	16.99	7.55	5.91	11.27	3.66	1.50	1.84	1.16
x ₁	20.75	22.93	23.55	83.33	82.33	85.43	61.56	61.21	60.94	11.64	12.48	13.42
x ₂	-1.34	0.40	-2.40	1.04	4.72	-0.18	-0.04	1.42	-1.38	0.44	0.72	0.46
x ₃	-0.32	0.19	-2.62	1.55	2.05	0.46	0.76	0.92	-0.79	0.33	0.34	0.60
x ₄	5.35	4.20	4.80	24.67	9.86	15.85	12.30	5.41	9.06	3.37	0.95	2.10
x ₅	26.76	25.36	23.59	36.46	29.12	31.60	31.36	27.12	28.00	1.69	0.79	1.33
x ₆	17.65	19.96	13.24	25.34	26.21	25.20	21.29	22.74	18.82	1.72	1.38	2.64
x ₇	22.05	22.39	18.28	28.88	27.03	26.84	25.82	24.62	22.77	1.36	0.97	1.84

ตารางที่ 4-27 แสดงค่าสถิติพื้นฐานจำแนกตามฤดูกาลของข้อมูลขนาด 500 จำนวน ดังนี้ ปริมาณน้ำฝนมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 11.27 มิลลิเมตร และมีส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.84 มิลลิเมตร ความชื้นสัมพัทธ์ของอากาศมีค่าเฉลี่ยสูงสุดในฤดูร้อนคิดเป็นร้อยละ 61.56 และส่วนเบี่ยงเบนมาตรฐานร้อยละ 11.64 ความเร็วลมตามแนวแกน x มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 1.42 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.72 เมตรต่อวินาที ความเร็วลมตามแนวแกน y มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 0.92 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.34 เมตรต่อวินาที การระเหยของน้ำมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 12.30 มิลลิเมตร และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 3.37 มิลลิเมตร อุณหภูมิอากาศสูงสุดมีค่าเฉลี่ยสูงสุดในฤดูร้อน

เท่ากับ 31.36 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.69 °C อุณหภูมิอากาศต่ำสุดมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 22.74 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.38 °C และอุณหภูมิอากาศเฉลี่ยมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 25.82 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.36 °C

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-28

ตารางที่ 4-28 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้อัตลักษณ์ขนาด 500 จำนวน สำหรับฤดูร้อน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.053 (.233)	1						
x_3	-.030 (.510)	.378** (.000)	1					
x_4	.024 (.593)	.521** (.000)	.305** (.000)	1				
x_5	.009 (.841)	.266** (.000)	.139** (.002)	.414** (.000)	1			
x_6	.157** (.000)	.462** (.000)	-.085 (.059)	.114* (.011)	.303** (.000)	1		
x_7	.097* (.030)	.474** (.000)	.055 (.217)	.332** (.000)	.800** (.000)	.759** (.000)	1	
y	.072 (.109)	-.228** (.000)	-.437** (.000)	-.591** (.000)	-.637** (.000)	.130** (.004)	-.327** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-28 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้อัตลักษณ์ขนาด 500 จำนวน สำหรับฤดูร้อน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ อุณหภูมิอากาศสูงสุด (-0.637) รองลงมาคือ การระเหยของน้ำ (-0.591) ความเร็วลมตามแนวแกน y (-0.437) อุณหภูมิอากาศเฉลี่ย (-0.327) ความเร็วลม

ตามแนวแกน x (-0.228) และอุณหภูมิอากาศต่ำสุด (0.130) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.072)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-29

ตารางที่ 4-29 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายได้ข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน

Variable Entered										
Multiple R	.834									
Coefficient of Determination(R ²)	.695									
Adjusted R ²	.693									
Standard error of estimate	.830									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	778.055	4	194.514	282.450	.000					
Residual	340.890	495	.689							
Total	1118.945	499								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	18.408	.761		24.179	.000					
x_5	-.505	.025	-.569	-19.982	.000	-.637	-.668	-.496	.760	1.315
x_4	-.142	.013	-.320	-11.303	.000	-.591	-.453	-.280	.766	1.306
x_6	.277	.023	.319	12.140	.000	.130	.479	.301	.891	1.122
x_3	-1.077	.121	-.234	-8.894	.000	-.437	-.371	-.221	.890	1.123

จากตารางที่ 4-29 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า $R = .834$ ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 69.5% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $y' = 18.408 - 1.077 x_3 - .142 x_4 - .505 x_5 + .277 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า

b มากที่สุดคือ ความเร็วลมตามแนวแกน y รองลงมาคือ อุณหภูมิอากาศสูงสุด อุณหภูมิอากาศต่ำสุด และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 4-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-30

ตารางที่ 4-30 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.006 (.900)	1						
x_3	.122** (.006)	.489** (.000)	1					
x_4	.059 (.189)	.408** (.000)	.072 (.109)	1				
x_5	.036 (.418)	.008 (.857)	.297** (.000)	-.108* (.016)	1			
x_6	.083 (.064)	.654** (.000)	.528** (.000)	.488** (.000)	.569** (.000)	1		
x_7	.066 (.138)	.509** (.000)	.523** (.000)	.293** (.000)	.783** (.000)	.952** (.000)	1	
y	.046 (.309)	-.318** (.000)	-.295** (.000)	.345** (.000)	-.066 (.139)	.057 (.203)	-.011 (.800)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-30 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (0.345) รองลงมาคือ ความเร็วลมตามแนวแกน x (-0.318) ความเร็วลมตามแนวแกน y (-0.295) อุณหภูมิอากาศสูงสุด (-0.066) อุณหภูมิอากาศต่ำสุด (0.057) และความชื้นสัมพัทธ์ของอากาศ (0.046) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ อุณหภูมิอากาศเฉลี่ย (-0.011)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-31

ตารางที่ 4-31 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน

Variable Entered										
Multiple R	.724									
Coefficient of Determination(R ²)	.525									
Adjusted R ²	.520									
Standard error of estimate	1.277									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	889.747	5	177.949	109.135	.000					
Residual	805.492	494	1.631							
Total	1695.240	499								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	17.707	2.313		7.655	.000					
X ₄	.381	.087	.197	4.372	.000	.345	.193	.136	.472	2.117
X ₂	-2.428	.138	-.945	-17.593	.000	-.318	-.621	-.546	.334	2.997
X ₆	1.343	.109	1.002	12.376	.000	.057	.487	.384	.147	6.817
X ₅	-1.274	.133	-.544	-9.588	.000	-.066	-.396	-.297	.298	3.352
X ₃	-1.153	.210	-.215	-5.481	.000	-.295	-.239	-.170	.627	1.596

จากตารางที่ 4-31 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า $R = .724$ ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 52.5% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 17.707 - 2.428 x_2 - 1.153 x_3 + .381 x_4 - 1.274 x_5 + 1.343 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ อุณหภูมิอากาศต่ำสุด อุณหภูมิอากาศสูงสุด ความเร็วลมตามแนวแกน y และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 5-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-32

ตารางที่ 4-32 ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์
ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.030 (.504)	1						
x_3	-.037 (.415)	.442** (.000)	1					
x_4	.034 (.445)	.279** (.000)	-.022 (.624)	1				
x_5	.064 (.154)	.308** (.000)	-.087 (.051)	.013 (.780)	1			
x_6	.118** (.008)	.325** (.000)	-.479** (.000)	.224** (.000)	.496** (.000)	1		
x_7	.120** (.007)	.325** (.000)	-.442** (.000)	.163** (.000)	.692** (.000)	.967** (.000)	1	
y	.103* (.022)	.538** (.000)	-.191** (.000)	.184** (.000)	.369** (.000)	.681** (.000)	.658** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-32 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ อุณหภูมิอากาศต่ำสุด (0.681) รองลงมาคือ อุณหภูมิอากาศเฉลี่ย (0.658) ความเร็วลมตามแนวแกน x (0.538) อุณหภูมิอากาศสูงสุด (0.369) ความเร็วลมตามแนวแกน y (-0.191) และการระเหยของน้ำ (0.184) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.103)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-33

ตารางที่ 4-33 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน
สำหรับฤดูหนาว

Variable Entered										
Multiple R	.769									
Coefficient of Determination(R ²)	.592									
Adjusted R ²	.589									
Standard error of estimate	.742									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	395.837	3	131.946	239.419	.000					
Residual	273.349	496	.551							
Total	669.187	499								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	1.558	.432		3.608	.000					
x_6	.185	.020	.422	9.439	.000	.681	.390	.271	.412	2.426
x_2	1.228	.109	.492	11.249	.000	.538	.451	.323	.430	2.324
x_3	-.398	.091	-.207	-4.383	.000	-.191	-.193	-.126	.371	2.696

จากตารางที่ 4-33 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ทำให้ค่า R = .769 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 59.2% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 1.558 + 1.228 x_2 - .398 x_3 + .185 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 3-4-4-1

2.3.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA กับที่ใช้การคัดเลือกแบบเดิมของวิธี GA การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 แบบ พิจารณาจากค่า MAE MAPE RMSE และ R^2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-34 และตารางที่ 4-35

ตารางที่ 4-34 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.04910	0.53922	0.60840	1.03950	0.61433	0.69750
ค่า MAPE	0.19714	0.09568	0.11006	0.23059	0.12587	0.13950
ค่า RMSE	1.32660	0.67140	0.80522	1.29380	0.76270	0.87447
ค่า R^2	0.22649	0.80188	0.71503	0.35231	0.68502	0.58595

จากตารางที่ 4-34 กรณีข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.53922 ค่า MAPE เท่ากับ 0.09568 ค่า RMSE เท่ากับ 0.67140 และค่า R^2 เท่ากับ 0.80188 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.60840 ค่า MAPE เท่ากับ 0.11006 ค่า RMSE เท่ากับ 0.80522 และค่า R^2 เท่ากับ 0.71503 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.04910 ค่า MAPE เท่ากับ 0.19714 ค่า RMSE เท่ากับ 1.32660 และค่า R^2 เท่ากับ 0.22649 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจาก

ค่า MAE เท่ากับ 0.61433 ค่า MAPE เท่ากับ 0.12587 ค่า RMSE เท่ากับ 0.76270 และค่า R^2 เท่ากับ 0.68502 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.69750 ค่า MAPE เท่ากับ 0.13950 ค่า RMSE เท่ากับ 0.87447 และค่า R^2 เท่ากับ 0.58595 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.03950 ค่า MAPE เท่ากับ 0.23059 ค่า RMSE เท่ากับ 1.29380 และค่า R^2 เท่ากับ 0.35231 ตามลำดับ

ตารางที่ 4-35 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.52684	0.45185	0.45124	0.69969	0.66599	0.64313
ค่า MAPE	0.10641	0.07852	0.07862	0.14090	0.13382	0.12816
ค่า RMSE	0.68372	0.57439	0.57223	0.87609	0.82632	0.78660
ค่า R^2	0.81271	0.85500	0.85608	0.58440	0.63028	0.66497

จากตารางที่ 4-35 กรณีข้อมูลขนาด 500 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.45124 ค่า MAPE เท่ากับ 0.07862 ค่า RMSE เท่ากับ 0.57223 และค่า R^2 เท่ากับ 0.85608 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.45124 ค่า MAPE เท่ากับ 0.07862 ค่า RMSE เท่ากับ 0.57223 และค่า R^2 เท่ากับ 0.85608 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.52684 ค่า MAPE เท่ากับ 0.10641 ค่า RMSE เท่ากับ 0.68372 และค่า R^2 เท่ากับ 0.81271 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.64313 ค่า MAPE เท่ากับ 0.12816 ค่า RMSE เท่ากับ 0.78660 และค่า R^2 เท่ากับ 0.66497 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.66599 ค่า MAPE เท่ากับ 0.13382 ค่า RMSE เท่ากับ 0.82632 และค่า R^2 เท่ากับ 0.63028 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.69969 ค่า MAPE เท่ากับ 0.14090 ค่า RMSE เท่ากับ 0.87609 และค่า R^2 เท่ากับ 0.58440 ตามลำดับ

สำหรับฤดูร้อนข้อมูลขนาด 500 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ชุดการเรียนรู้ตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุด และชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-36 และตารางที่ 4-37

ตารางที่ 4-36 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้อข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.24040	0.66228	0.68251	1.45820	0.80720	0.80187
ค่า MAPE	0.11753	0.05958	0.06152	0.16473	0.08165	0.08445
ค่า RMSE	1.71790	0.85124	0.87488	2.14500	1.06420	1.11070
ค่า R^2	0.02487	0.76056	0.74708	0.01782	0.75401	0.73203

จากตารางที่ 4-36 กรณีข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.66228 ค่า MAPE เท่ากับ 0.05958 ค่า RMSE เท่ากับ 0.85124 และค่า R^2 เท่ากับ 0.76056 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.68251 ค่า MAPE เท่ากับ 0.06152 ค่า RMSE เท่ากับ 0.87488 และค่า R^2 เท่ากับ 0.74708 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.24040 ค่า MAPE เท่ากับ 0.11753 ค่า RMSE เท่ากับ 1.71790 และค่า R^2 เท่ากับ 0.02487 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.80720 ค่า MAPE เท่ากับ 0.08165 ค่า RMSE เท่ากับ 1.06420 และค่า R^2 เท่ากับ 0.75401 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.80187 ค่า MAPE เท่ากับ 0.08445 ค่า RMSE เท่ากับ 1.11070 และค่า R^2 เท่ากับ 0.73203 และตัวแบบ Asadi-

GA-ANN มีค่า MAE เท่ากับ 1.45820 ค่า MAPE เท่ากับ 0.16473 ค่า RMSE เท่ากับ 2.14500 และค่า R^2 เท่ากับ 0.01782 ตามลำดับ

ตารางที่ 4-37 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน

ประสิทธิภาพ การพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA- ANN	Wang- GA(New)-ANN	Wang-GA- BPNN	Wang-GA- ANN	Wang- GA(New)-ANN	Wang-GA- BPNN
ค่า MAE	0.58034	0.58026	0.54989	0.81041	0.80942	0.79115
ค่า MAPE	0.05203	0.05202	0.04946	0.07956	0.07941	0.07778
ค่า RMSE	0.74784	0.74767	0.71390	1.00370	1.00270	0.97859
ค่า R^2	0.81520	0.81528	0.83159	0.78119	0.78164	0.79200

จากตารางที่ 4-37 กรณีข้อมูลขนาด 500 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.54989 ค่า MAPE เท่ากับ 0.04946 ค่า RMSE เท่ากับ 0.71390 และค่า R^2 เท่ากับ 0.83159 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.58026 ค่า MAPE เท่ากับ 0.05202 ค่า RMSE เท่ากับ 0.74767 และค่า R^2 เท่ากับ 0.81528 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.58034 ค่า MAPE เท่ากับ 0.05203 ค่า RMSE เท่ากับ 0.74784 และค่า R^2 เท่ากับ 0.81520 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.79115 ค่า MAPE เท่ากับ 0.07778 ค่า RMSE เท่ากับ 0.97859 และค่า R^2 เท่ากับ 0.79200 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.80942 ค่า MAPE เท่ากับ 0.07941 ค่า RMSE เท่ากับ 1.00270 และค่า R^2 เท่ากับ 0.78164 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.81041 ค่า MAPE เท่ากับ 0.07956 ค่า RMSE เท่ากับ 1.00370 และค่า R^2 เท่ากับ 0.78119 ตามลำดับ

สำหรับฤดูฝนข้อมูลขนาด 500 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-38 และตารางที่ 4-39

ตารางที่ 4-38 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	0.69106	0.46670	0.55306	0.66297	0.61003	0.63800
ค่า MAPE	0.21137	0.14097	0.16557	0.18452	0.17136	0.17770
ค่า RMSE	0.84654	0.57934	0.69071	0.87100	0.79116	0.81483
ค่า R^2	0.47771	0.75538	0.65230	0.37732	0.48624	0.45505

จากตารางที่ 4-38 กรณีข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.46670 ค่า MAPE เท่ากับ 0.14097 ค่า RMSE เท่ากับ 0.57934 และค่า R^2 เท่ากับ 0.75538 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.55306 ค่า MAPE เท่ากับ 0.16557 ค่า RMSE เท่ากับ 0.69071 และค่า R^2 เท่ากับ 0.65230 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.69106 ค่า MAPE เท่ากับ 0.21137 ค่า RMSE เท่ากับ 0.84654 และค่า R^2 เท่ากับ 0.47771 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.61003 ค่า MAPE เท่ากับ 0.17136 ค่า RMSE เท่ากับ 0.79116 และค่า R^2 เท่ากับ 0.48624 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.63800 ค่า MAPE เท่ากับ 0.17770 ค่า RMSE เท่ากับ 0.81483 และค่า R^2 เท่ากับ 0.45505 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.66297 ค่า MAPE เท่ากับ 0.18452 ค่า RMSE เท่ากับ 0.87100 และค่า R^2 เท่ากับ 0.37732 ตามลำดับ

ตารางที่ 4-39 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.35314	0.31028	0.31117	0.63190	0.61071	0.61465
ค่า MAPE	0.11102	0.09587	0.09618	0.18289	0.17608	0.17836
ค่า RMSE	0.44239	0.39108	0.39243	0.78589	0.77700	0.78269
ค่า R^2	0.85737	0.88853	0.88776	0.49306	0.50447	0.49718

จากตารางที่ 4-39 กรณีข้อมูลขนาด 500 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.31028 ค่า MAPE เท่ากับ 0.09587 ค่า RMSE เท่ากับ 0.39108 และค่า R^2 เท่ากับ 0.88853 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.31117 ค่า MAPE เท่ากับ 0.09618 ค่า RMSE เท่ากับ 0.39243 และค่า R^2 เท่ากับ 0.88776 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.35314 ค่า MAPE เท่ากับ 0.11102 ค่า RMSE เท่ากับ 0.44239 และค่า R^2 เท่ากับ 0.85737 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.61071 ค่า MAPE เท่ากับ 0.17608 ค่า RMSE เท่ากับ 0.77700 และค่า R^2 เท่ากับ 0.50447 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.61465 ค่า MAPE เท่ากับ 0.17836 ค่า RMSE เท่ากับ 0.78269 และค่า R^2 เท่ากับ 0.49718 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.63190 ค่า MAPE เท่ากับ 0.18289 ค่า RMSE เท่ากับ 0.78589 และค่า R^2 เท่ากับ 0.49306 ตามลำดับ

สำหรับฤดูหนาวข้อมูลขนาด 500 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด

2.4 สำหรับสถานการณ์ที่ 4 ภายใต้ข้อมูลขนาด 1000 จำนวน แบบรายฤดูกาล แบ่งการแสดงผลเป็น 2 ส่วน ได้แก่

2.4.1 ข้อมูลพื้นฐาน ได้แก่ ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัว ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise

2.4.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

ผลการวิเคราะห์ข้อมูลสำหรับสถานการณ์ที่ 4 ภายใต้ข้อมูลขนาด 1000 จำนวน แบบรายฤดูกาล แสดงผลดังนี้

2.4.1 ข้อมูลพื้นฐาน

ตารางที่ 4-40 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูกาลของข้อมูลขนาด 1000 จำนวน

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	5.71	11.24	3.66	1.55	1.62	1.07
x ₁	20.75	22.93	23.55	83.95	82.95	85.43	61.58	61.01	61.38	11.69	12.74	12.53
x ₂	-1.62	0.26	-2.40	1.04	4.72	0.55	-0.09	1.37	-1.39	0.44	0.60	0.45
x ₃	-0.98	0.19	-2.62	1.55	2.05	1.18	0.74	0.93	-0.78	0.35	0.32	0.58
x ₄	4.77	4.20	4.80	24.67	9.86	16.13	12.10	5.43	9.00	3.27	0.89	1.98
x ₅	25.09	24.88	23.59	36.46	29.12	31.60	31.13	27.05	27.94	1.75	0.73	1.24
x ₆	15.62	19.96	13.24	25.34	26.21	25.20	21.03	22.66	18.70	1.74	1.20	2.38
x ₇	19.93	22.39	18.28	28.97	27.03	26.84	25.55	24.53	22.68	1.42	0.85	1.68

ตารางที่ 4-40 แสดงค่าสถิติพื้นฐานจำแนกตามฤดูกาลของข้อมูลขนาด 400 จำนวน ดังนี้ ปริมาณน้ำฝนมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 11.24 มิลลิเมตร และมีส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.62 มิลลิเมตร ความชื้นสัมพัทธ์ของอากาศมีค่าเฉลี่ยสูงสุดในฤดูร้อนคิดเป็นร้อยละ 61.58 และส่วนเบี่ยงเบนมาตรฐานร้อยละ 11.69 ความเร็วลมตามแนวแกน x มีค่าเฉลี่ยสูงสุดในฤดูหนาวเท่ากับ 1.39 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.45 เมตรต่อวินาที ความเร็วลมตามแนวแกน y มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 0.93 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.32 เมตรต่อวินาที การระเหยของน้ำมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 12.10 มิลลิเมตร และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 3.27 มิลลิเมตร อุณหภูมิอากาศสูงสุดมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 31.13 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.75 °C อุณหภูมิอากาศต่ำสุดมีค่าเฉลี่ย

สูงสุดในเดือนพฤษภาคมเท่ากับ 22.66 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.20 °C และอุณหภูมิอากาศเฉลี่ยมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 25.55 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.42 °C

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-41

ตารางที่ 4-41 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์

ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.003 (.915)	1						
x_3	-.072* (.023)	.463** (.000)	1					
x_4	-.007 (.828)	.553** (.000)	.328** (.000)	1				
x_5	-.027 (.394)	.369** (.000)	.227** (.000)	.486** (.000)	1			
x_6	.093** (.003)	.473** (.000)	-.026 (.419)	.149** (.000)	.359** (.000)	1		
x_7	.034 (.277)	.536** (.000)	.147** (.000)	.391** (.000)	.819** (.000)	.813** (.000)	1	
y	.064* (.043)	-.136** (.000)	-.285** (.000)	-.541** (.000)	-.502** (.000)	.261** (.000)	-.150** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-41 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (-0.541) รองลงมาคือ อุณหภูมิอากาศสูงสุด (-0.502) ความเร็วลมตามแนวแกน y (-0.285) อุณหภูมิอากาศต่ำสุด (0.261)

อุณหภูมิอากาศเฉลี่ย (-0.150) และความเร็วลมตามแนวแกน x (-0.136) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.064) ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-42

ตารางที่ 4-42 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายได้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน

Variable Entered										
Multiple R	.762									
Coefficient of Determination(R ²)	.581									
Adjusted R ²	.580									
Standard error of estimate	1.007									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	1398.500	3	466.167	460.124	.000					
Residual	1009.079	996	1.013							
Total	2407.579	999								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	12.350	.626		19.726	.000					
x ₄	-.177	.011	-.372	-15.833	.000	-.541	-.448	-.325	.763	1.311
x ₆	.443	.020	.495	22.535	.000	.261	.581	.462	.871	1.149
x ₅	-.444	.022	-.499	-20.049	.000	-.502	-.536	-.411	.680	1.471

จากตารางที่ 4-42 พบว่าตัวแปรพยากรณ์ได้แก่ การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า R = .762 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 58.1% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 12.350 - .177 x_4 - .444 x_5 + .443 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ อุณหภูมิอากาศสูงสุด รองลงมาคืออุณหภูมิอากาศต่ำสุด และการระเหยของน้ำ ตามลำดับ ดังนั้น

การคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน ได้ตัวแปรนำเข้าคือ การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 3-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-43

ตารางที่ 4-43 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	-.029 (.357)	1						
x_3	.089** (.005)	.409** (.000)	1					
x_4	.052 (.100)	.432** (.000)	.075* (.018)	1				
x_5	.033 (.304)	-.063* (.047)	.252** (.000)	-.164** (.000)	1			
x_6	.072* (.023)	.587** (.000)	.438** (.000)	.480** (.000)	.548** (.000)	1		
x_7	.060 (.057)	.423** (.000)	.436** (.000)	.258** (.000)	.780** (.000)	.944** (.000)	1	
y	.025 (.439)	-.247** (.000)	-.247** (.000)	.352** (.000)	-.057 (.070)	.161** (.000)	.072* (.023)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-43 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน ปรากฏว่าตัวแปรพยากรณ์ที่มี

ความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (0.352) รองลงมาคือ ความเร็วลมตามแนวแกน x (-0.247) และความเร็วลมตามแนวแกน y (-0.247) อุณหภูมิอากาศต่ำสุด (0.161) อุณหภูมิอากาศเฉลี่ย (0.072) และอุณหภูมิอากาศสูงสุด (-0.057) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.025) ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-44

ตารางที่ 4-44 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้อัตราข้อมูลขนาด 1000 จำนวนสำหรับฤดูฝน

Variable Entered										
Multiple R	.712									
Coefficient of Determination(R ²)	.507									
Adjusted R ²	.505									
Standard error of estimate	1.138									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	1324.509	5	264.902	204.7	.000					
	1286.261			11						
Residual	2610.771	994	1.294							
Total		999								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	17.752	1.573		11.287	.000					
x ₄	.322	.059	.176	5.486	.000	.352	.171	.122	.481	2.081
x ₂	-2.288	.095	-.845	-24.204	.000	-.247	-.609	-.539	.407	2.459
x ₆	1.298	.069	.967	18.877	.000	.161	.514	.420	.189	5.293
x ₅	-1.242	.087	-.562	-14.221	.000	-.057	-.411	-.317	.317	3.152
x ₃	-.999	.132	-.197	-7.582	.000	-.247	-.234	-.169	.732	1.366

จากตารางที่ 4-44 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า $R = .712$ ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 50.7% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 17.752 - 2.288 x_2 - .999 x_3 + .322 x_4 - 1.242 x_5 + 1.298 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ อุณหภูมิอากาศต่ำสุด อุณหภูมิอากาศสูงสุด ความเร็วลมตามแนวแกน y และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 5-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูหนาว ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ อุณหภูมิอากาศต่ำสุด (0.700) รองลงมาคือ อุณหภูมิอากาศเฉลี่ย (0.671) ความเร็วลมตามแนวแกน x (0.537) อุณหภูมิอากาศสูงสุด (0.385) การระเหยของน้ำ (0.196) และความเร็วลมตามแนวแกน y (-0.141) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.044) ดังตารางที่ 4-45

ตารางที่ 4-45 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์
ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	-.005 (.867)	1						
x_3	-.037 (.238)	.478** (.000)	1					
x_4	.033 (.299)	.267** (.000)	-.005 (.879)	1				
x_5	.022 (.489)	.302** (.000)	-.078* (.014)	.034 (.287)	1			
x_6	.075* (.017)	.354** (.000)	-.408** (.000)	.236** (.000)	.537** (.000)	1		
x_7	.068* (.033)	.344** (.000)	-.377** (.000)	.179** (.000)	.724** (.000)	.966** (.000)	1	
y	.044 (.169)	.537** (.000)	-.141** (.000)	.196** (.000)	.385** (.000)	.700** (.000)	.671** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปร
นำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-46

ตารางที่ 4-46 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1000 จำนวน
สำหรับฤดูหนาว

Variable Entered										
Multiple R	.771									
Coefficient of Determination(R ²)	.595									
Adjusted R ²	.594									
Standard error of estimate	.683									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	681.879	3	227.293	487.918	.000					
Residual	463.979	996	.466							
Total	1145.858	999								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	.873	.303		2.882	.004					
x_6	.216	.014	.479	15.806	.000	.700	.448	.319	.443	2.258
x_2	1.065	.076	.443	14.062	.000	.537	.407	.284	.410	2.439
x_3	-.288	.059	-.157	-4.861	.000	-.141	-.152	-.098	.391	2.560

จากตารางที่ 4-46 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ทำให้ค่า R = .771 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 59.5% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = .873 + 1.065 x_2 - .288 x_3 + .216 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 3-4-4-1

2.4.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA กับที่ใช้การคัดเลือกแบบเดิมของวิธี GA การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 แบบ พิจารณาจากค่า MAE MAPE RMSE และ R^2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-47 และตารางที่ 4-48

ตารางที่ 4-47 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.15390	0.51802	0.75011	0.94957	0.56689	0.57643
ค่า MAPE	0.25583	0.09134	0.15293	0.16390	0.09674	0.09887
ค่า RMSE	1.44760	0.65283	0.96804	1.16300	0.73673	0.76326
ค่า R^2	0.19871	0.81268	0.64165	0.17703	0.66973	0.64552

จากตารางที่ 4-47 กรณีข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.51802 ค่า MAPE เท่ากับ 0.09134 ค่า RMSE เท่ากับ 0.65283 และค่า R^2 เท่ากับ 0.81268 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.75011 ค่า MAPE เท่ากับ 0.15293 ค่า RMSE เท่ากับ 0.96804 และค่า R^2 เท่ากับ 0.64165 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.15390 ค่า MAPE เท่ากับ 0.25583 ค่า RMSE เท่ากับ 1.44760 และค่า R^2 เท่ากับ 0.19871 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจาก

ค่า MAE เท่ากับ 0.56689 ค่า MAPE เท่ากับ 0.09674 ค่า RMSE เท่ากับ 0.73673 และค่า R^2 เท่ากับ 0.66973 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.57643 ค่า MAPE เท่ากับ 0.09887 ค่า RMSE เท่ากับ 0.76326 และค่า R^2 เท่ากับ 0.64552 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.94957 ค่า MAPE เท่ากับ 0.16390 ค่า RMSE เท่ากับ 1.16300 และค่า R^2 เท่ากับ 0.17703 ตามลำดับ

ตารางที่ 4-48 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.53777	0.44141	0.53329	0.61874	0.61510	0.60068
ค่า MAPE	0.10808	0.07640	0.10704	0.10370	0.12596	0.10206
ค่า RMSE	0.69328	0.56282	0.68556	0.81804	0.79217	0.77099
ค่า R^2	0.81621	0.86078	0.82027	0.59281	0.66021	0.63831

จากตารางที่ 4-48 กรณีข้อมูลขนาด 1000 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.44141 ค่า MAPE เท่ากับ 0.07640 ค่า RMSE เท่ากับ 0.56282 และค่า R^2 เท่ากับ 0.86078 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.53329 ค่า MAPE เท่ากับ 0.10704 ค่า RMSE เท่ากับ 0.68556 และค่า R^2 เท่ากับ 0.82027 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.53777 ค่า MAPE เท่ากับ 0.10808 ค่า RMSE เท่ากับ 0.69328 และค่า R^2 เท่ากับ 0.81621 ตามลำดับ สำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.61510 ค่า MAPE เท่ากับ 0.12596 ค่า RMSE เท่ากับ 0.79217 ซึ่งมากกว่าตัวแบบ Wang-GA-BPNN ที่มีค่า MAE เท่ากับ 0.60068 ค่า MAPE เท่ากับ 0.10206 ค่า RMSE เท่ากับ 0.77099 แต่มีค่า R^2 เท่ากับ 0.66021 ซึ่งมากกว่าตัวแบบ Wang-GA-BPNN ที่มีค่า R^2 เท่ากับ 0.63831 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.61874 ค่า MAPE เท่ากับ 0.10370 ค่า RMSE เท่ากับ 0.81804 และค่า R^2 เท่ากับ 0.59281 ซึ่งมีความแม่นยำน้อยที่สุด

สำหรับฤดูร้อนข้อมูลขนาด 1000 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด และชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุด ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-49 และตารางที่ 4-50

ตารางที่ 4-49 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้อข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.16940	0.66070	0.70475	1.00560	0.79358	0.92277
ค่า MAPE	0.11251	0.05893	0.06381	0.09200	0.08081	0.09365
ค่า RMSE	1.65570	0.86023	0.91911	1.29950	1.10110	1.21380
ค่า R^2	0.04380	0.74187	0.72086	0.03068	0.73667	0.68000

จากตารางที่ 4-49 กรณีข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.66070 ค่า MAPE เท่ากับ 0.05893 ค่า RMSE เท่ากับ 0.86023 และค่า R^2 เท่ากับ 0.74187 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.70475 ค่า MAPE เท่ากับ 0.06381 ค่า RMSE เท่ากับ 0.91911 และค่า R^2 เท่ากับ 0.72086 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.16940 ค่า MAPE เท่ากับ 0.11251 ค่า RMSE เท่ากับ 1.65570 และค่า R^2 เท่ากับ 0.04380 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.73958 ค่า MAPE เท่ากับ 0.08081 ค่า RMSE เท่ากับ 1.10110 และค่า R^2 เท่ากับ 0.73667 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.92277 ค่า MAPE เท่ากับ 0.09365 ค่า RMSE เท่ากับ 1.21380 และค่า R^2 เท่ากับ 0.68000 และตัวแบบ Asadi-

GA-ANN มีค่า MAE เท่ากับ 1.00560 ค่า MAPE เท่ากับ 0.09200 ค่า RMSE เท่ากับ 1.29950 และค่า R^2 เท่ากับ 0.03068 ตามลำดับ

ตารางที่ 4-50 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.60025	0.56285	0.57327	0.85147	0.78342	0.83379
ค่า MAPE	0.05373	0.05067	0.05133	0.07873	0.07752	0.07649
ค่า RMSE	0.77106	0.72811	0.73683	1.17570	0.96637	1.08700
ค่า R^2	0.79261	0.82482	0.81062	0.20656	0.79716	0.32181

จากตารางที่ 4-50 กรณีข้อมูลขนาด 1000 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.56285 ค่า MAPE เท่ากับ 0.05067 ค่า RMSE เท่ากับ 0.72811 และค่า R^2 เท่ากับ 0.82482 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.57327 ค่า MAPE เท่ากับ 0.05133 ค่า RMSE เท่ากับ 0.73683 และค่า R^2 เท่ากับ 0.81062 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.60025 ค่า MAPE เท่ากับ 0.05373 ค่า RMSE เท่ากับ 0.77106 และค่า R^2 เท่ากับ 0.79261 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.78342 ค่า MAPE เท่ากับ 0.07752 ค่า RMSE เท่ากับ 0.96637 และค่า R^2 เท่ากับ 0.79716 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.83379 ค่า MAPE เท่ากับ 0.07649 ค่า RMSE เท่ากับ 1.08700 และค่า R^2 เท่ากับ 0.32181 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.85147 ค่า MAPE เท่ากับ 0.07873 ค่า RMSE เท่ากับ 1.17570 และค่า R^2 เท่ากับ 0.20656 ตามลำดับ

สำหรับฤดูร้อนข้อมูลขนาด 1000 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-51 และตารางที่ 4-52

ตารางที่ 4-51 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	0.66195	0.46518	0.50544	0.59159	0.45784	0.47215
ค่า MAPE	0.20976	0.14000	0.15905	0.16757	0.12592	0.13132
ค่า RMSE	0.83376	0.57647	0.64375	0.76250	0.57794	0.59959
ค่า R^2	0.44608	0.75781	0.66978	0.22407	0.55424	0.52021

จากตารางที่ 4-51 กรณีข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.46518 ค่า MAPE เท่ากับ 0.14000 ค่า RMSE เท่ากับ 0.57647 และค่า R^2 เท่ากับ 0.75781 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.50544 ค่า MAPE เท่ากับ 0.15905 ค่า RMSE เท่ากับ 0.64375 และค่า R^2 เท่ากับ 0.66978 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.66195 ค่า MAPE เท่ากับ 0.20976 ค่า RMSE เท่ากับ 0.83376 และค่า R^2 เท่ากับ 0.44608 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.45784 ค่า MAPE เท่ากับ 0.12592 ค่า RMSE เท่ากับ 0.57794 และค่า R^2 เท่ากับ 0.48624 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.47215 ค่า MAPE เท่ากับ 0.13132 ค่า RMSE เท่ากับ 0.59959 และค่า R^2 เท่ากับ 0.52021 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.59159 ค่า MAPE เท่ากับ 0.16757 ค่า RMSE เท่ากับ 0.76250 และค่า R^2 เท่ากับ 0.22407 ตามลำดับ

ตารางที่ 4-52 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.37930	0.31057	0.37988	0.46316	0.44190	0.44236
ค่า MAPE	0.11700	0.09600	0.11712	0.13143	0.12641	0.12656
ค่า RMSE	0.49096	0.39150	0.48253	0.61491	0.58573	0.58615
ค่า R^2	0.80793	0.88830	0.81447	0.49537	0.54214	0.54148

จากตารางที่ 4-52 กรณีข้อมูลขนาด 1000 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.31057 ค่า MAPE เท่ากับ 0.09600 ค่า RMSE เท่ากับ 0.39150 และค่า R^2 เท่ากับ 0.88830 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.37988 ค่า MAPE เท่ากับ 0.11712 ค่า RMSE เท่ากับ 0.48253 และค่า R^2 เท่ากับ 0.81447 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.37930 ค่า MAPE เท่ากับ 0.11700 ค่า RMSE เท่ากับ 0.49096 และค่า R^2 เท่ากับ 0.80793 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.44190 ค่า MAPE เท่ากับ 0.12641 ค่า RMSE เท่ากับ 0.58573 และค่า R^2 เท่ากับ 0.54214 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.44236 ค่า MAPE เท่ากับ 0.12656 ค่า RMSE เท่ากับ 0.58615 และค่า R^2 เท่ากับ 0.54148 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.46316 ค่า MAPE เท่ากับ 0.13143 ค่า RMSE เท่ากับ 0.61491 และค่า R^2 เท่ากับ 0.49537 ตามลำดับ

สำหรับฤดูหนาวข้อมูลขนาด 1000 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด และชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุด

2.5 สำหรับสถานการณ์ที่ 5 ภายใต้ข้อมูลขนาด 1100 จำนวน แบบรายฤดูกาล แบ่งการแสดงผลเป็น 2 ส่วน ได้แก่

2.5.1 ข้อมูลพื้นฐาน ได้แก่ ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัว ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise

2.5.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

ผลการวิเคราะห์ข้อมูลสำหรับสถานการณ์ที่ 5 ภายใต้อัตราข้อมูลขนาด 1100 จำนวน แบบรายฤดูกาล แสดงผลดังนี้

2.5.1 ข้อมูลพื้นฐาน

ตารางที่ 4-53 ค่าสถิติพื้นฐานของข้อมูลจริงจำแนกตามฤดูกาลของข้อมูลขนาด 1100 จำนวน

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

จากตารางที่ 4-53 แสดงค่าสถิติพื้นฐานจำแนกตามฤดูกาลของข้อมูลขนาด 1100 จำนวนดังนี้ 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 อุณหภูมิอากาศต่ำสุดมีค่าเฉลี่ย

สูงสุดในฤดูฝนเท่ากับ 22.69 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.18 °C และอุณหภูมิอากาศเฉลี่ยมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 25.60 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.40 °C

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-54

ตารางที่ 4-54 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์

ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.031 (.308)	1						
x_3	-.061* (.043)	.452** (.000)	1					
x_4	-.008 (.801)	.540** (.000)	.323** (.000)	1				
x_5	-.016 (.599)	.365** (.000)	.227** (.000)	.486** (.000)	1			
x_6	.108** (.000)	.476** (.000)	-.031 (.306)	.149** (.000)	.356** (.000)	1		
x_7	.048 (.112)	.535** (.000)	.145** (.000)	.393** (.000)	.822** (.000)	.809** (.000)	1	
y	.060* (.047)	-.134** (.000)	-.286** (.000)	-.549** (.000)	-.514** (.000)	.252** (.000)	-.167** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-54 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (-0.549) รองลงมาคือ อุณหภูมิ

อากาศสูงสุด (-0.514) ความเร็วลมตามแนวแกน y (-0.286) อุณหภูมิอากาศต่ำสุด (0.252) อุณหภูมิอากาศเฉลี่ย (-0.167) และความเร็วลมตามแนวแกน x (-0.134) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.060)

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-55

ตารางที่ 4-55 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายได้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน

Variable Entered										
Multiple R	.767									
Coefficient of Determination(R ²)	.589									
Adjusted R ²	.588									
Standard error of estimate	.981									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	1512.123	3	504.041	523.228	.000					
Residual	1055.808	1096	.963							
Total	2567.931	1099								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	12.599	.592		21.282	.000					
X ₄	-.178	.011	-.376	-16.951	.000	-.549	-.456	-.328	.763	1.311
X ₆	.439	.019	.488	23.520	.000	.252	.579	.456	.872	1.146
X ₅	-.448	.021	-.505	-21.519	.000	-.514	-.545	-.417	.681	1.468

จากตารางที่ 4-55 พบว่าตัวแปรพยากรณ์ได้แก่ การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า R = .767 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝน

ได้ 58.9% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 12.599 - .178 x_4 - .448 x_5 + .439 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ อุณหภูมิอากาศสูงสุด รองลงมาคืออุณหภูมิอากาศต่ำสุด และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน ได้ตัวแปรนำเข้าคือ การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 3-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-56

ตารางที่ 4-56 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	-.024 (.422)	1						
x_3	.093** (.002)	.402** (.000)	1					
x_4	.049 (.105)	.426** (.000)	.062* (.039)	1				
x_5	.030 (.324)	-.074* (.014)	.240** (.000)	-.160** (.000)	1			
x_6	.074* (.014)	.582** (.000)	.434** (.000)	.478** (.000)	.546** (.000)	1		
x_7	.061* (.044)	.413** (.000)	.427** (.000)	.255** (.000)	.783** (.000)	.941** (.000)	1	
y	.042 (.164)	-.251** (.000)	-.255** (.000)	.356** (.000)	-.069* (.022)	.150** (.000)	.058 (.054)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

จากตารางที่ 4-56 แสดงผลค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ การระเหยของน้ำ (0.356) รองลงมาคือ ความเร็วลมตามแนวแกน y (-0.255) ความเร็วลมตามแนวแกน x (-0.251) อุณหภูมิอากาศต่ำสุด (0.150) อุณหภูมิอากาศสูงสุด (-0.069) และอุณหภูมิอากาศเฉลี่ย (0.058) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.042) ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-57

ตารางที่ 4-57 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน

Variable Entered										
Multiple R										
Coefficient of Determination(R ²)										
Adjusted R ²										
Standard error of estimate										
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	1507.211	5	301.442	232.108	.000					
Residual	1420.797	1094	1.299							
Total	2928.008	1099								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	18.663	1.486		12.559	.000					
X ₄	.324	.057	.173	5.708	.000	.356	.170	.120	.485	2.064
X ₂	-2.360	.091	-.852	-25.808	.000	-.251	-.615	-.544	.407	2.460
X ₆	1.345	.067	.974	20.101	.000	.150	.519	.423	.189	5.296
X ₅	-1.308	.083	-.588	-15.753	.000	-.069	-.430	-.332	.318	3.140
X ₃	-1.064	.127	-.205	-8.344	.000	-.255	-.245	-.176	.734	1.362

จากตารางที่ 4-57 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ทำให้ค่า $R = .717$ ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 51.5% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = 18.663 - 2.360 \cdot x_2 - 1.064 \cdot x_3 + .324 \cdot x_4 - 1.308 \cdot x_5 + 1.345 \cdot x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ อุณหภูมิอากาศต่ำสุด อุณหภูมิอากาศสูงสุด ความเร็วลมตามแนวแกน y และการระเหยของน้ำ ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูกนำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 5-4-4-1

การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์ สำหรับฤดูหนาว ปรากฏว่าตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์มากที่สุดคือ อุณหภูมิอากาศต่ำสุด (0.698) รองลงมาคือ อุณหภูมิอากาศเฉลี่ย (0.665) ความเร็วลมตามแนวแกน x (0.527) อุณหภูมิอากาศสูงสุด (0.372) การระเหยของน้ำ (0.193) และความเร็วลมตามแนวแกน y (-0.146) ตามลำดับ สำหรับตัวแปรพยากรณ์ที่มีความสัมพันธ์กับตัวแปรเกณฑ์น้อยที่สุดคือ ความชื้นสัมพัทธ์ของอากาศ (0.054) ดังตารางที่ 4-58

ตารางที่ 4-58 ค่าสัมประสิทธิ์สหสัมพันธ์รายคู่ระหว่างชุดตัวแปรพยากรณ์และตัวแปรเกณฑ์
ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว

ตัวแปร	x_1	x_2	x_3	x_4	x_5	x_6	x_7	y
x_1	1							
x_2	.011 (.710)	1						
x_3	-.038 (.214)	.484** (.000)	1					
x_4	.035 (.248)	.253** (.000)	-.018 (.557)	1				
x_5	.033 (.274)	.290** (.000)	-.089** (.003)	.033 (.270)	1			
x_6	.076* (.012)	.350** (.000)	-.410** (.000)	.238** (.000)	.541** (.000)	1		
x_7	.071* (.019)	.337** (.000)	-.380** (.000)	.180** (.000)	.729** (.000)	.966** (.000)	1	
y	.054 (.076)	.527** (.000)	-.146** (.000)	.193** (.000)	.372** (.000)	.698** (.000)	.665** (.000)	1

(ค่า p-value) ค่าความน่าจะเป็นที่จะเกิดค่าสถิติทดสอบที่คำนวณได้

*มีนัยสำคัญทางสถิติที่ระดับ .05

**มีนัยสำคัญทางสถิติที่ระดับ .01

ขั้นตอนต่อไปเป็นการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise เพื่อคัดเลือกตัวแปร
นำเข้าของโครงข่ายประสาทเทียม สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-59

ตารางที่ 4-59 ผลการวิเคราะห์ด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน
สำหรับฤดูหนาว

Variable Entered										
Multiple R	.767									
Coefficient of Determination(R ²)	.588									
Adjusted R ²	.587									
Standard error of estimate	.671									
Analysis of Variance										
	Sum of Squares	df	Mean Square	F	Sig.					
Regression	703.967	3	234.656	521.555	.000					
Residual	493.107	1096	.450							
Total	1197.074	1099								
Variables Entered into the Regression Model										
Variables Entered	Regression Coefficients			Statistical Significance		Correlations			Collinearity Statistics	
	b	Std. Error	Beta	t	Sig.	Zero-order	Partial	Part	Tolerance	VIF
(Constant)	.844	.291		2.905	.004					
x_6	.215	.013	.478	16.349	.000	.698	.443	.317	.439	2.277
x_2	1.038	.072	.438	14.363	.000	.527	.398	.278	.404	2.475
x_3	-.293	.057	-.162	-5.169	.000	-.146	-.154	-.100	.383	2.611

จากตารางที่ 4-59 พบว่าตัวแปรพยากรณ์ได้แก่ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ทำให้ค่า R = .767 ซึ่งสามารถอธิบายตัวแปรเกณฑ์ปริมาณน้ำฝนได้ 58.8% และมีนัยสำคัญทางสถิติที่ .05 สามารถสร้างสมการพยากรณ์ด้วยค่า b ได้เป็น $Y' = .844 + 1.038 x_2 - .293 x_3 + .215 x_6$ ซึ่งตัวแปรพยากรณ์ที่มีค่า b มากที่สุดคือ ความเร็วลมตามแนวแกน x รองลงมาคือ ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ตามลำดับ ดังนั้นการคัดเลือกตัวแปรนำเข้าของโครงข่ายประสาทเทียมด้วยวิธี MRA แบบ Stepwise ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว ได้ตัวแปรนำเข้าคือ ความเร็วลมตามแนวแกน x ความเร็วลมตามแนวแกน y และอุณหภูมิอากาศต่ำสุด ตัวแปรที่ผ่านการคัดเลือกเหล่านี้จะถูก

นำไปใช้ในการสร้างตัวแบบพยากรณ์โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN โดยมีสถาปัตยกรรมของโครงข่ายเป็น 3-4-4-1

2.5.2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม

เปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA กับที่ใช้การคัดเลือกแบบเดิมของวิธี GA การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 แบบ พิจารณาจากค่า MAE MAPE RMSE และ R^2 ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูร้อน แสดงผลที่ได้ดังตารางที่ 4-60 และตารางที่ 4-61

ตารางที่ 4-60 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.12120	0.65309	0.69176	0.95550	0.61133	0.64118
ค่า MAPE	0.24685	0.13278	0.14030	0.16607	0.10227	0.10880
ค่า RMSE	1.41400	0.86192	0.90989	1.17620	0.79127	0.81326
ค่า R^2	0.19898	0.70235	0.66830	0.17752	0.62777	0.60679

จากตารางที่ 4-60 กรณีข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.65309 ค่า MAPE เท่ากับ 0.13278 ค่า RMSE เท่ากับ 0.86192 และค่า R^2 เท่ากับ 0.70235 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.69176 ค่า MAPE เท่ากับ 0.14030 ค่า RMSE เท่ากับ 0.90989 และค่า R^2 เท่ากับ 0.66830 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.12120 ค่า MAPE

เท่ากับ 0.24685 ค่า RMSE เท่ากับ 1.41400 และค่า R^2 เท่ากับ 0.19898 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.61133 ค่า MAPE เท่ากับ 0.10227 ค่า RMSE เท่ากับ 0.79127 และค่า R^2 เท่ากับ 0.62777 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.64118 ค่า MAPE เท่ากับ 0.10880 ค่า RMSE เท่ากับ 0.81326 และค่า R^2 เท่ากับ 0.60679 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.95550 ค่า MAPE เท่ากับ 0.16607 ค่า RMSE เท่ากับ 1.17620 และค่า R^2 เท่ากับ 0.17752 ตามลำดับ

ตารางที่ 4-61 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.52684	0.52676	0.52086	0.59314	0.57050	0.56404
ค่า MAPE	0.10641	0.10539	0.10386	0.09891	0.09638	0.09504
ค่า RMSE	0.68372	0.67935	0.67670	0.75776	0.73380	0.72241
ค่า R^2	0.81271	0.81509	0.81653	0.65863	0.67987	0.68973

จากตารางที่ 4-61 กรณีข้อมูลขนาด 1100 จำนวน สำหรับฤดูร้อน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.52086 ค่า MAPE เท่ากับ 0.10386 ค่า RMSE เท่ากับ 0.67670 และค่า R^2 เท่ากับ 0.81653 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.52676 ค่า MAPE เท่ากับ 0.10539 ค่า RMSE เท่ากับ 0.67935 และค่า R^2 เท่ากับ 0.81509 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.52684 ค่า MAPE เท่ากับ 0.10641 ค่า RMSE เท่ากับ 0.68372 และค่า R^2 เท่ากับ 0.81217 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.56404 ค่า MAPE เท่ากับ 0.09504 ค่า RMSE เท่ากับ 0.72241 และค่า R^2 เท่ากับ 0.68973 รองลงมาคือตัวแบบ Wang-GA(New)-ANN มีค่า MAE เท่ากับ 0.57050 ค่า MAPE เท่ากับ 0.09638 ค่า RMSE เท่ากับ 0.73380 และค่า R^2 เท่ากับ 0.67987 และตัวแบบ Wang-

GA-ANN มีค่า MAE เท่ากับ 0.59314 ค่า MAPE เท่ากับ 0.09891 ค่า RMSE เท่ากับ 0.75776 และค่า R^2 เท่ากับ 0.65863 ตามลำดับ

สำหรับฤดูร้อนข้อมูลขนาด 1100 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA-BPNN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูฝน แสดงผลที่ได้ดังตารางที่ 4-62 และตารางที่ 4-63

ตารางที่ 4-62 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	1.13490	0.65695	0.68519	1.21170	0.84143	0.91927
ค่า MAPE	0.10875	0.05855	0.06216	0.11101	0.08868	0.09109
ค่า RMSE	1.60450	0.86083	0.90309	1.57520	1.22710	1.27470
ค่า R^2	0.04858	0.75513	0.73050	0.00671	0.67295	0.64709

จากตารางที่ 4-62 กรณีข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.65695 ค่า MAPE เท่ากับ 0.05855 ค่า RMSE เท่ากับ 0.86083 และค่า R^2 เท่ากับ 0.75513 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.68519 ค่า MAPE เท่ากับ 0.06216 ค่า RMSE เท่ากับ 0.90309 และค่า R^2 เท่ากับ 0.73050 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.13490 ค่า MAPE เท่ากับ 0.10875 ค่า RMSE เท่ากับ 1.60450 และค่า R^2 เท่ากับ 0.04858 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจาก

ค่า MAE เท่ากับ 0.84143 ค่า MAPE เท่ากับ 0.08868 ค่า RMSE เท่ากับ 1.22710 และค่า R^2 เท่ากับ 0.67295 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.91927 ค่า MAPE เท่ากับ 0.09109 ค่า RMSE เท่ากับ 1.27470 และค่า R^2 เท่ากับ 0.64709 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 1.21170 ค่า MAPE เท่ากับ 0.11101 ค่า RMSE เท่ากับ 1.57520 และค่า R^2 เท่ากับ 0.00671 ตามลำดับ

ตารางที่ 4-63 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.60047	0.59257	0.59528	1.00580	0.92739	0.98464
ค่า MAPE	0.05381	0.05307	0.05345	0.09302	0.08746	0.09083
ค่า RMSE	0.76911	0.75706	0.75972	1.39330	1.23060	1.33370
ค่า R^2	0.78138	0.78818	0.78669	0.22289	0.39384	0.28800

จากตารางที่ 4-63 กรณีข้อมูลขนาด 1100 จำนวน สำหรับฤดูฝน การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.59257 ค่า MAPE เท่ากับ 0.05307 ค่า RMSE เท่ากับ 0.75706 และค่า R^2 เท่ากับ 0.78818 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.59528 ค่า MAPE เท่ากับ 0.05345 ค่า RMSE เท่ากับ 0.75972 และค่า R^2 เท่ากับ 0.78669 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.60047 ค่า MAPE เท่ากับ 0.05381 ค่า RMSE เท่ากับ 0.76911 และค่า R^2 เท่ากับ 0.78138 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.92739 ค่า MAPE เท่ากับ 0.08746 ค่า RMSE เท่ากับ 1.23060 และค่า R^2 เท่ากับ 0.39384 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.98464 ค่า MAPE เท่ากับ 0.09083 ค่า RMSE เท่ากับ 1.33370 และค่า R^2 เท่ากับ 0.28800 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 1.00580 ค่า MAPE เท่ากับ 0.09302 ค่า RMSE เท่ากับ 1.39330 และค่า R^2 เท่ากับ 0.22289 ตามลำดับ

สำหรับฤดูฝนข้อมูลขนาด 1100 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด และชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุด ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และระหว่างตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA สำหรับฤดูหนาว แสดงผลที่ได้ดังตารางที่ 4-64 และตารางที่ 4-65

ตารางที่ 4-64 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN ภายใต้อข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN	Asadi-GA-ANN	Asadi-GA(New)-ANN	Asadi-GA-BPNN
ค่า MAE	0.64757	0.46800	0.47165	0.60103	0.43919	0.44397
ค่า MAPE	0.20369	0.14194	0.14348	0.16861	0.12391	0.12502
ค่า RMSE	0.82158	0.58104	0.59392	0.75917	0.55836	0.56112
ค่า R^2	0.43720	0.75394	0.74292	0.18247	0.55776	0.55339

จากตารางที่ 4-64 กรณีข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.46800 ค่า MAPE เท่ากับ 0.14194 ค่า RMSE เท่ากับ 0.58104 และค่า R^2 เท่ากับ 0.75394 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.47165 ค่า MAPE เท่ากับ 0.14348 ค่า RMSE เท่ากับ 0.59392 และค่า R^2 เท่ากับ 0.74292 และตัวแบบ Asadi-GA-ANN มีค่า MAE เท่ากับ 0.64757 ค่า MAPE เท่ากับ 0.20369 ค่า RMSE เท่ากับ 0.82158 และค่า R^2 เท่ากับ 0.43720 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Asadi-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.43919 ค่า MAPE เท่ากับ 0.12391 ค่า RMSE เท่ากับ 0.55836 และค่า R^2 เท่ากับ 0.55776 รองลงมาคือตัวแบบ Asadi-GA-BPNN มีค่า MAE เท่ากับ 0.44397 ค่า MAPE เท่ากับ 0.12502 ค่า RMSE เท่ากับ 0.56112 และค่า R^2 เท่ากับ 0.55339 และตัวแบบ Asadi-

GA-ANN มีค่า MAE เท่ากับ 0.60103 ค่า MAPE เท่ากับ 0.16861 ค่า RMSE เท่ากับ 0.75917 และค่า R^2 เท่ากับ 0.18247 ตามลำดับ

ตารางที่ 4-65 ค่า MAE MAPE RMSE และ R^2 ของตัวแบบพยากรณ์ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ภายใต้ข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว

ประสิทธิภาพการพยากรณ์	ชุดการเรียนรู้			ชุดการทดสอบ		
	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN	Wang-GA-ANN	Wang-GA(New)-ANN	Wang-GA-BPNN
ค่า MAE	0.38074	0.36905	0.37750	0.43167	0.42410	0.41963
ค่า MAPE	0.11663	0.11238	0.11646	0.12233	0.12034	0.12170
ค่า RMSE	0.49148	0.47533	0.48491	0.56244	0.53706	0.54787
ค่า R^2	0.79860	0.81162	0.80394	0.55129	0.59087	0.57423

จากตารางที่ 4-65 กรณีข้อมูลขนาด 1100 จำนวน สำหรับฤดูหนาว การตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ ปรากฏว่า สำหรับชุดการเรียนรู้ตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.36905 ค่า MAPE เท่ากับ 0.11238 ค่า RMSE เท่ากับ 0.47533 และค่า R^2 เท่ากับ 0.81162 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.37750 ค่า MAPE เท่ากับ 0.11646 ค่า RMSE เท่ากับ 0.48491 และค่า R^2 เท่ากับ 0.80394 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.38074 ค่า MAPE เท่ากับ 0.11663 ค่า RMSE เท่ากับ 0.49148 และค่า R^2 เท่ากับ 0.79860 ตามลำดับ ในทำนองเดียวกันสำหรับชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุดจากค่า MAE เท่ากับ 0.42410 ค่า MAPE เท่ากับ 0.12034 ค่า RMSE เท่ากับ 0.53706 และค่า R^2 เท่ากับ 0.59087 รองลงมาคือตัวแบบ Wang-GA-BPNN มีค่า MAE เท่ากับ 0.41963 ค่า MAPE เท่ากับ 0.12170 ค่า RMSE เท่ากับ 0.54787 และค่า R^2 เท่ากับ 0.57423 และตัวแบบ Wang-GA-ANN มีค่า MAE เท่ากับ 0.43167 ค่า MAPE เท่ากับ 0.12233 ค่า RMSE เท่ากับ 0.56244 และค่า R^2 เท่ากับ 0.55129 ตามลำดับ

สำหรับชุดหวนข้อมูลขนาด 1100 จำนวน เมื่อตรวจสอบประสิทธิภาพความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 6 แล้ว ปรากฏว่า ทั้งชุดการเรียนรู้และชุดการทดสอบตัวแบบ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของทั้ง 6 ตัวแบบ โดยพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE MAPE RMSE และ R^2 โดยที่ค่า MAE MAPE และ RMSE ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามีความแม่นยำในการพยากรณ์ ส่วนค่า R^2 ต้องมีค่ามาก ๆ เข้าใกล้ 1 และควรมากกว่า 0.7 (สถาบันพัฒนาการชลประทาน, 2551) จึงถือว่ามีความแม่นยำในการพยากรณ์ ภายใต้ข้อมูล 5 สถานการณ์สรุปผลได้ดังนี้

ตารางที่ 4-6 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAE สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์

แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	1.03430	0.56672	0.58014	0.33178	0.33071	0.33013	1.47190	0.54351	0.78250	0.34965	0.32962	0.34597	0.74759	0.53371	0.56044	0.28833	0.27842	0.28287
2	1.29590	0.67502	0.71141	0.50750	0.42197	0.45421	1.28800	0.55556	0.59301	0.46898	0.45352	0.46311	1.03390	0.49923	0.63615	0.38436	0.37714	0.38371
3	1.04910	0.53922	0.60840	0.52684	0.45185	0.45124	1.24040	0.66228	0.68251	0.58034	0.58026	0.54989	0.69106	0.46670	0.55306	0.35314	0.31028	0.31117
4	1.15390	0.51802	0.75011	0.53777	0.44141	0.53329	1.16940	0.66070	0.70475	0.60025	0.56285	0.57327	0.66195	0.46518	0.50544	0.37930	0.31057	0.37988
5	1.12120	0.65309	0.69176	0.52684	0.52676	0.52086	1.13490	0.65695	0.68519	0.60047	0.59257	0.59528	0.64757	0.46800	0.47165	0.38074	0.36905	0.37750

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-6 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE

ตารางที่ 4-67 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAPE สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์
แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	0.18970	0.09731	0.09933	0.05444	0.05420	0.05407	0.14509	0.04839	0.07386	0.03204	0.02978	0.03094	0.25682	0.18463	0.19425	0.09695	0.09213	0.09361
2	0.24994	0.11878	0.12719	0.08785	0.07418	0.07881	0.12759	0.05047	0.05434	0.04291	0.04180	0.04231	0.34212	0.15003	0.19368	0.11601	0.11286	0.11592
3	0.19714	0.09568	0.11006	0.10641	0.07852	0.07862	0.11753	0.05958	0.06152	0.05203	0.05202	0.04946	0.21137	0.14097	0.16557	0.11102	0.09587	0.09618
4	0.25583	0.09134	0.15293	0.10808	0.07640	0.10704	0.11251	0.05893	0.06381	0.05373	0.05067	0.05133	0.20976	0.14000	0.15905	0.11700	0.09600	0.11712
5	0.24685	0.13278	0.14030	0.10641	0.10539	0.10386	0.10875	0.05855	0.06216	0.05381	0.05307	0.05345	0.20369	0.14194	0.14348	0.11663	0.11238	0.11646

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-67 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAPE

ตารางที่ 4-68 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า RMSE สำหรับชุดการเรียนรู้ภายใต้ข้อมูล 5 สถานการณ์
แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	1.31110	0.70518	0.72014	0.43353	0.43176	0.43114	2.05050	0.69987	1.12340	0.46946	0.43291	0.45086	0.93226	0.67750	0.73065	0.37524	0.36270	0.36305
2	1.59030	0.86439	0.90254	0.64797	0.53691	0.59715	1.85980	0.71152	0.75414	0.61028	0.59294	0.60120	1.27180	0.65079	0.80702	0.50969	0.50419	0.50888
3	1.32660	0.67140	0.80522	0.68372	0.57439	0.57223	1.71790	0.85124	0.87488	0.74784	0.74767	0.71390	0.84654	0.57934	0.69071	0.44239	0.39108	0.39243
4	1.44760	0.65283	0.96804	0.69328	0.56282	0.68556	1.65570	0.86023	0.91911	0.77106	0.72811	0.73683	0.83376	0.57647	0.64375	0.49096	0.39150	0.48253
5	1.41400	0.86192	0.90989	0.68372	0.67935	0.67670	1.60450	0.86083	0.90309	0.76911	0.75706	0.75972	0.82158	0.58104	0.59392	0.49148	0.47533	0.48491

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-68 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า RMSE

ตารางที่ 4-69 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า R^2 สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์
แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	0.18441	0.76405	0.75394	0.91082	0.91155	0.91180	0.04063	0.88823	0.71203	0.94971	0.95724	0.95362	0.43706	0.70269	0.65422	0.90880	0.91479	0.91463
2	0.00438	0.70587	0.67933	0.83471	0.88652	0.85963	0.05108	0.86111	0.84397	0.89782	0.90355	0.90084	0.00223	0.73873	0.59823	0.83975	0.84318	0.84025
3	0.22649	0.80188	0.71503	0.81271	0.85500	0.85608	0.02487	0.76056	0.74708	0.81520	0.81528	0.83159	0.47771	0.75538	0.65230	0.85737	0.88853	0.88776
4	0.19871	0.81268	0.64165	0.81621	0.86078	0.82027	0.04380	0.74187	0.72086	0.79261	0.82482	0.81062	0.44608	0.75781	0.66978	0.80793	0.88830	0.81447
5	0.19898	0.70235	0.66830	0.81271	0.81509	0.81653	0.04858	0.75513	0.73050	0.78138	0.78818	0.78669	0.43720	0.75394	0.74292	0.79860	0.81162	0.80394

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-69 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า R^2

ตารางที่ 4-70 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ
สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล

สถานการณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	x	✓	✓	✓	✓	✓	x	✓	✓	✓	✓	✓	x	✓	x	✓	✓	✓
2	x	✓	x	✓	✓	✓	x	✓	✓	✓	✓	✓	x	✓	x	✓	✓	✓
3	x	✓	✓	✓	✓	✓	x	✓	✓	✓	✓	✓	x	✓	x	✓	✓	✓
4	x	✓	x	✓	✓	✓	x	✓	✓	✓	✓	✓	x	✓	x	✓	✓	✓
5	x	✓	x	✓	✓	✓	x	✓	✓	✓	✓	✓	x	✓	✓	✓	✓	✓

หมายเหตุ: ✓ หมายถึงตัวแบบพยากรณ์มีค่า R^2 มากกว่า 0.7

x หมายถึงตัวแบบพยากรณ์มีค่า R^2 ไม่เกิน 0.7

M1 แทน Asadi-GA-ANN

M2 แทน Asadi-GA(New)-ANN

M3 แทน Asadi-GA-BPNN

M4 แทน Wang-GA-ANN

M5 แทน Wang-GA(New)-ANN

M6 แทน Wang-GA-BPNN

จากตารางที่ 4-70 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ สำหรับชุดการเรียนรู้ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล (ฤดูร้อน ฤดูฝน ฤดูหนาว) มีทั้งหมด 15 สถานการณ์ สรุปได้ว่า

M1 ไม่มีสถานการณ์ใดที่มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 0 ของสถานการณ์ทั้งหมด

M2 ทุกสถานการณ์มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 100 ของสถานการณ์ทั้งหมด

M3 มี 8 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 53.33 ของสถานการณ์ทั้งหมด

M4 ทุกสถานการณ์มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 100 ของสถานการณ์ทั้งหมด

M5 ทุกสถานการณ์มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 100 ของสถานการณ์ทั้งหมด

M6 ทุกสถานการณ์มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 100 ของสถานการณ์ทั้งหมด

นั่นคือ M2 M4 M5 และ M6 มีประสิทธิภาพความแม่นยำที่ดี สามารถนำไปใช้ได้กับทุก

สถานการณ์ M3 มีประสิทธิภาพความแม่นยำที่ดีใน 8 สถานการณ์คือ ฤดูร้อน สำหรับขนาดข้อมูล 300 และ 500 ฤดูฝน สำหรับขนาดข้อมูล 300 400 500 1000 และ 1100 ฤดูหนาว สำหรับขนาดข้อมูล 1100 แต่ส่วน M1 มีประสิทธิภาพความแม่นยำที่ไม่ดีในทุกสถานการณ์

ตารางที่ 4-71 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAE สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์
แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	1.33930	0.70081	0.73206	0.83470	0.82661	0.82501	1.26310	0.69410	0.78139	0.94811	0.84713	0.86158	0.77458	0.46668	0.62347	0.56888	0.54755	0.55412
2	1.47360	0.78683	0.91198	0.80012	0.65886	0.65983	1.38730	0.78047	0.81321	0.80544	0.73455	0.75717	0.98363	0.65227	0.70515	0.49911	0.49586	0.49679
3	1.03950	0.61433	0.69750	0.69969	0.66599	0.64313	1.45820	0.80720	0.80187	0.81041	0.80942	0.79115	0.66297	0.61003	0.63800	0.63190	0.61071	0.61465
4	0.94957	0.56689	0.57643	0.61874	0.61510	0.60068	1.00560	0.79358	0.92277	0.85147	0.78342	0.83379	0.59159	0.45784	0.47215	0.46316	0.44190	0.44236
5	0.95550	0.61133	0.64118	0.59314	0.57050	0.56404	1.21170	0.84143	0.91927	1.00580	0.92739	0.98464	0.60103	0.43919	0.44397	0.43167	0.42410	0.41963

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-71 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE

ตารางที่ 4-72 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า MAPE สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์
แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	0.37502	0.17866	0.18731	0.19237	0.18992	0.18932	0.14923	0.06618	0.07973	0.10085	0.08729	0.09100	0.18512	0.10665	0.15727	0.14491	0.14327	0.14502
2	0.46117	0.19897	0.25233	0.21673	0.16621	0.16692	0.14983	0.07119	0.07551	0.07285	0.06689	0.07019	0.42655	0.23139	0.25891	0.18809	0.18712	0.18732
3	0.23059	0.12587	0.13950	0.14090	0.13382	0.12816	0.16473	0.08165	0.08445	0.07956	0.07941	0.07778	0.18452	0.17136	0.17770	0.18289	0.17608	0.17836
4	0.16390	0.09674	0.09887	0.10370	0.12596	0.10206	0.09200	0.08081	0.09365	0.07873	0.07752	0.07649	0.16757	0.12592	0.13132	0.13143	0.12641	0.12656
5	0.16607	0.10227	0.10880	0.09891	0.09638	0.09504	0.11101	0.08868	0.09109	0.09302	0.08746	0.09083	0.16861	0.12391	0.12502	0.12233	0.12034	0.12170

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-72 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAPE

ตารางที่ 4-73 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า RMSE สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์
แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	1.65960	0.88592	0.93795	1.10810	1.10550	1.10420	1.98090	0.85318	1.12010	1.43300	1.17650	1.25410	0.99092	0.64061	0.78521	0.74395	0.70371	0.70615
2	1.92820	1.04910	1.22000	1.11250	0.93694	0.93898	2.01380	0.97811	1.01250	1.09850	0.93195	1.04650	1.20550	0.82844	0.86780	0.64135	0.63571	0.63748
3	1.29380	0.76270	0.87447	0.87609	0.82632	0.78660	2.14500	1.06420	1.11070	1.00370	1.00270	0.97859	0.87100	0.79116	0.81483	0.78589	0.77700	0.78269
4	1.16300	0.73673	0.76326	0.81804	0.79217	0.77099	1.29950	1.10110	1.21380	1.17570	0.96637	1.08700	0.76250	0.57794	0.59959	0.61491	0.58573	0.58615
5	1.17620	0.79127	0.81326	0.75776	0.73380	0.72241	1.57520	1.22710	1.27470	1.39330	1.23060	1.33370	0.75917	0.55836	0.56112	0.56244	0.53706	0.54787

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-73 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า RMSE

ตารางที่ 4-74 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ จากค่า R² สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์
แบบรายฤดูกาล

สถาน การณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	0.46675	0.70921	0.67405	0.54509	0.54719	0.54823	0.07249	0.80356	0.66143	0.44583	0.62646	0.57560	0.42134	0.76491	0.62785	0.68294	0.71631	0.71434
2	0.37212	0.59311	0.44978	0.54249	0.67549	0.67407	0.04819	0.75551	0.73803	0.69161	0.77804	0.72014	0.25657	0.40709	0.34941	0.64466	0.65087	0.64893
3	0.35231	0.68502	0.58595	0.58440	0.63028	0.66497	0.01782	0.75401	0.73203	0.78119	0.78164	0.79200	0.37732	0.48624	0.45505	0.49306	0.50447	0.49718
4	0.17703	0.66973	0.64552	0.59281	0.66021	0.63831	0.03068	0.73667	0.68000	0.20656	0.79716	0.32181	0.22407	0.55424	0.52021	0.49537	0.54214	0.54148
5	0.17752	0.62777	0.60679	0.65863	0.67987	0.68973	0.00671	0.67295	0.64709	0.22289	0.39384	0.28800	0.18247	0.55776	0.55339	0.55129	0.59087	0.57423

หมายเหตุ: M1 แทน Asadi-GA-ANN
M2 แทน Asadi-GA(New)-ANN
M3 แทน Asadi-GA-BPNN
M4 แทน Wang-GA-ANN
M5 แทน Wang-GA(New)-ANN
M6 แทน Wang-GA-BPNN

จากตารางที่ 4-74 แสดงให้เห็นว่า ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ เมื่อพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า R²

ตารางที่ 4-75 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ
สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล

สถานการณ์	ฤดูร้อน						ฤดูฝน						ฤดูหนาว					
	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6	M1	M2	M3	M4	M5	M6
1	x	✓	x	x	x	x	x	✓	x	x	x	x	x	✓	x	x	✓	✓
2	x	x	x	x	x	x	x	✓	✓	x	✓	✓	x	x	x	x	x	x
3	x	x	x	x	x	x	x	✓	✓	✓	✓	✓	x	x	x	x	x	x
4	x	x	x	x	x	x	x	✓	x	x	✓	x	x	x	x	x	x	x
5	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x

หมายเหตุ: ✓ หมายถึงตัวแบบพยากรณ์มีค่า R^2 มากกว่า 0.7

x หมายถึงตัวแบบพยากรณ์มีค่า R^2 ไม่เกิน 0.7

M1 แทน Asadi-GA-ANN

M2 แทน Asadi-GA(New)-ANN

M3 แทน Asadi-GA-BPNN

M4 แทน Wang-GA-ANN

M5 แทน Wang-GA(New)-ANN

M6 แทน Wang-GA-BPNN

จากตารางที่ 4-75 ผลการประเมินประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ทั้ง 6 ตัวแบบ สำหรับชุดการทดสอบ ภายใต้ข้อมูล 5 สถานการณ์ แบบรายฤดูกาล (ฤดูร้อน ฤดูฝน ฤดูหนาว) มีทั้งหมด 15 สถานการณ์ สรุปได้ว่า

M1 ไม่มีสถานการณ์ใดที่มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 0 ของสถานการณ์ทั้งหมด

M2 มี 6 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 40 ของสถานการณ์ทั้งหมด

M3 มี 2 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 13.33 ของสถานการณ์ทั้งหมด

M4 มี 1 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 6.67 ของสถานการณ์ทั้งหมด

M5 มี 4 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 26.67 ของสถานการณ์ทั้งหมด

M6 มี 3 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 20 ของสถานการณ์ทั้งหมด

นั่นคือ M2 มีประสิทธิภาพความแม่นยำที่ดีมากที่สุดใน 6 สถานการณ์คือ ฤดูร้อน สำหรับขนาดข้อมูล 300 ฤดูฝน สำหรับขนาดข้อมูล 300 400 500 และ 1000 ฤดูหนาว สำหรับขนาดข้อมูล 300 รองลงมาคือ M5 มีประสิทธิภาพความแม่นยำที่ดีใน 4 สถานการณ์คือ ฤดูฝน สำหรับขนาดข้อมูล 400 500 และ 1000 ฤดูหนาว สำหรับขนาดข้อมูล 300 M6 มีประสิทธิภาพความแม่นยำที่ดีใน 3 สถานการณ์คือ ฤดูฝน สำหรับขนาดข้อมูล 400 และ 500 ฤดูหนาว สำหรับขนาดข้อมูล 300 M3 มีประสิทธิภาพความแม่นยำที่ดีใน 2 สถานการณ์คือ ฤดูฝน สำหรับขนาดข้อมูล 400 และ 500

M4 มีประสิทธิภาพความแม่นยำที่ดีใน 1 สถานการณ์คือ ฤดูฝน สำหรับขนาดข้อมูล 500 ตามลำดับ แต่ส่วน M1 มีประสิทธิภาพความแม่นยำที่ไม่ดีในทุกสถานการณ์

กล่าวโดยสรุปว่า ทั้งชุดการเรียนรู้และชุดการทดสอบ ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าที่ใช้การคัดเลือกแบบเดิมของวิธี GA ทุกสถานการณ์ ซึ่งเป็นไปตามสมมติฐานในการวิจัยข้อที่ 1 คือ ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมร่วมกับการคัดเลือกแบบแข่งขันของวิธี GA ที่พัฒนาขึ้นมีความแม่นยำสูงกว่า Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้อข้อมูล 5 สถานการณ์

ตอนที่ 3 ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA

การวิจัยนี้ใช้ข้อมูลจริงของจังหวัดในภาคกลางเก็บรวบรวมจาก NCEP-NOAA (NOAA NCEP-NCAR, 2019) ตั้งแต่ปี พ.ศ. 2532-2561 ขนาดข้อมูลเท่ากับ 360 จำนวน เพื่อพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 แบบรายฤดูกาล ประกอบด้วยข้อมูลนำเข้าจำนวน 7 ตัวแปรได้แก่ ความชื้นสัมพัทธ์ของอากาศ (Relative Humidity) (x_1) ความเร็วลม (Wind Speed) และทิศทางลม (Wind Direction) ในแนวตะวันออก-ตะวันตก (Zonal Wind) (ความเร็วลมตามแนวแกน x) (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (Meridional Wind) (ความเร็วลมตามแนวแกน y) (x_3) การระเหย (Evaporation) ของน้ำ (x_4) อุณหภูมิอากาศ (Air Temperature) สูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และอุณหภูมิอากาศเฉลี่ย (x_7) ข้อมูลส่งออกจำนวน 1 ตัวแปรคือ ปริมาณน้ำฝนในภาคกลางของประเทศไทย (y)

การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมร่วมกับการคัดเลือกแบบแข่งขันของวิธี GA ที่พัฒนาขึ้นของ Wang et al. (2017) เรียกว่าตัวแบบ Wang-GA(New)-ANN เพราะเป็นตัวแบบพยากรณ์ที่มีความแม่นยำมากที่สุดของขนาดข้อมูล 400 จำนวน พิจารณาขนาดข้อมูล 400 จำนวน เนื่องจากมีขนาดข้อมูลใกล้เคียงกับข้อมูลจริงที่นำมาใช้ในการพยากรณ์ จากตารางที่ 4-21 และตารางที่ 4-22 ในฤดูร้อน (หน้า 137-138) ตารางที่ 4-23 และตารางที่ 4-24 ในฤดูฝน (หน้า 139-140) ตารางที่ 4-25 และตารางที่ 4-26 ในฤดูหนาว (หน้า 141-142) ตัวแบบพยากรณ์ Wang-GA(New)-ANN มีความแม่นยำมากที่สุด ดังนั้นจึงเลือกตัวแบบพยากรณ์ Wang-GA(New)-ANN สำหรับนำไปใช้ในการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย

ลักษณะข้อมูลพื้นฐานแสดงดังตารางที่ 4-76 ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัว จำแนกตามฤดูกาล และผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 แบบรายฤดูกาล (ตารางที่ 4-77) ได้แก่ 1) ฤดูร้อน คือ เดือนกุมภาพันธ์ มีนาคม เมษายน และพฤษภาคม 2) ฤดูฝน คือ เดือนมิถุนายน กรกฎาคม สิงหาคม และกันยายน และ 3) ฤดูหนาว คือ เดือนตุลาคม พฤศจิกายน ธันวาคม และมกราคม โดยพิจารณาความแม่นยำของการพยากรณ์จากค่า MAE MAPE RMSE และ R^2 โดยที่ค่า MAE MAPE และ RMSE ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามีความแม่นยำในการพยากรณ์ ส่วนค่า R^2 ต้องมีค่ามาก ๆ เข้าใกล้ 1 และควรมากกว่า 0.7 (สถาบันพัฒนาการชลประทาน, 2551) จึงถือว่ามีความแม่นยำในการพยากรณ์

ตารางที่ 4-76 ค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัวจำแนกตามฤดู

ตัวแปร	ค่าต่ำสุด			ค่าสูงสุด			ค่าเฉลี่ย			ส่วนเบี่ยงเบนมาตรฐาน		
	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว	ร้อน	ฝน	หนาว
y	1.43	5.21	0.76	9.88	17.02	8.15	5.75	11.47	3.68	1.69	1.93	1.25
x_1	22.35	23.23	24.75	81.20	82.98	82.45	60.61	59.56	60.09	11.63	13.16	13.59
x_2	-1.24	0.39	-2.38	1.12	4.66	-0.29	-0.04	1.44	-1.46	0.49	0.80	0.46
x_3	-0.32	0.21	-2.51	2.13	2.12	0.61	0.73	0.86	-0.88	0.38	0.35	0.60
x_4	5.92	4.18	4.44	24.82	9.94	14.72	12.39	5.41	9.15	3.43	0.98	2.09
x_5	26.85	25.50	25.02	37.33	30.02	31.32	31.48	27.31	28.19	1.81	0.76	1.29
x_6	17.79	19.85	12.04	26.71	26.32	25.12	21.65	22.94	19.13	2.06	1.39	2.75
x_7	20.56	22.96	18.12	29.60	27.08	26.76	26.10	24.82	23.01	1.36	0.94	1.86

ตารางที่ 4-76 แสดงค่าสถิติพื้นฐานของข้อมูลตัวแปรแต่ละตัวจำแนกตามฤดูดังนี้ ปริมาณน้ำฝนมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 11.47 มิลลิเมตร และมีส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.93 มิลลิเมตร ความชื้นสัมพัทธ์ของอากาศมีค่าเฉลี่ยสูงสุดในฤดูร้อนคิดเป็นร้อยละ 60.61 และส่วนเบี่ยงเบนมาตรฐานร้อยละ 11.63 ความเร็วลมตามแนวแกน x มีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ 1.44 เมตรต่อวินาที และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.80 เมตรต่อวินาที ความเร็วลมตามแนวแกน y มีค่าเฉลี่ยสูงสุดในฤดูหนาวเท่ากับ 0.88 เมตรต่อวินาทีและส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.60 เมตรต่อวินาที การระเหยของน้ำมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 12.39 มิลลิเมตร และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 3.43 มิลลิเมตร อุณหภูมิอากาศสูงสุดมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 31.48 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.81 °C อุณหภูมิอากาศต่ำสุดมีค่าเฉลี่ยสูงสุดในฤดูฝนเท่ากับ

22.94 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.39 °C และอุณหภูมิอากาศเฉลี่ยมีค่าเฉลี่ยสูงสุดในฤดูร้อนเท่ากับ 26.10 °C และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.36 °C

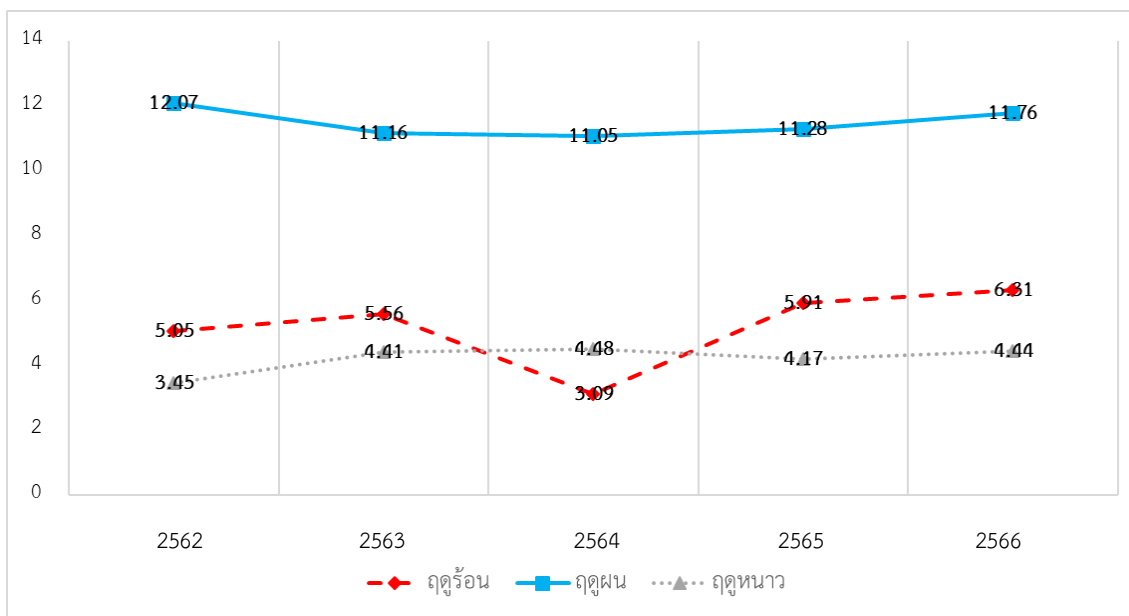
ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 แบบรายฤดูกาล แสดงดังตารางที่ 4-77 และภาพที่ 4-2

ตารางที่ 4-77 ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 แบบรายฤดูกาล

พ.ศ.	ปริมาณน้ำฝน (มิลลิเมตร)		
	ฤดูร้อน (Summer)	ฤดูฝน (Rainy)	ฤดูหนาว (Winter)
2562	5.05	12.07	3.45
2563	5.56	11.16	4.41
2564	3.09	11.05	4.48
2565	5.91	11.28	4.17
2566	6.31	11.76	4.44
ฤดูร้อน:	MAE _{Summer} = 0.41990, MAPE _{Summer} = 0.10852, RMSE _{Summer} = 0.54386, R ² _{Summer} = 0.89957		
ฤดูฝน:	MAE _{Rainy} = 0.36477, MAPE _{Rainy} = 0.03294, RMSE _{Rainy} = 0.49593, R ² _{Rainy} = 0.89700		
ฤดูหนาว:	MAE _{Winter} = 0.27802, MAPE _{Winter} = 0.07042, RMSE _{Winter} = 0.36774, R ² _{Winter} = 0.91432		

จากตารางที่ 4-77 ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี แบบรายฤดูกาล ปรากฏว่า ฤดูร้อนปริมาณน้ำฝนมากที่สุดในปี พ.ศ. 2566 เท่ากับ 6.31 มิลลิเมตร รองลงมาคือ พ.ศ. 2565 เท่ากับ 5.91 มิลลิเมตร พ.ศ. 2563 เท่ากับ 5.56 มิลลิเมตร และ พ.ศ. 2562 เท่ากับ 5.05 มิลลิเมตร ตามลำดับ น้อยที่สุดในปี พ.ศ. 2564 เท่ากับ 3.09 มิลลิเมตร โดยมีค่า MAE_{Summer} เท่ากับ 0.41990 ค่า MAPE_{Summer} เท่ากับ 0.10852 ค่า RMSE_{Summer} เท่ากับ 0.54386 และค่า R²_{Summer} เท่ากับ 0.89957 ฤดูฝนปริมาณน้ำฝนมากที่สุดในปี พ.ศ. 2562 เท่ากับ 12.07 มิลลิเมตร รองลงมาคือ พ.ศ. 2566 เท่ากับ 11.76 มิลลิเมตร พ.ศ. 2565 เท่ากับ 11.28 มิลลิเมตร และ พ.ศ. 2563 เท่ากับ 11.16 มิลลิเมตร ตามลำดับ น้อยที่สุดในปี พ.ศ. 2564 เท่ากับ 11.05 มิลลิเมตร โดยมีค่า MAE_{Rainy} เท่ากับ 0.36477 ค่า MAPE_{Rainy} เท่ากับ 0.03294 ค่า RMSE_{Rainy} เท่ากับ 0.49593 และค่า R²_{Rainy} เท่ากับ 0.89700 และฤดูหนาวปริมาณน้ำฝนมากที่สุดในปี พ.ศ. 2564 เท่ากับ 4.48 มิลลิเมตร รองลงมาคือ พ.ศ. 2566 เท่ากับ 4.44 มิลลิเมตร พ.ศ. 2563 เท่ากับ 4.41 มิลลิเมตร และ พ.ศ. 2565 เท่ากับ 4.17 มิลลิเมตร ตามลำดับ น้อยที่สุดในปี พ.ศ. 2462 เท่ากับ 3.45 มิลลิเมตร โดยมีค่า MAE_{Winter} เท่ากับ 0.27802 ค่า MAPE_{Winter} เท่ากับ 0.07042

ค่า $RMSE_{Winter}$ เท่ากับ 0.36774 และค่า R^2_{Winter} เท่ากับ 0.91432 ดังนั้นตัวแบบ Wang-GA(New)-ANN สามารถพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี แบบรายฤดูกาลได้อย่างแม่นยำ



ภาพที่ 4-2 ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 แบบรายฤดูกาล

เมื่อพิจารณาผลการพยากรณ์ปริมาณน้ำฝนตามตำแหน่งในภาคกลางของประเทศไทย 12 ตำแหน่ง ได้แก่ 1) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 12.3808 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 99.375 องศาตะวันออก 2) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 14.2855 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 99.375 องศาตะวันออก 3) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 16.1902 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 99.375 องศาตะวันออก 4) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 18.095 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 99.375 องศาตะวันออก 5) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 12.3808 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 101.25 องศาตะวันออก 6) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 14.2855 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 101.25 องศาตะวันออก 7) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 16.1902 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 101.25 องศาตะวันออก 8) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 18.095 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 101.25 องศาตะวันออก 9) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 12.3808 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 103.125 องศาตะวันออก 10) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด

14.2855 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 103.125 องศาตะวันออก 11) ตำแหน่งพิกัดทาง
 ภูมิศาสตร์ที่ละติจูด 16.1902 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 103.125 องศาตะวันออก และ
 12) ตำแหน่งพิกัดทางภูมิศาสตร์ที่ละติจูด 18.095 องศาเหนือ และมีตำแหน่งลองจิจูดที่ 103.125
 องศาตะวันออก

ผลการพยากรณ์ปริมาณน้ำฝนตามตำแหน่งในภาคกลางของประเทศไทยจำนวน 5 ปี
 แบบรายฤดูกาล ปรากฏว่า ฤดูร้อนปริมาณน้ำฝนมากที่สุดในพ.ศ. 2566 เท่ากับ 75.77 มิลลิเมตร
 และน้อยที่สุดในพ.ศ. 2564 เท่ากับ 37.10 มิลลิเมตร เมื่อพิจารณาตามตำแหน่งพบว่า พ.ศ. 2562
 ตำแหน่งที่ 12 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 4 ในพ.ศ. 2563 ตำแหน่งที่ 10
 ปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 5 ในพ.ศ. 2564 ตำแหน่งที่ 12 มีปริมาณน้ำฝน
 มากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 5 ในพ.ศ. 2565 ตำแหน่งที่ 11 มีปริมาณน้ำฝนมากที่สุด และ
 น้อยที่สุดที่ตำแหน่งที่ 5 และพ.ศ. 2566 ตำแหน่งที่ 10 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่
 ตำแหน่งที่ 5 ฤดูฝนปริมาณน้ำฝนมากที่สุดในพ.ศ. 2562 เท่ากับ 144.78 มิลลิเมตร และน้อยที่สุดใน
 พ.ศ. 2564 เท่ากับ 132.55 มิลลิเมตร เมื่อพิจารณาตามตำแหน่งพบว่า พ.ศ. 2562 ตำแหน่งที่ 5
 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 4 ในพ.ศ. 2563 ตำแหน่งที่ 1 ปริมาณน้ำฝนมาก
 ที่สุด และน้อยที่สุดที่ตำแหน่งที่ 5 ในพ.ศ. 2564 ตำแหน่งที่ 1 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุด
 ที่ตำแหน่งที่ 5 ในพ.ศ. 2565 ตำแหน่งที่ 1 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 4
 และพ.ศ. 2566 ตำแหน่งที่ 2 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 5 ฤดูหนาวปริมาณ
 น้ำฝนมากที่สุดในพ.ศ. 2564 เท่ากับ 53.81 มิลลิเมตร และน้อยที่สุดในพ.ศ. 2562 เท่ากับ 41.43
 มิลลิเมตร เมื่อพิจารณาตามตำแหน่งพบว่า พ.ศ. 2562 ตำแหน่งที่ 1 มีปริมาณน้ำฝนมากที่สุด และ
 น้อยที่สุดที่ตำแหน่งที่ 8 ในพ.ศ. 2563 ตำแหน่งที่ 1 ปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่ง
 ที่ 4 ในพ.ศ. 2564 ตำแหน่งที่ 1 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 12 ในพ.ศ.
 2565 ตำแหน่งที่ 1 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 12 และพ.ศ. 2566
 ตำแหน่งที่ 1 มีปริมาณน้ำฝนมากที่สุด และน้อยที่สุดที่ตำแหน่งที่ 4 ดังตารางที่ 4-78

ตารางที่ 4-78 ผลการพยากรณ์ปริมาณน้ำฝนตามตำแหน่งในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปีพ.ศ. 2562-2566 แบบรายฤดูกาล

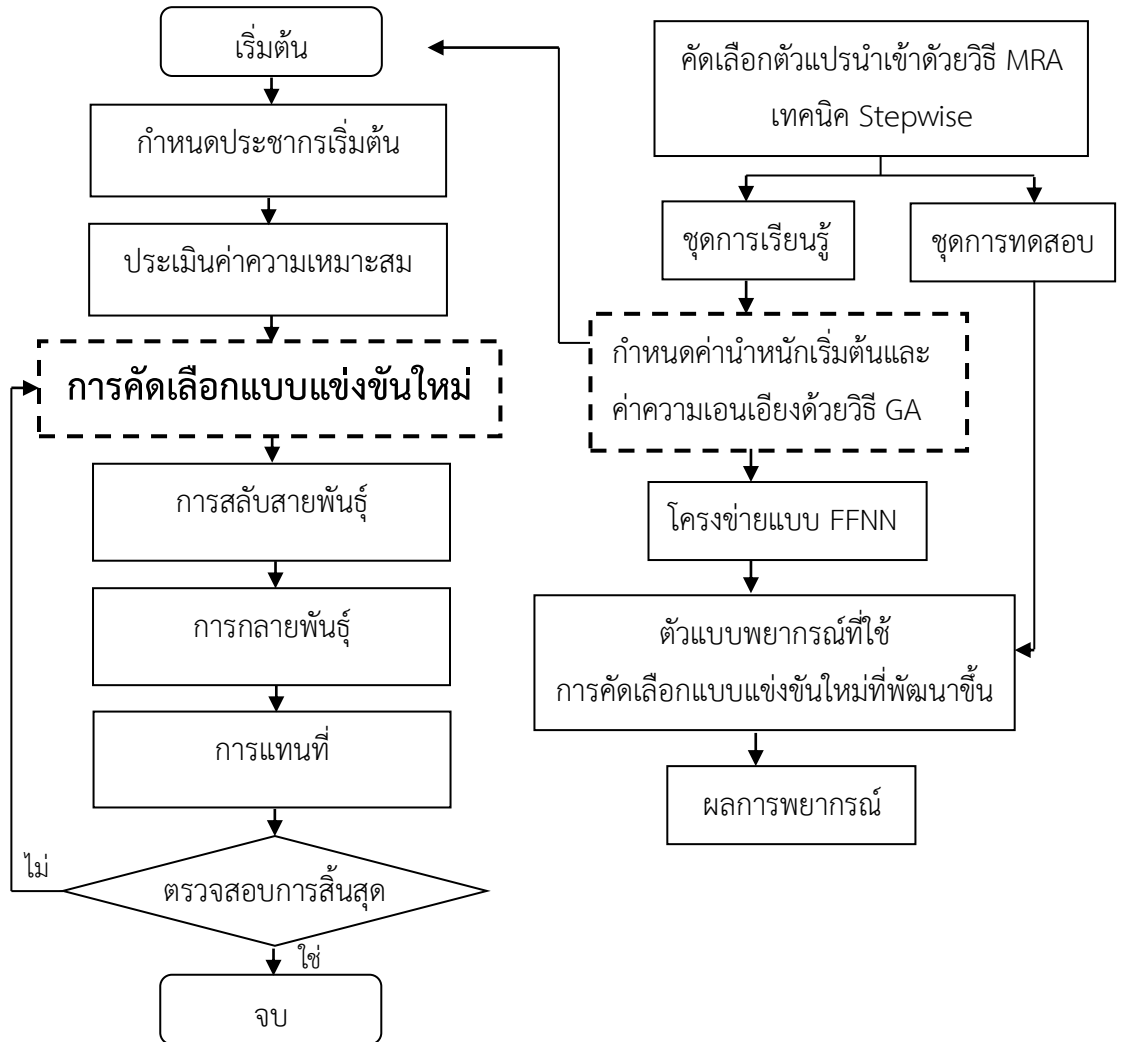
ตำแหน่ง	ปริมาณน้ำฝนตามตำแหน่งในภาคกลางพ.ศ. 2562-2566														
	พ.ศ. 2562			พ.ศ. 2563			พ.ศ. 2564			พ.ศ. 2565			พ.ศ. 2566		
	ฤดูร้อน	ฤดูฝน	ฤดูหนาว	ฤดูร้อน	ฤดูฝน	ฤดูหนาว	ฤดูร้อน	ฤดูฝน	ฤดูหนาว	ฤดูร้อน	ฤดูฝน	ฤดูหนาว	ฤดูร้อน	ฤดูฝน	ฤดูหนาว
1	6.16	13.76	5.44	6.49	13.75	6.11	3.13	14.68	6.32	6.76	13.68	6.41	6.96	13.68	7.20
2	4.42	13.47	4.51	5.21	13.41	5.33	1.97	11.74	6.15	5.61	12.67	5.51	6.17	14.01	5.88
3	4.07	12.15	3.03	4.20	11.72	3.68	1.97	10.87	4.27	4.23	11.20	3.88	4.84	12.35	3.91
4	3.10	10.73	2.49	3.54	9.93	2.59	2.41	9.86	3.54	4.66	9.85	2.95	5.33	10.83	2.90
5	3.25	14.04	3.19	3.29	6.00	3.28	1.61	7.16	3.40	2.87	10.66	3.91	4.44	5.59	3.59
6	5.39	10.77	4.52	6.74	11.31	5.86	1.93	10.33	5.49	6.18	10.72	5.28	7.22	12.53	5.87
7	5.28	11.27	3.10	6.10	11.26	4.64	2.94	9.92	3.99	6.54	11.10	3.19	7.06	12.02	3.73
8	5.62	11.33	2.00	5.37	10.74	2.86	3.75	11.29	3.07	6.15	10.99	2.95	7.18	11.33	3.16
9	5.47	12.80	4.57	5.78	12.09	5.47	3.35	13.11	5.66	5.93	11.21	5.14	6.98	11.54	5.48
10	5.48	11.38	3.46	6.95	11.13	5.32	3.46	11.53	4.90	7.41	10.87	4.40	7.28	12.81	4.77
11	5.96	11.53	2.77	6.86	11.57	4.36	5.16	11.05	3.96	7.89	11.56	3.64	6.52	12.78	3.47
12	6.35	11.55	2.34	6.17	11.04	3.36	5.41	11.01	3.06	6.73	10.89	2.77	5.79	11.64	3.27
รวม	60.55	144.78	41.43	66.70	133.95	52.86	37.10	132.55	53.81	70.96	135.40	50.03	75.77	141.11	53.23

กล่าวโดยสรุปว่า การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันใหม่ที่พัฒนาขึ้นของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม คือ ตัวแบบ Wang-GA(New)-ANN สามารถพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย แบบรายฤดูกาล ได้อย่างแม่นยำมีค่า R^2 มากกว่า 0.7 ทุกฤดูกาล ซึ่งเป็นไปตามสมมติฐานในการวิจัยข้อที่ 2 คือ การพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA สามารถพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยที่มีค่า R^2 มากกว่า 0.7

และจากการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียมนี้ ทำให้ได้ตัวแบบพยากรณ์ใหม่ทั้งสิ้น 4 ตัวแบบที่แบ่งตามตำแหน่งของการใช้วิธี GA ได้แก่ การกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม และการปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับ ดังนี้

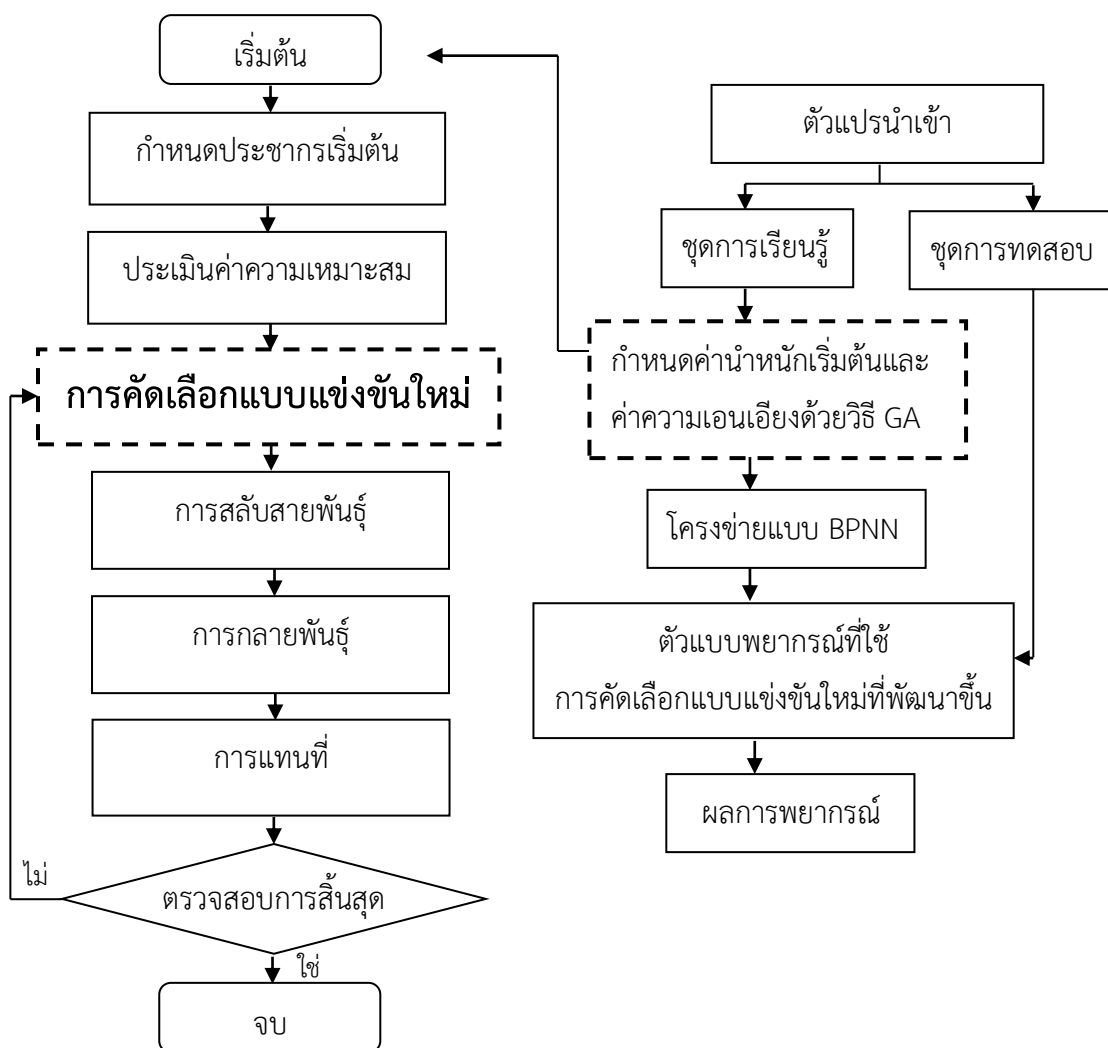
การกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียมด้วยวิธี GA ที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นคือ

1. ตัวแบบ Asadi-GA(New)-ANN



ภาพที่ 4-3 รูปแบบการทำงานตัวแบบ Asadi-GA(New)-ANN

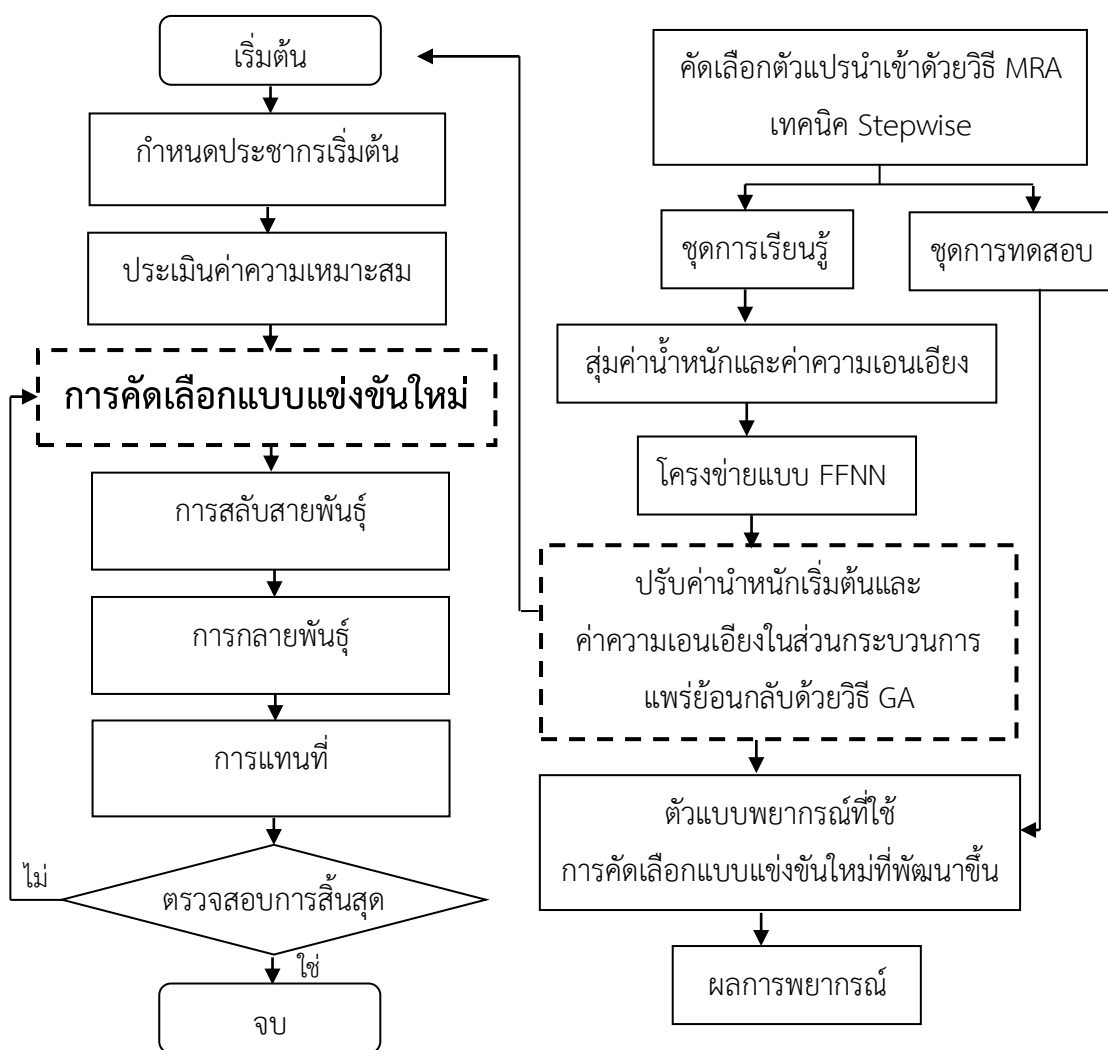
2. ตัวแบบ Wang-GA(New)-ANN



ภาพที่ 4-4 รูปแบบการทำงานตัวแบบ Wang-GA(New)-ANN

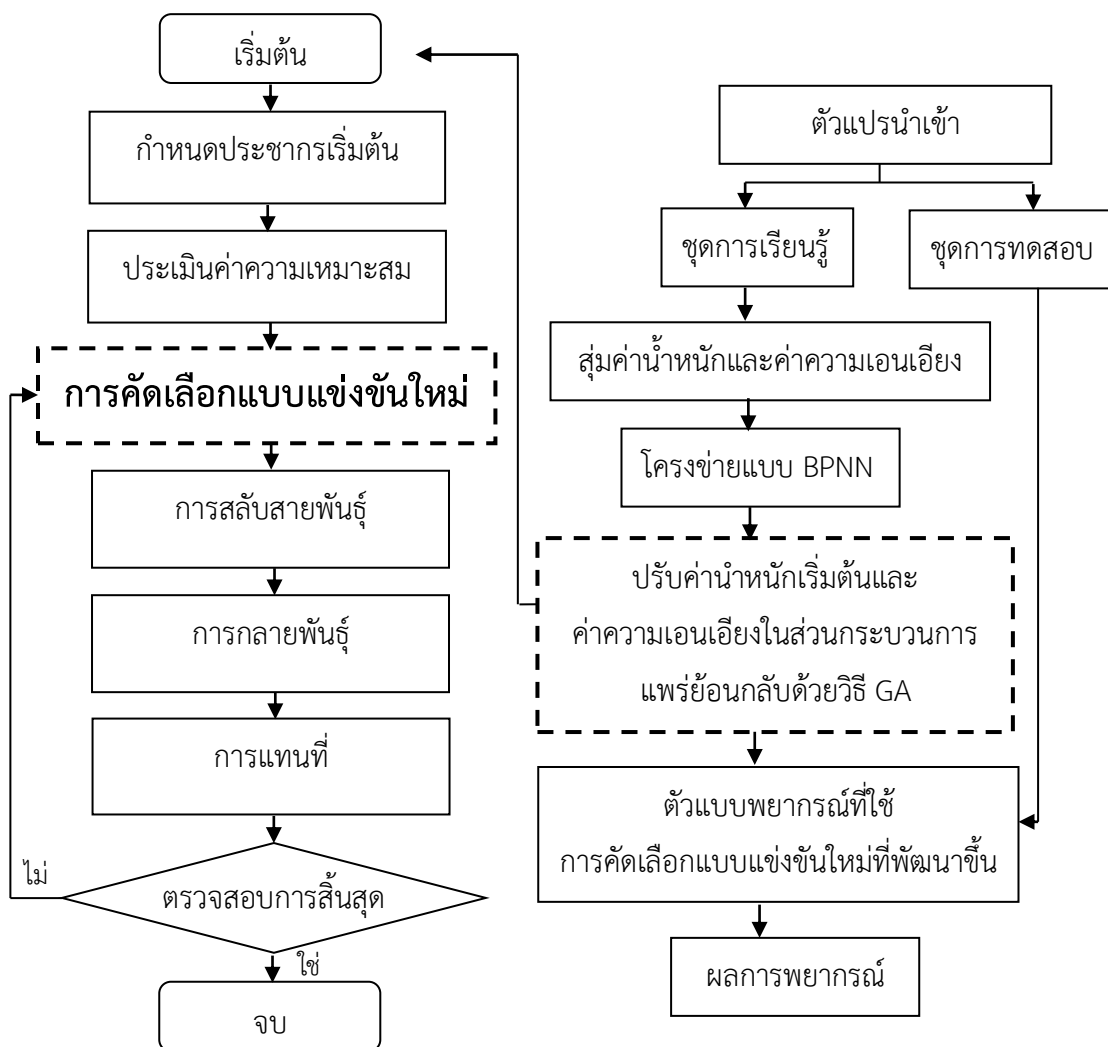
การปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสม
ในส่วนกระบวนการแพร่ย้อนกลับด้วยวิธี GA ที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นคือ

1. ตัวแบบ Asadi-GA-BPNN



ภาพที่ 4-5 รูปแบบการทำงานตัวแบบ Asadi-GA-BPNN

2. ตัวแบบ Wang-GA-BPNN



ภาพที่ 4-6 รูปแบบการทำงานตัวแบบ Wang-GA-BPNN

บทที่ 5

สรุปและอภิปรายผล

การวิจัยนี้เป็นการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm: GA) สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ใช้หลักการ Normalized Geometric Ranking (NGR) (Joines & Houck, 1994) หลักการคัดเลือกแบบวงล้อรูเล็ตต์ (RWS) (Yu et al., 2016) และหลักการคัดเลือกแบบแข่งขัน (TS) (Goldberg & Deb, 1991)

จากนั้นเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi et al. (2013) และ Wang et al. (2017) ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม โดยเปรียบเทียบจากค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ที่ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามีความแม่นยำในการพยากรณ์ และค่าสัมประสิทธิ์ตัวกำหนด (Coefficient of Determination: R^2) ต้องมีค่ามาก ๆ เข้าใกล้ 1 และควรมากกว่า 0.7 (สถาบันพัฒนาการชลประทาน, 2551) จึงถือว่ามีความแม่นยำในการพยากรณ์ จากข้อมูล 5 สถานการณ์ ดังนี้

สถานการณ์ที่ 1 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้ข้อมูลขนาด 300 จำนวน

สถานการณ์ที่ 2 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้ข้อมูลขนาด 400 จำนวน

สถานการณ์ที่ 3 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้ข้อมูลขนาด 500 จำนวน

สถานการณ์ที่ 4 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ

Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้ข้อมูลขนาด 1000 จำนวน

สถานการณ์ที่ 5 ตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN Asadi-GA-BPNN และ Asadi-GA-ANN และตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN Wang-GA-BPNN และ Wang-GA-ANN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมของวิธี GA ภายใต้ข้อมูลขนาด 1100 จำนวน

และนำตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA ไปพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย แบบรายฤดูกาล ได้แก่ ได้แก่ 1) ฤดูร้อน คือ เดือนกุมภาพันธ์ มีนาคม เมษายน และพฤษภาคม 2) ฤดูฝน คือ เดือนมิถุนายน กรกฎาคม สิงหาคม และกันยายน และ 3) ฤดูหนาว คือ เดือนตุลาคม พฤศจิกายน ธันวาคม มกราคม สำหรับการวิจัยนี้ใช้ข้อมูลจริงของจังหวัดในภาคกลางเก็บรวบรวมจาก NCEP-NOAA (NOAA NCEP-NCAR, 2019) ตั้งแต่ปี พ.ศ. 2532-2561 ขนาดข้อมูลเท่ากับ 360 จำนวน เพื่อพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 แบบรายฤดูกาล ประกอบด้วยข้อมูลนำเข้าจำนวน 7 ตัวแปรได้แก่ ความชื้นสัมพัทธ์ของอากาศ (Relative Humidity) (x_1) ความเร็วลม (Wind Speed) และทิศทางลม (Wind Direction) ในแนวตะวันออก-ตะวันตก (Zonal Wind) (ความเร็วลมตามแนวแกน x) (x_2) ความเร็วลมและทิศทางลมในแนวเหนือ-ใต้ (Meridional Wind) (ความเร็วลมตามแนวแกน y) (x_3) การระเหย (Evaporation) ของน้ำ (x_4) อุณหภูมิอากาศ (Air Temperature) สูงสุด (x_5) อุณหภูมิอากาศต่ำสุด (x_6) และอุณหภูมิอากาศเฉลี่ย (x_7) ข้อมูลส่งออกจำนวน 1 ตัวแปรคือ ปริมาณน้ำฝนในภาคกลางของประเทศไทย (y) โดยพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE MAPE RMSE และ R^2 โดยที่ค่า MAE MAPE และ RMSE ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามีความแม่นยำในการพยากรณ์ ส่วนค่า R^2 ต้องมีค่ามาก ๆ เข้าใกล้ 1 และควรมากกว่า 0.7 (สถาบันพัฒนาการชลประทาน, 2551) จึงถือว่ามีความแม่นยำในการพยากรณ์

สรุปผลการวิจัย

1. ผลการพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA สำหรับพยากรณ์โดยใช้โครงข่ายประสาทเทียม

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรมสำหรับการพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม ประกอบด้วย

- หลักการ NGR (Joines & Houck, 1994) เพื่อให้ได้ค่าลำดับ ผลที่ได้จากหลักการนี้คือค่าลำดับของค่าการแจกแจงปกติของค่าความเหมาะสมของโครโมโซมแต่ละตัว

- หลักการ RWS (Yu et al., 2016) เพื่อให้ได้ค่าความน่าจะเป็นของแต่ละโครโมโซมโดยใช้ค่าความเหมาะสม ผลที่ได้จากหลักการนี้คือ ค่าความน่าจะเป็นของค่าความเหมาะสมของแต่ละโครโมโซม

- หลักการ TS (Goldberg & Deb, 1991) เพื่อคัดเลือกโครโมโซมที่ดีและตัดโครโมโซมที่ไม่ดีออกไป โดยกำหนดจำนวนของการแข่งขันในแต่ละแถวเท่ากับ s ซึ่งมีค่าเท่ากับจำนวนเส้นเชื่อมต่อระหว่างโหนดทั้งหมดของโครงข่ายประสาทเทียมและกำหนดจำนวนแถวเท่ากับ n ซึ่งมีค่าเท่ากับจำนวนโครโมโซมที่เป็นขนาดของประชากร จากหลักการ Normalized Geometric Ranking (Joines & Houck, 1994) และหลักการคัดเลือกแบบวงล้อรูเล็ต (Yu et al., 2016) นำผลลัพธ์ที่ได้จากหลักการทั้งสองมาคูณกันเพื่อให้ได้ค่าความน่าจะเป็นที่แท้จริง (Real Probabilities) ของโครโมโซมแต่ละตัว จากนั้นนำค่าความน่าจะเป็นที่แท้จริงเข้าสู่การคัดเลือกแบบแข่งขัน เพื่อคัดเลือกโครโมโซมที่ดีหรือค่าน้ำหนักที่เหมาะสมของแต่ละเส้นเชื่อมเข้าสู่กระบวนการการสลับสายพันธุและการกลายพันธุ์ในขั้นตอนต่อไปของ GA ผลลัพธ์สุดท้ายทำให้ได้โครโมโซมที่ดีหรือค่าน้ำหนักที่เหมาะสมของแต่ละเส้นเชื่อมที่พร้อมนำไปใช้สร้างตัวแบบพยากรณ์ด้วยวิธีโครงข่ายประสาทเทียมต่อไป

2. ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม จากข้อมูล 5 สถานการณ์ (รายละเอียดในหน้า 207-208)

การเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิม ทั้ง 5 สถานการณ์ พิจารณาความแม่นยำจากค่า MAE MAPE RMSE ที่ต้องมีค่าน้อย ๆ เข้าใกล้ 0-1 จึงถือว่ามีความแม่นยำในการพยากรณ์ และค่า R^2 ต้องมีค่ามาก ๆ เข้าใกล้ 1 และควรมากกว่า 0.7 (สถาบันพัฒนาการชลประทาน, 2551) จึงถือว่ามีความแม่นยำในการพยากรณ์

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Asadi-GA(New)-ANN เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม ตัวแบบพยากรณ์ Asadi-GA-BPNN เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียมและตัวแบบพยากรณ์ Asadi-GA-ANN เมื่อใช้การคัดเลือกแบบเดิมของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม แบ่งเป็น 3 ฤดูกาล ได้แก่ ฤดูร้อน ฤดูฝน และฤดูหนาว โดยพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE MAPE RMSE และ R^2 ภายใต้อข้อมูล 5 สถานการณ์ พบว่า ตัวแบบพยากรณ์ Asadi-GA(New)-ANN และ Asadi-GA-BPNN ที่

ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าตัวแบบพยากรณ์ Asadi-GA-ANN ที่ใช้การคัดเลือกแบบเดิมของวิธี GA ในทุกสถานการณ์ ซึ่งเป็นไปตามสมมติฐานการวิจัยข้อ 1

ผลการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมของ Wang-GA(New)-ANN เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม ตัวแบบพยากรณ์ Wang-GA-BPNN เมื่อใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA เพื่อปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียม และตัวแบบพยากรณ์ Wang-GA-ANN เมื่อใช้การคัดเลือกแบบเดิมของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม แบ่งเป็น 3 ฤดูกาล ได้แก่ ฤดูร้อน ฤดูฝน และฤดูหนาว โดยพิจารณาความแม่นยำของตัวแบบพยากรณ์จากค่า MAE MAPE RMSE และ R^2 ภายใต้อข้อมูล 5 สถานการณ์ พบว่า ตัวแบบพยากรณ์ Wang-GA(New)-ANN และ Wang-GA-BPNN ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าตัวแบบพยากรณ์ Wang-GA-ANN ที่ใช้การคัดเลือกแบบเดิมของวิธี GA ในทุกสถานการณ์ ซึ่งเป็นไปตามสมมติฐานการวิจัยข้อ 1

3. ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA

ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยแบบรายฤดูกาลจำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 จากตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA คือ ตัวแบบ Wang-GA(New)-ANN ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยจำนวน 5 ปีแบบรายฤดูกาล ปรากฏว่า ฤดูร้อนปริมาณน้ำฝนมากที่สุดในปี พ.ศ. 2566 เท่ากับ 6.31 มิลลิเมตร และน้อยที่สุดในปี พ.ศ. 2564 เท่ากับ 3.09 มิลลิเมตร ฤดูฝนปริมาณน้ำฝนมากที่สุดในปี พ.ศ. 2562 เท่ากับ 12.07 มิลลิเมตร และน้อยที่สุดในปี พ.ศ. 2564 เท่ากับ 11.05 มิลลิเมตร และฤดูหนาวปริมาณน้ำฝนมากที่สุดในปี พ.ศ. 2564 เท่ากับ 4.48 มิลลิเมตร และน้อยที่สุดในปี พ.ศ. 2462 เท่ากับ 3.45 มิลลิเมตร ตัวแบบ Wang-GA(New)-ANN สามารถพยากรณ์ได้อย่างแม่นยำในทุกฤดูกาล โดยฤดูร้อนมีค่า MAE_{Summer} เท่ากับ 0.41990 ค่า $MAPE_{Summer}$ เท่ากับ 0.10852 ค่า $RMSE_{Summer}$ เท่ากับ 0.54386 และค่า R^2_{Summer} เท่ากับ 0.89957 ฤดูฝนมีค่า MAE_{Rainy} เท่ากับ 0.36477 ค่า $MAPE_{Rainy}$ เท่ากับ 0.03294 ค่า $RMSE_{Rainy}$ เท่ากับ 0.49593 และค่า R^2_{Rainy} เท่ากับ 0.89700 ฤดูหนาวมีค่า MAE_{Winter} เท่ากับ 0.27802 ค่า $MAPE_{Winter}$ เท่ากับ 0.07042 ค่า $RMSE_{Winter}$ เท่ากับ 0.36774 และค่า R^2_{Winter} เท่ากับ 0.91432 ซึ่งเป็นไปตามสมมติฐานการวิจัยข้อ 2 คือการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA สามารถพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยที่มีค่า R^2 มากกว่า 0.7 ดังนั้นถือว่า

ตัวแบบมีความแม่นยำในการพยากรณ์ สามารถนำไปใช้พยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยได้

อภิปรายผล

การวิจัยนี้เป็นการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (GA) สำหรับพยากรณ์ปริมาณน้ำฝนโดยใช้โครงข่ายประสาทเทียม การพัฒนาการคัดเลือกแบบแข่งขันของวิธี GA ใช้หลักการ NGR (Joines & Houck, 1994) หลักการ RWS (Yu et al., 2016) และหลักการ TS (Goldberg & Deb, 1991) ทำให้ได้กระบวนการคัดเลือกแบบใหม่ของวิธี GA โดยใช้ค่าความน่าจะเป็นที่แท้จริง (Real Probabilities) ของโครโมโซมแต่ละตัวที่ได้จากหลักการ NGR (Joines & Houck, 1994) และหลักการ RWS (Yu et al., 2016) จากนั้นเข้าสู่การคัดเลือกโครโมโซมด้วยหลักการ TS (Goldberg & Deb, 1991) เพื่อคัดเลือกโครโมโซมที่ดีที่สุดหรือค่าน้ำหนักที่เหมาะสมของแต่ละเส้นเชื่อมสำหรับนำไปใช้สร้างตัวแบบพยากรณ์ด้วยวิธีโครงข่ายประสาทเทียม ทั้งในส่วนของการใช้วิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม และใช้ในการปรับค่าน้ำหนักและค่าความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสมในส่วนของกระบวนการแพร่ย้อนกลับของโครงข่ายประสาทเทียม

การพิจารณาความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝนของภาคกลางในประเทศไทย แยกตามฤดูกาล (ฤดูร้อน ฤดูฝน และฤดูหนาว) ระหว่างตัวแบบโครงข่ายประสาทเทียมที่พัฒนาการคัดเลือกแบบแข่งขันของวิธี GA และตัวแบบโครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบเดิมของวิธี GA ผู้วิจัยพิจารณาจากค่า MAE MAPE RMSE และ R^2 จากข้อมูล 5 สถานการณ์ ผลการวิจัยแสดงชัดเจนว่า ตัวแบบพยากรณ์ Asadi-GA(New)-ANN และ Asadi-GA-BPNN มีประสิทธิภาพการพยากรณ์ที่แม่นยำกว่าตัวแบบ Asadi-GA-ANN ในส่วนของการนำขั้นตอนวิธี GA ที่มีการคัดเลือกแบบแข่งขันใหม่ที่พัฒนาขึ้นมากำหนดค่าน้ำหนักเริ่มต้นและความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดในโครงข่ายประสาทเทียม อีกทั้งยังมีการปรับค่าน้ำหนักและความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้มีความเหมาะสมมากยิ่งขึ้นในส่วนกระบวนการแพร่ย้อนกลับ (Saxena et al., 2014) ดังนั้นการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นดีกว่าการคัดเลือกแบบเดิม และนอกจากนี้ยังลดขั้นตอนการสร้างตัวแบบพยากรณ์ของ Asadi-GA(New)-ANN และ Asadi-GA-BPNN โดยนำวิธี K-means ออก เนื่องจากวิธี K-means ถูกใช้ในการจัดแบ่งกลุ่มข้อมูลนำเข้า เพื่อจำแนกและแยกแยะข้อมูลออกเป็นกลุ่ม ๆ ซึ่งพิจารณาตามรูปแบบของข้อมูลนำเข้า (ธนวุฒิ ประกอบผล, 2552; Chauhan et al., 2018; Haykin, 1999, pp. 65-66; Ramesh et al., 2011; Uddin et al., 2015) อาจจะไม่เหมาะสมด้วยลักษณะของข้อมูลในการนำมาใช้กับข้อมูลนำเข้าในการวิจัยนี้ การที่นำวิธี K-means ทำให้ขั้นตอนการสร้างตัวแบบพยากรณ์มีความซับซ้อนน้อยลง ใช้เวลาในการวิเคราะห์ข้อมูล

รวดเร็วขึ้น แต่ทำให้ประสิทธิภาพของการพยากรณ์มีความแม่นยำมากขึ้น และยังคงใช้วิธี MRA ที่ใช้เทคนิค Stepwise ร่วมสร้างตัวแบบพยากรณ์ เพื่อคัดเลือกตัวแปรนำเข้าของโครงข่าย (ทักษิณา คงสมลาภ และสมชาย เล็กเจริญ, 2560; อรณรงค์ บุเกตุ และพุทธิ ศิริแสงตระกูล, 2556; อัฒพล คุณเลิศ และพุทธิ ศิริแสงตระกูล, 2557) ซึ่งทำให้ตัวแบบ Asadi-GA(New)-ANN และ Asadi-GA-BPNN มีประสิทธิภาพการพยากรณ์ที่ดี สามารถนำไปใช้ในการพยากรณ์ปริมาณน้ำฝนได้อย่างแม่นยำ โดยตัวแปรนำเข้าที่ผ่านการคัดเลือกทุกสถานการณ์ในฤดูร้อนได้แก่ การระเหยของน้ำ และอุณหภูมิอากาศสูงสุด ฤดูฝนได้แก่ ความเร็วลมตามแนวแกน x การระเหยของน้ำ อุณหภูมิอากาศสูงสุด และอุณหภูมิอากาศต่ำสุด ฤดูหนาวได้แก่ ความเร็วลมตามแนวแกน x และอุณหภูมิอากาศต่ำสุด

ชุดการเรียนรู้มีค่า MAE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.51802 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนน้อยที่สุดเท่ากับ 0.54351 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.46518 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ค่า MAPE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.09134 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนน้อยที่สุดเท่ากับ 0.04839 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.14000 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ค่า RMSE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.65283 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนน้อยที่สุดเท่ากับ 0.69987 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.57647 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ค่า R^2 ในฤดูร้อนมากที่สุดเท่ากับ 0.81268 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนมากที่สุดเท่ากับ 0.88823 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวมากที่สุดเท่ากับ 0.75781 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ยิ่งไปกว่านั้นทุกสถานการณ์ตัวแบบ Asadi-GA(New)-ANN มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 100 ของสถานการณ์ทั้งหมด และตัวแบบ Asadi-GA-BPNN มีถึง 8 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 53.33 ของสถานการณ์ทั้งหมด

และชุดการทดสอบมีค่า MAE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.56689 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนน้อยที่สุดเท่ากับ 0.69410 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.43919 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ค่า MAPE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.09674 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนน้อยที่สุดเท่ากับ 0.06618 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.10665 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ค่า RMSE ในฤดูร้อนน้อยที่สุด

เท่ากับ 0.73673 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนน้อยที่สุด เท่ากับ 0.85318 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.55836 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ค่า R^2 ในฤดูร้อนมากที่สุดเท่ากับ 0.70921 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูฝนมากที่สุดเท่ากับ 0.80356 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ฤดูหนาวมากที่สุดเท่ากับ 0.76491 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Asadi-GA(New)-ANN ยิ่งไปกว่านั้นตัวแบบ Asadi-GA(New)-ANN มี 6 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 40 ของสถานการณ์ทั้งหมด ในฤดูฝนมากถึง 4 สถานการณ์คือ ขนาดข้อมูล 300 400 500 และ 1000 จำนวน นั่นคือ ตัวแบบ Asadi-GA(New)-ANN เหมาะกับการนำไปใช้ในฤดูฝนที่มีขนาดข้อมูลไม่เกิน 1000 จำนวน และตัวแบบ Asadi-GA-BPNN มี 2 สถานการณ์ในฤดูฝนของขนาดข้อมูล 400 และ 500 จำนวนที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 13.33 ของสถานการณ์ทั้งหมด นั่นคือ ตัวแบบ Asadi-GA-BPNN เหมาะกับการนำไปใช้ในฤดูฝนที่มีขนาดข้อมูลไม่เกิน 500 จำนวน

ในทำนองเดียวกันผลการวิจัยนี้แสดงชัดเจนว่า ตัวแบบพยากรณ์ Wang-GA(New)-ANN และ Wang-GA-BPNN มีประสิทธิภาพการพยากรณ์ที่แม่นยำกว่าตัวแบบ Wang-GA-ANN ในส่วนของการนำขั้นตอนวิธี GA ที่มีการคัดเลือกแบบแข่งขันใหม่ที่พัฒนาขึ้นมากำหนดค่าน้ำหนักเริ่มต้นและความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดในโครงข่ายประสาทเทียม อีกทั้งยังมีการปรับค่าน้ำหนักและความเอนเอียงของแต่ละเส้นเชื่อมต่อระหว่างโหนดให้มีความเหมาะสมมากยิ่งขึ้นในส่วนกระบวนการแพร่ย้อนกลับ (Saxena et al., 2014) ดังนั้นการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นดีกว่าการคัดเลือกแบบเดิม ดังนั้นตัวแบบ Wang-GA(New)-ANN และ Wang-GA-BPNN มีประสิทธิภาพการพยากรณ์ที่ดี สามารถนำไปใช้ในการพยากรณ์ปริมาณน้ำฝนได้อย่างแม่นยำ นอกจากนี้ยังสามารถนำตัวแบบ Wang-GA(New)-ANN ไปพยากรณ์ปริมาณน้ำฝนของภาคกลางในประเทศไทยแยกตามฤดูกาลได้อย่างมีประสิทธิภาพ

ชุดการเรียนรู้มีค่า MAE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.33013 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนน้อยที่สุดเท่ากับ 0.32962 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.27842 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ค่า MAPE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.05407 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนน้อยที่สุดเท่ากับ 0.02978 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.09213 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ค่า RMSE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.43114 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนน้อยที่สุดเท่ากับ 0.43291 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ

0.36270 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ค่า R^2 ในฤดูร้อนมากที่สุดเท่ากับ 0.91180 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนมากที่สุดเท่ากับ 0.95724 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวมากที่สุดเท่ากับ 0.91479 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ยิ่งไปกว่านั้นทุกสถานการณ์ทั้งตัวแบบ Wang-GA(New)-ANN และตัวแบบ Wang-GA-BPNN มีค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 100 ของสถานการณ์ทั้งหมด

และชุดการทดสอบมีค่า MAE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.56404 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนน้อยที่สุดเท่ากับ 0.73455 ของขนาดข้อมูล 400 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.41963 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Wang-GA-BPNN ค่า MAPE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.09504 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนน้อยที่สุดเท่ากับ 0.06689 ของขนาดข้อมูล 400 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.12034 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Wang-GA(New)-ANN ค่า RMSE ในฤดูร้อนน้อยที่สุดเท่ากับ 0.72241 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนน้อยที่สุดเท่ากับ 0.93195 ของขนาดข้อมูล 400 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวน้อยที่สุดเท่ากับ 0.53706 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Wang-GA(New)-ANN ค่า R^2 ในฤดูร้อนมากที่สุดเท่ากับ 0.68973 ของขนาดข้อมูล 1100 จำนวน จากตัวแบบ Wang-GA-BPNN ฤดูฝนมากที่สุดเท่ากับ 0.79716 ของขนาดข้อมูล 1000 จำนวน จากตัวแบบ Wang-GA(New)-ANN ฤดูหนาวมากที่สุดเท่ากับ 0.71631 ของขนาดข้อมูล 300 จำนวน จากตัวแบบ Wang-GA(New)-ANN ยิ่งไปกว่านั้นตัวแบบ Wang-GA(New)-ANN มี 4 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 26.67 ของสถานการณ์ทั้งหมด ในฤดูฝนมากถึง 3 สถานการณ์คือ ขนาดข้อมูล 300 400 และ 500 จำนวน นั่นคือ ตัวแบบ Wang-GA(New)-ANN เหมาะกับการนำไปใช้ในฤดูฝนที่มีขนาดข้อมูลไม่เกิน 500 จำนวน และตัวแบบ Wang-GA-BPNN มี 3 สถานการณ์ที่ค่า R^2 มากกว่า 0.7 คิดเป็นร้อยละ 20 ของสถานการณ์ทั้งหมด ในฤดูฝนมากมี 2 สถานการณ์คือ ขนาดข้อมูล 400 และ 500 จำนวน นั่นคือตัวแบบ Wang-GA-BPNN เหมาะกับการนำไปใช้ในฤดูฝนที่มีขนาดข้อมูลไม่เกิน 500 จำนวน

สรุปได้ว่า การพัฒนาคัดเลือกแบบแข่งขันของขั้นตอนวิธี GA ที่ใช้หลักการ NGR (Joines & Houck, 1994) หลักการ RWS (Yu et al., 2016) และหลักการ TS (Goldberg & Deb, 1991) ทำให้ได้วิธีการคัดเลือกแบบใหม่ของวิธี GA เพื่อสร้างตัวแบบพยากรณ์ปริมาณน้ำฝนร่วมกับโครงข่ายประสาทเทียม จากนั้นนำตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นกับที่ใช้การคัดเลือกแบบเดิมมาเปรียบเทียบความแม่นยำ พิจารณาความแม่นยำจากค่า

MAE MAPE RMSE และ R^2 ปรากฏว่าตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นมีความแม่นยำมากกว่าตัวแบบพยากรณ์ที่ใช้การคัดเลือกแบบเดิมทุกสถานการณ์

สำหรับการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย แบบรายฤดูกาล จำนวน 5 ปี ตั้งแต่ปี พ.ศ. 2562-2566 ด้วยตัวแบบพยากรณ์ Wang-GA(New)-ANN ที่มีการคัดเลือกแบบแข่งขันใหม่ที่พัฒนาขึ้นของวิธี GA เพื่อกำหนดค่าน้ำหนักเริ่มต้นและค่าความเอนเอียงของโครงข่ายประสาทเทียม สามารถพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย แบบรายฤดูกาลได้อย่างแม่นยำมีค่า R^2 มากกว่า 0.7 ทุกฤดูกาล โดยฤดูร้อนปริมาณน้ำฝนในปี พ.ศ. 2562-2566 อยู่ในเกณฑ์ฝนตกเล็กน้อยมีปริมาณน้ำฝนระหว่าง 0.1-10.0 มิลลิเมตร ฤดูฝนปริมาณน้ำฝนในปี พ.ศ. 2562-2566 อยู่ในเกณฑ์ฝนตกปานกลางมีปริมาณน้ำฝนระหว่าง 10.1-35.0 มิลลิเมตร และฤดูหนาวปริมาณน้ำฝนในปี พ.ศ. 2562-2566 อยู่ในเกณฑ์ฝนตกเล็กน้อยมีปริมาณน้ำฝนระหว่าง 0.1-10.0 มิลลิเมตร (กรมอุตุนิยมวิทยา, 2556, หน้า 20) แนวโน้มของปริมาณน้ำฝนในฤดูร้อนปี พ.ศ. 2562-2563 เพิ่มขึ้น และลดลงต่ำสุดในปี พ.ศ. 2564 จากนั้นปี พ.ศ. 2565-2566 เพิ่มขึ้นตามลำดับ ฤดูฝนมีแนวโน้มลดลงในปี พ.ศ. 2562-2564 จากนั้นปี พ.ศ. 2565-2566 เพิ่มขึ้นตามลำดับ ในทางกลับกัน ฤดูหนาวมีแนวโน้มเพิ่มขึ้นในปี พ.ศ. 2562-2564 จากนั้นปี พ.ศ. 2565 ลดลง แต่ปี พ.ศ. 2566 เพิ่มขึ้น

ข้อเสนอแนะ

ข้อเสนอแนะในการนำผลการวิจัยไปใช้

การวิจัยนี้เป็นการพัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม (GA) สำหรับพยากรณ์ปริมาณน้ำฝนด้วยโครงข่ายประสาทเทียม การนำผลการวิจัยนี้ไปใช้คือ

1. นำวิธีที่มีประสิทธิภาพในการคัดเลือกโครโมโซมของวิธี GA สำหรับขั้นตอนการดำเนินการทางพันธุกรรม (Genetic Operators) ไปใช้เพื่อให้เกิดการปรับเปลี่ยนสายพันธุ์หรือเกิดการปรับเปลี่ยนคำตอบ (ใกล้เคียง) ที่ดีที่สุด เมื่อนำวิธี GA ไปใช้ในการหาคำตอบที่เหมาะสมที่สุด (Optimum Solution) ของปัญหาต่าง ๆ

2. นำผลการพยากรณ์ปริมาณน้ำฝนที่ได้จากตัวแบบพยากรณ์โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันใหม่ที่พัฒนาขึ้นของวิธี GA ไปใช้เป็นข้อมูลพื้นฐานเพื่อประกอบการพิจารณาหรือวางแผนรับมือกับปัญหาและผลกระทบที่อาจเกิดขึ้นเนื่องจากปริมาณน้ำฝน เช่น

ด้านการเกษตรกรรม ปริมาณน้ำฝนถูกใช้ในการวางแผนการเพาะปลูก การสรรหาแนวทางการป้องกันและแก้ไข เพื่อบรรเทา ภัยที่ยังผลกระทบและความเสียหายที่อาจเกิดขึ้นกับ

การเกษตรกรรม (Samhitha & Srikanth, 2017; Tafoughalti et al., 2018; Wahyuni et al., 2018)

ด้านการพยากรณ์ ข้อมูลปริมาณน้ำฝนถูกนำมาใช้เป็นตัวแปรในการพยากรณ์ของหลากหลายสาขา เช่น การพยากรณ์ระดับน้ำ (ยุพิน ไชยสมภาร และทวี ชัยพิมลผลิน, 2560; ศุภมิตร บุญทา และจิระนันต์ เจริญรัตน์, 2559) การพยากรณ์อัตราการไหลของน้ำสูงสุด (อนุชา กาญจนารักษ์ และวรรณดี ไทยสยาม, 2561) การพยากรณ์เกี่ยวกับยุบ (Lee et al., 2016) การพยากรณ์ปริมาณน้ำฝน (Arya & Pai, 2018; Chanklan et al., 2017; Purnomo et al., 2017; Shaikh & Sawlani, 2017; Wahyuni et al., 2018)

ด้านการเตือนภัยพิบัติ เช่น การเตือนภัยดินถล่ม ปัจจัยที่สำคัญที่ทำให้ดินถล่มคือปริมาณน้ำฝน เหตุการณ์ดินถล่มในประเทศไทยที่เกิดขึ้นแล้วเกิดขึ้นในช่วงเวลาที่ฝนตกหนักติดต่อกันหลายวัน ทั้งฝนที่ตกตามฤดูกาลและฝนที่ตกหนัก เนื่องจากอิทธิพลพายุหมุนเขตร้อนที่พัดผ่านเข้ามาในประเทศไทย (สุทธิศักดิ์ ศรีสัมพันธ์ และธีรไนย นุ้ยมาก, 2556) นอกจากนี้ข้อมูลปริมาณน้ำฝนยังถูกใช้ในการเตือนภัยแล้งและการเกิดอุทกภัยอีกด้วย

ด้านการเก็บกักน้ำ เพื่อให้มีน้ำใช้สำหรับการชลประทานอย่างเพียงพอในเวลาที่ต้องการตลอดไป เก็บกักน้ำที่มีมากในลำน้ำตอนฤดูน้ำหลากไว้ สำหรับเป็นแหล่งน้ำต้นทุนเก็บสำรองไว้ใช้เมื่อถึงคราวจำเป็น

ด้านการท่องเที่ยว การท่องเที่ยวของไทยเป็นภาคส่วนที่มีความสำคัญทางเศรษฐกิจอย่างมาก การเปลี่ยนแปลงปริมาณน้ำฝนหรือการกระจายตัวของน้ำฝนก็อาจทำให้แหล่งท่องเที่ยวบางสถานที่เปลี่ยนไป บางสถานที่ปริมาณฝนน้อยทำให้ไม่สวยงามเท่าที่ควร บางสถานที่ไม่เหมาะกับการเดินทางไปเที่ยวในช่วงที่มีปริมาณน้ำฝนมากเพราะจะก่อให้เกิดอันตราย

ข้อเสนอแนะในการวิจัยต่อไป

1. การวิจัยนี้สร้างตัวแบบพยากรณ์จากวิธีโครงข่ายประสาทเทียมร่วมกับวิธี GA ที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้น ดังนั้นในการศึกษาครั้งต่อไปควรมีการนำการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของขั้นตอนวิธี GA มาใช้ร่วมกับวิธีการอื่นในการสร้างตัวแบบพยากรณ์ เพื่อให้ตัวแบบมีประสิทธิภาพเพิ่มมากขึ้น เช่น วิธี GA ร่วมกับเทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) วิธี GA ร่วมกับเทคนิคเพื่อนบ้านใกล้สุด (k-Nearest Neighbor: k-NN) วิธี GA ร่วมกับการวิเคราะห์ถดถอยเชิงเส้น และวิธี GA ร่วมกับฟัซซีลอจิก (Fuzzy Logic) เป็นต้น

2. การวิจัยนี้นำตัวแบบพยากรณ์โดยใช้โครงข่ายประสาทเทียมที่ใช้การคัดเลือกแบบแข่งขันที่พัฒนาขึ้นไปพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทย ดังนั้นในการศึกษาครั้งต่อไปควรมีนำตัวแบบพยากรณ์ไปพยากรณ์กับภูมิภาคอื่น ๆ ของประเทศไทย เช่น นำไปพยากรณ์ปริมาณน้ำฝนของภาคตะวันออกเฉียงเหนือโดยอาจจะต้องพิจารณาเพิ่มเติมสำหรับการเลือกใช้ตัวแปรนำเข้า

เนื่องจากภาคตะวันออกเฉียงเหนือมีบริเวณพื้นที่ที่เป็นชายฝั่งยาวไปตามแนวอ่าวไทยและทางตอนกลางของภาค มีภูเขาสูง ลักษณะเช่นนี้มีอิทธิพลต่อภูมิอากาศ ทำให้ภาคตะวันออกเฉียงเหนือได้รับลมมรสุมตะวันตกเฉียงใต้ ผ่านอ่าวไทยเข้าสู่ตอนในของภาค ส่งผลทำให้ลักษณะภูมิอากาศของภาคตะวันออกเฉียงเหนือแตกต่างกันคือ ทำให้บริเวณชายฝั่งมีฝนตกชุกได้แก่ บริเวณชายฝั่งจังหวัดจันทบุรีและตราด ส่วนตอนในของภาคมีฝนตกน้อย ดังนั้นก่อนที่จะนำตัวแบบไปใช้พยากรณ์ควรพิจารณาในเรื่องตัวแปรที่ส่งผลต่อปริมาณน้ำฝนเหล่านี้ด้วย ซึ่งมีความแตกต่างกันในแต่ละภูมิภาคหรือนำตัวแบบพยากรณ์ไปพยากรณ์ในด้านอื่น ๆ เช่น

ด้านการแพทย์ นำไปใช้ในการวินิจฉัยโรคหรือนำไปใช้ในการจำลองอวัยวะต่าง ๆ ในร่างกายมนุษย์ สำหรับการวินิจฉัยโรค เช่น Malek et al. (2016) ศึกษาการใช้โครงข่ายประสาทเทียมเพื่อจำแนกเวลาที่ใช้สำหรับการรักษากระดูกช่วงขาที่หักในเด็ก

ด้านธุรกิจ นำไปใช้ในการวางแผนการตลาดหรือสนับสนุนปัจจัยต่าง ๆ ที่สำคัญต่อการตลาด เช่น การวางแผนเส้นทางการขายของพนักงานขายสินค้า ที่วิเคราะห์ต้นทุนที่จะต้องใช้จ่าย เพื่อช่วยลดต้นทุนให้น้อยที่สุดและเพิ่มกำไรจากการขายให้มากขึ้น เช่น Yan (2015) ศึกษาการสร้างตัวแบบพยากรณ์แบบโครงข่ายประสาทเทียมแบบ BPNN ร่วมกับวิธี GA ในการพยากรณ์ค่าดัชนีความปลอดภัยในอาหาร (The Food Safety Index)

ด้านวิศวกรรม เช่น Porte et al. (2018) ศึกษาการพยากรณ์การเปลี่ยนแปลงของกระแสน้ำและระดับน้ำใต้ดิน ซึ่งกลายเป็นองค์ประกอบสำคัญของการควบคุมระบบทรัพยากรน้ำและภารกิจที่ทำนายสำหรับวิศวกรแหล่งน้ำ

ด้านการเกษตรกรรม เช่น ธนวัฒน์ ปุณฺณฤทธิ และชุตินันท์ ศรีสวัสดิ์ (2560) ศึกษาการจำแนกสภาพดอกเดหลีโดยใช้เนื้อหาภาพ เพื่อให้การระบุสภาพดอกเดหลีสะดวกและง่ายขึ้น El Massi et al. (2017) ศึกษาการจดจำโรคพืชแบบอัตโนมัติโดยใช้การจำแนกของโครงข่ายประสาทเทียม Gong et al. (2018) ศึกษาการใช้ตัวแบบโครงข่ายประสาทเทียมและการถดถอยโลจิสติก (Logistic Regression) เพื่อวิเคราะห์บริเวณที่สามารถเกิดดินถล่มได้ง่ายและระบุปัจจัยควบคุมหลักของการเกิดดินถล่มในลุ่มน้ำเหมยเจียง (Meijiang River Basin) ของประเทศจีนตอนใต้

บรรณานุกรม

- กรมอุตุนิยมวิทยา. (2556). รู้เร็ว รู้ทัน รู้ป้องกัน ภัยธรรมชาติ, *การสัมมนาวิชาการวันอุตุนิยมวิทยาโลก 2556*. กรุงเทพฯ: กรมอุตุนิยมวิทยา.
- กรมอุตุนิยมวิทยา. (ไม่ปรากฏปีพิมพ์). *ความรู้อุตุนิยมวิทยา*. ค้นเมื่อ 18 เมษายน 2561, จาก <https://www.tmd.go.th/info/info.php>.
- กรมอุตุนิยมวิทยา. (ไม่ปรากฏปีพิมพ์). *อุตุนิยมวิทยา* [PowerPoint slides]. ค้นเมื่อ 2 มีนาคม 2561, จาก <http://hydro-1.net/08HYDRO/HD-10/10-2/General%20Meteorogy.pdf>
- กิตติเชษฐ์ นนทะสุด และธีรพจน์ เวศพันธ์. (2560). แบบจำลองการพยากรณ์การใช้พลังงานไฟฟ้าเพื่อการวางแผนพัฒนาท่าอากาศยานเชียงใหม่. *วารสารวิชาการมหาวิทยาลัยอีสเทิร์นเอเชียฉบับวิทยาศาสตร์และเทคโนโลยี*, 11(3), 124-136.
- จตุภัทร เมฆพ่ายพ์ และกิตติการ สายธนู. (2554). สมรรถนะของข่ายงานระบบประสาทแบบ Multi-Layer Perceptron และ Radial Basis Function สำหรับแผนภูมิควบคุมคุณภาพหลายตัวแปร. *วารสารวิทยาศาสตร์บูรพา*, 16(2), 97-106.
- เจษฎา ตงศิริ และอนงค์ฤทธิ์ แข็งแรง. (2561). การพยากรณ์ปริมาณน้ำท่าในอนาคตภายใต้การเปลี่ยนแปลงลักษณะทางอุทกวิทยาและการปรับปรุงโค้งควบคุมอ่างเก็บน้ำน้ำอูนด้วยเทคนิคเจเนติกอัลกอริทึม. *วารสารวิทยาศาสตร์และเทคโนโลยีมหาวิทยาลัยมหาสารคาม*, 37(2), 775-788.
- ชูพันธุ์ รัตนโกคา. (2559). *ความรู้เบื้องต้นทางปัญญาประดิษฐ์*. (เอกสารประกอบคำสอน). กรุงเทพฯ: มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ.
- ฐกร กาญจนจิระเดช, มยุรี รัตนเสริมพงศ์ และสมบุญรณ์ สุขสำราญ. (2561). รูปแบบการมีส่วนร่วมของชุมชนในการบริหารจัดการน้ำอย่างยั่งยืนของจังหวัดอุทัยธานีตามแนวปรัชญาเศรษฐกิจพอเพียง. *วารสารสันติศึกษาปริทรรศน์ มจร*, 6(2), 537-552.
- ณัฐภา ผิวมา. (2558). การพัฒนาแบบจำลองพยากรณ์แนวโน้มการสมัครงานให้ตรงกับวุฒิการศึกษาสาขาคอมพิวเตอร์โดยใช้โครงข่ายประสาทเทียม. *วารสารปัญญาภิวัฒน์*, 7(2), 1-16.
- ณัฐพงษ์ วารีประเสริฐ. (2552). *ปัญญาประดิษฐ์*. กรุงเทพฯ: ไทยเจริญการพิมพ์.

- ทศพร ศรีเพียงจันทร์, จิรัชญา บุญยงค์ และศศิวิมล คนคง. (2555). *ถอดบทเรียนนุทกภัย 2554 และ การศึกษาแนวทางการบรรเทาปัญหาอุทกภัยในลุ่มน้ำเจ้าพระยา*. นครปฐม: โครงการงาน วิศวกรรมชลประทาน, มหาวิทยาลัยเกษตรศาสตร์.
- ทวี ชัยพิมลผลิน (2557). บทบาทของแบบจำลองโครงข่ายประสาทเทียมสำหรับงานวิจัยทางด้าน ภูมิศาสตร์ในประเทศไทย. *วารสารสังคมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ*, 17, 315-327.
- ธงจรัส แสงอรุณ และอรลภา แสงอรุณ. (2558). การจำแนกพฤติกรรมการลาออกของพนักงาน โรงแรมโดยใช้โครงข่ายประสาทเทียม. *Southeast Bangkok Journal*, 1(2), 96-112.
- ธวัช รวมทรัพย์ และสุรศักดิ์ มั่งสิงห์. (2559). การจำแนกชนิดของพืชด้วยวิธีเพื่อนบ้านใกล้สุดร่วมกับการเลือกตัวแทนที่เหมาะสมด้วยขั้นตอนวิธีเชิงพันธุกรรมโดยใช้คุณลักษณะรูปทรงและ พื้นผิวของใบพืช. *Veridian E-journal Science and Technology Silpakorn University*, 3(4), 135-146.
- ธนาวุฒิ ประกอบผล. (2552). โครงข่ายประสาทเทียม. *มฉก.วิชาการ*, 12(24), 73-87.
- นันทชัย กานตานันทะ. (2555). การพยากรณ์ด้วยวิธีการพยากรณ์เชิงสาเหตุ. *วารสาร วิศวกรรมศาสตร์*, 4(1), 33-48.
- นิภาพร ชนะมาร และพรรณี สิทธิเดช. (2557). การวิเคราะห์ปัจจัยการเรียนรู้ด้วยการคัดเลือก คุณสมบัติและการพยากรณ์. *วารสารมหาวิทยาลัยราชภัฏสกลนคร*, 6(12), 31-46.
- บุญชม ศรีสะอาด. (2556). *วิธีการทางสถิติสำหรับการวิจัย เล่ม 1*. (พิมพ์ครั้งที่ 5). กรุงเทพฯ: สุวีริยา สาส์น.
- ปริญ หล่อพิทยากร. (2560). อิทธิพลของเอลนีโญที่มีผลต่อการแพร่กระจายของปริมาณฝนในช่วงฤดู ฝนและฤดูแล้งบริเวณภาคตะวันออกเฉียงเหนือของประเทศไทย. *วารสารวิทยาศาสตร์และเทคโนโลยี*, 25(6), 944-959.
- ปริญ หล่อพิทยากร. (2561). อิทธิพลของลานีญาที่มีผลต่อการแพร่กระจายของปริมาณฝนในช่วงฤดู ฝนและฤดูแล้งบริเวณภาคตะวันออกเฉียงเหนือของประเทศไทย. *วารสารวิทยาศาสตร์และเทคโนโลยี*, 26(1), 1-16.
- ปานทิพย์ อัครนนานิช. (2553). *ภูมิศาสตร์การท่องเที่ยวไทย*. กรุงเทพฯ: สำนักพิมพ์มหาวิทยาลัย รามคำแหง.

- เปรม รังสิวณิชพงศ์, ชัยวัฒน์ เอกวัฒน์พานิชย์ และดวงฤดี โฆษิตกิตติวงศ์. (2558). การพยากรณ์ฝนรายฤดูกาลในกลุ่มแม่เจ้าพระยาโดยใช้โครงข่ายประสาทเทียม. [บทคัดย่อ]. *การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ, 20*, 1-6.
- พงศ์ศักดิ์ ชลธนสวัสดิ์, รัตนา ตั้งวงศ์กิจ, บพิตร ตั้งวงศ์กิจ และสุนัญญา อัฐิจิศิลป์เวท. (2558). อิทธิพลของปริมาณน้ำฝนเฉลี่ยรายปีต่อผลผลิตอ้อยโรงงานในพื้นที่ภาคกลางเขต 7. *การประชุมวิชาการสมาคมวิศวกรรมเกษตรแห่งประเทศไทยระดับชาติ ครั้งที่ 6 ประจำปี 2558 และระดับนานาชาติ ครั้งที่ 8*, 591-596.
- พยุง มีสีจ. (2555). *ระบบพีซีและโครงข่ายประสาทเทียม*. กรุงเทพฯ: คณะเทคโนโลยีสารสนเทศ มจพ.
- พูลพงศ์ สุขสว่าง. (2561). *โมเดลสมการโครงสร้าง*. (พิมพ์ครั้งที่ 2). ชลบุรี: เอ.พี.บลูปรีนท์.
- ยุพิน ไชยสมภาร และทวี ชัยพิมลผลิน. (2560). การพยากรณ์ระดับน้ำโดยแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูลปริมาณน้ำฝนจากแบบจำลอง WRF-ECHAM5 (WATER LEVEL FORECASTING BY ARTIFICIAL NEURAL NETWORK MODEL WITH RAINFALL DATA FROM WRF-ECHAM5 MODEL). *Srinakharinwirot University (Journal of Science and Technology)*, 9(17), 83-90.
- รังสรรค์ อาภาคัพทะกุล. (2547). *อุตุนิยมวิทยาเบื้องต้น*. กรุงเทพฯ: สำนักพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย.
- วรางคณา กิริติวิบูลย์. (2557). ตัวแบบพยากรณ์ปริมาณน้ำฝนจังหวัดสงขลา. *วารสารมหาวิทยาลัยทักษิณ*, 17(1), 40-48.
- วัฒนา กันบัว. (2558, มีนาคม 28). *The Weather Lover Club*. ค้นเมื่อ 3 มกราคม 2561, จาก https://www.facebook.com/pg/WeatherLoverClub/photos/?ref=page_internal.
- วิจักชณ์ นุ่มนิ่ม. (2554). *สถาปัตยกรรมที่ตอบสนองต่อภัยพิบัติทางธรรมชาติ*. กรุงเทพฯ: ปริญญาสถาปัตยกรรมศาสตร์มหาบัณฑิต สาขาวิชาสถาปัตยกรรม, มหาวิทยาลัยศิลปากร.
- วิชัย ศรีบุญลือ. (2552). *อุทกวิทยา*. ขอนแก่น: โรงพิมพ์มหาวิทยาลัยขอนแก่น.
- วิรัช มณีสาร. (2538). *ลักษณะภูมิประเทศและลักษณะอากาศตามฤดูกาลของภาคต่าง ๆ ในประเทศไทย*. เอกสารวิชาการเลขที่ 551.582-02-2538. กรุงเทพฯ: กรมอุตุนิยมวิทยา.

- ศุภกานต์ พิมลธเรศ. (2553). เทคโนโลยีไปโอเมตริกส์บนโครงข่ายประสาทเทียม. *วารสารวิชาการ มหาวิทยาลัยหอการค้าไทย*, 30(1), 90-103.
- ศุภมิตร บุญทา และจิระนันต์ เจริญรัตน์. (2559). การพยากรณ์การเปลี่ยนแปลงระดับน้ำด้วยเทคนิคโครงข่ายประสาทเทียมแบบแพร่กลับ กรณีศึกษา ทะเลสาบหนองหาร จังหวัดสกลนคร. *การประชุมวิชาการระดับชาติเครือข่ายวิจัยสถาบันอุดมศึกษาทั่วประเทศ ครั้งที่ 11 “เครือข่ายวิจัยอุดมศึกษา สานพลังประชารัฐ”*, 304-310.
- ศุภโชค แสงสว่าง. (2559). การประยุกต์ใช้โครงข่ายประสาทเทียมกับงานด้านการเกษตร. *วารสารวิชาการพระจอมเกล้าพระนครเหนือ*, 26(2), 319-331.
- สถาบันพัฒนาการชลประทาน. (2551). *เอกสารประกอบการฝึกอบรม การประยุกต์ใช้ Artificial Neural Network (ANNs) ในงานชลประทาน*. นนทบุรี: สถาบันพัฒนาการชลประทาน.
- สายชล สีนสมบูรณ์ทอง. (2558). *การทำเหมืองข้อมูล*. กรุงเทพฯ: จามจุรีโปรดักส์.
- สุทธิศักดิ์ ศรีลัมภ์ และธีรไฉน นุ่มมาก. (2556). การประเมินเกณฑ์ปริมาณน้ำฝนเชิงสถิติสำหรับเตือนภัยดินถล่ม. *การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ*, 18, 322-330.
- สุวิมล คำแสน และอริวัฒน์ บุญมี. (2561). การวางแผนเส้นทางการเยี่ยมชมจุดท่องเที่ยวภายใต้เงื่อนไขด้านกรอบเวลา โดยประยุกต์ใช้วิธีเชิงพันธุกรรม: กรณีศึกษาเมืองจำลอง จังหวัดชลบุรี. *วารสารไทยการวิจัยดำเนินงาน*, 6(1), 1-12.
- เสกศึก สำราญสุข และมนสิชา เพชรานนท์. (2560). รูปแบบวิธีการบริหารจัดการน้ำ เพื่อแก้ปัญหาภัยแล้ง (พื้นที่แล้งซ้ำซาก) จังหวัดนครราชสีมา. *การประชุมวิชาการระดับชาติ มหาวิทยาลัยราชภัฏเพชรบูรณ์*, 4, 609-615.
- อรอนงค์ บุเกตุ และพฤษดี ศิริแสงตระกูล. (2556). แบบจำลองการพยากรณ์ปริมาณอ้อยของภาคตะวันออกเฉียงเหนือโดยใช้โครงข่ายประสาทเทียม. *ว.วิทย์. มช.*, 41(1), 213-225.
- อภิรักษ์ พัชโรภาสวัฒนกุล, ขนิษฐา เสถียรพีระกุล, เกศสุดา สิทธิสันติกุล และนิโรจน์ สีนณรงค์. (2560). ผลกระทบของการเปลี่ยนแปลงสภาพภูมิอากาศต่อผลผลิตมันสำปะหลัง ในภาคตะวันออกเฉียงเหนือ. *Veridian E-Journal ฉบับภาษาไทย สาขามนุษยศาสตร์ สังคมศาสตร์ และศิลปะ*, 10(3), 2528-2540.
- อภิรักษ์ ขัดวิลาศ. (2554). การประยุกต์วิธีเชิงพันธุกรรมสำหรับปัญหาการหาค่าที่เหมาะสมที่สุด. *วารสารวิชาการและวิจัย มทร.พระนคร*, 5(2), 153-163.

- อนุชา กาญจนารักษ์ และวรวรรณดี ไทยสยาม. (2561). การพยากรณ์อัตราการไหลสูงสุดในช่วงน้ำหลาก โดยใช้วิธีดัชนีน้ำฝนในลุ่มน้ำเลย. *วารสารวิชาการพระจอมเกล้าพระนครเหนือ*, 28(3), 1-9.
- อัครพล คุณเลิศ และพฤษดี ศิริแสงตระกูล. (2557). แบบจำลองการพยากรณ์ปริมาณผลผลิตข้าวด้วยเทคนิคโครงข่ายประสาทเทียม. [บทคัดย่อ]. *The National Conference on Computing and Information Technology*, 10, 7-12.
- อุทัย เลาหวิเชียร และสุวรรณี แสงมหาชัย. (2560). การบริหารการป้องกันและแก้ไขปัญหาอุทกภัยในเขตกรุงเทพมหานคร. *วารสารเกษมบัณฑิต*, 18(2), 111-127.
- Abdulkadir, T., Salami, A., & Kareem, A. (2012). Artificial Neural Network of Rainfall in Ilorin, Kwara State, Nigeria. *USEP Research information in Civil Engineering*, 9, 108-120.
- Akbar, A., Kuanar, A., Patnaik, J., Mishra, A., & Nayak, S. (2018). Application of Artificial Neural Network modeling for optimization and prediction of essential oil yield in turmeric (*Curcuma longa* L.). *Computers and Electronics in Agriculture*, 148, 160-178.
- Almazroui, M., Balkhair, K. S., Islam, M. N., & Şen, Z. (2017). Climate Change Impact on Monthly Precipitation Wet and Dry Spells in Arid Regions: Case Study over Wadi Al-Lith Basin. *Advances in Meteorology*, 1-13.
- Anderson, D., & McNeill, G. (1992). Artificial neural networks technology. *Kaman Sciences Corporation*, 258, 13502-13462.
- Arakaki, R. K., & Usberti, F. L. (2018). Hybrid genetic algorithm for the open capacitated arc routing problem. *Computers & Operations Research*, 90, 221-231.
- Arya, R., & Pai, M. L. (2018). Rainfall prediction using on optimised Genetic- Artificial Neural Network Model. *International Journal of Pure and Applied Mathematics*, 119(10), 669-678.

- Asadi, S., Shahrabi, J., Abbaszadeh, P., & Tabanmehr, S. (2013). A new hybrid artificial neural networks for rainfall–runoff process modeling. *Neurocomputing*, *121*, 470-480.
- Bennett, B. S. (1995). *Simulation Fundamentals*. London: Prentice Hall.
- Chanklan, R., Suksut, K., Chaiyakhan, K., Kaoungku, N., Kerdprasop, K., & Kerdprasop, N. (2017). On Applying Regression and Neural Network to Predict Rainfall Using Satellite Based Index. *Proceedings of the International MultiConference of Engineers and Computer Scientists*, *1*.
- Chauhan, N., Yadav, N., & Arya, N. (2018). Applications of Artificial Neural Network in Textiles. *Int. J. Curr. Microbiol. App. Sci*, *7*(4), 3134-3143.
- Dawson, C. W., & Wilby, R. L. (1999). A comparison of artificial neural networks used for river forecasting. *Hydrology and Earth System Sciences Discussions*, *3*(4), 529-540.
- Deb, K. (1999). An introduction to genetic algorithms. *Sadhana*, *24*(4), 293–315.
- Ding, Y., Cai, Y., Sun, P., & Chen, B. (2014). The use of combined neural networks and genetic algorithms for prediction of river water quality. *Journal of applied research and technology*, *12*(3), 493-499.
- Dubey, A. D. (2015). Artificial neural network models for rainfall prediction in Pondicherry. *International Journal of Computer Applications*, *120*(3).
- El Massi, I., Es-saad, Y., El Yassa, M., Mammass, D., & Benazoun, A. (2017). Automatic Recognition of Vegetable Crops Diseases based on Neural Network Classifier. *International Journal of Computer Applications (0975–8887)*, *158*(4), 48-51.
- Engelbrecht, A. P. (2005). *Computation Intelligence An Introduction*. Chichester: John Wiley & Son, Ltd.
- Feng, J., & Wang, X.-C. (2018). Impact of two types of La Niña on boreal autumn rainfall around Southeast Asia and Australia. *Atmospheric and Oceanic Science Letters*, *11*(1), 1-6.

- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Massachusetts: Addison–Wesley Longman, Inc.
- Goldberg, D. E. (1989). Sizing populations for serial and parallel genetic algorithms. *Proceeding of the 3rd International Conference on Genetic Algorithms*, 70–79.
- Goldberg, D. E., & Deb, Kalyanmoy. (1991). A Comparative Analysis of Selection Schemes Used in Genetic Algorithms. *Foundations of Genetic Algorithms*, 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.
- Gong, Q.-h., Zhang, J.-x., & Wang, J. (2018). Application of GIS-Based Back Propagation Artificial Neural Networks and Logistic Regression for shallow Landslide Susceptibility Mapping in South China-Take Meijiang River Basin as an Example. *The Open Civil Engineering Journal*, 12(1), 21-34.
- Gupta, P., Mishra, S., & Pandey, S. (2014). Time series data mining in rainfall forecasting using artificial neural network. *IJSET (ISSN: 2277-1581)*, 3(8), 1060-1065.
- Gupta, D., Vasudev, K., & Bhattacharyya, S. (2018). Genetic algorithm optimization based nonlinear ship maneuvering control. *Applied Ocean Research*, 74, 142-153.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate data analysis a global perspective (7th ed.)*. New Jersey: Prentice-Hall International.
- Hashim, F., Daud, N. N., Ahmad, K., Adnan, J., & Rizman, Z. (2017). Prediction of rainfall based on weather parameter using artificial neural network. *Journal of Fundamental and Applied Sciences*, 9(3S), 493-502.

- Haykin, S. (1999). *Neural Network A Comprehensive Foundation (2nded.)*. United States of America: Tom Robbins.
- Hettiarachchi, S., Wasko, C., & Sharma, A. (2018). Increase in flood risk resulting from climate change in a developed urban watershed—the role of storm temporal patterns. *Hydrology and Earth System Sciences*, 22(3), 2041-2056.
- Hewahi, N. M., & Rashid, S. (2017). Image Finder Mobile Application Based on Neural Networks. *BRAIN. Broad Research in Artificial Intelligence and Neuroscience*, 8(1), 5-16.
- Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor: University of Michigan Press.
- Huang, H.-C., & Hou, C.-I. (2017). Tourism demand forecasting model using neural network. *International Journal of Computer Science & Information Technology*, 9(2), 19-29.
- Hung, N. Q., Babel, M. S., Weesakul, S., & Tripathi, N. (2009). An artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrology and Earth System Sciences*, 13(8), 1413-1425.
- Hussain, D., Usmani, A., Verma, D. K., Jamal, F., & Khan, M. A. (2017). Rainfall Runoff Modelling Using Artificial Neural Network. *International Journal of Advance Research, Ideas and Innovations in Technology*, 3(6), 1528-1533.
- Joines, J. A., & Houck, C. R. (1994). *On the use of nonstationary penalty functions to solve nonlinear constrained optimization problems with GA's*. Paper presented at the Proceedings of the International Conference on Evolutionary Computation (IEEE Press, Piscataway, 1994), 579–584.
- Kaur, J., & Kaur, P. (2018). A Review: Artificial Neural Network. *International Journal of Current Engineering and Technology*, 8(4), 904-910.

- Kirar, V. P. S. (2015). Artificial Neural Networks for Cognitive Radio Network: A Survey. *International Journal of Computer, Electrical, Automation, Control and Information Engineering*, 9(1), 224-229.
- Kumar, R., & Yadav, G. (2013). Forecasting of Rain Fall in Mirzapur District, Uttar Pradesh, India Using Feed-Forward Artificial Neural Network. *International Journal of Engineering Science Invention*, 2(8), 87-93.
- Kumari, J., & Dubey, A. K. (2016). A Review Paper on Genetic Algorithm. *International Journal of Advance Research in Computer Science and Management Studies*, 4(7), 122-125.
- Kurup, R., Deonarine, G., & Ansari, A. A. (2017). Malaria trend and effect of rainfall and temperature within Regions 7 and 8, Guyana. *International Journal of Mosquito Research*, 4(6), 48-55
- Larasati, A., DeYong, C., & Slevitch, L. (2011). Comparing Neural Network and Ordinal Logistic Regression to Analyze Attitude Responses. *Service Science*, 3(4), 304-312.
- Lee, K. Y., Chung, N., & Hwang, S. (2016). Application of an artificial neural network (ANN) model for predicting mosquito abundances in urban areas. *Ecological informatics*, 36, 172-180.
- Maitanmi, S. S., Bridget, M., Andy, E. E., Yinka, A., & Onwodi, G. (2013). Neural Network Models: A Basic Statistical Tool for Data analysis and Forecasting. *International Journal of Computer (IJC)*, 8(1), 1-7.
- Malek, S., Gunalan, R., Kedija, S., Lau, C., Mosleh, M. A., Milow, P., Amber, H., & Saw, A. (2016). A primary study on application of artificial neural network in classification of pediatric fracture healing time of the lower limb. Paper presented at the 10th International Conference on Practical Applications of Computational Biology & Bioinformatics., 23-30.

- Metawa, N., Hassan, M. K., & Elhoseny, M. (2017). Genetic algorithm based model for optimizing bank lending decisions. *Expert Systems with Applications*, 80, 75-82.
- Mislan, Haviluddin, Hardwinarto, S., Sumaryono, & Aipassa, M. (2015). Rainfall Monthly Prediction Based on Artificial Neural Network: A Case Study in Tenggaraong Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59, 142-151.
- Mitchell, M. (1996). *An Introduction to Genetic Algorithms*. Cambridge, MA: MIT Press.
- Mitchell, T. M. (1997). *Machine Learning*. Singapore: MIT Press and McGraw-Hill Companies, Inc.
- Mohammadi, M., Lakestani, M., & Mohamed, M. (2018). Intelligent parameter optimization of Savonius rotor using Artificial Neural Network and Genetic Algorithm. *Energy*, 143, 56-68.
- Navid, M., & Niloy, N. (2018). Multiple Linear Regressions for Predicting Rainfall for Bangladesh. *Communications*, 6(1), 1-4.
- 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/>
- Panchal, F. S., & Panchal, M. (2014). Review on Methods of Selecting Number of Hidden Nodes in Artificial Neural Network. *International Journal of Computer Science and Mobile Computing*, 3(11), 455-464.
- Parajuli, A., Devkota, L. P., Adhikari, T. R., Dhakal, S., & Kayastha, R. B. (2015). Impact of Climate Change on River Discharge and Rainfall Pattern: A Case Study from Marshyangdi River basin, Nepal. *Journal of Hydrology and Meteorology*, 9(1), 60-73.
- Penname. (2007, August 20). *อุตุนิยมวิทยาที่ควรรู้*. ค้นเมื่อ 30 พฤษภาคม 2560, จาก <http://oknation.nationtv.tv/blog/print.php?id=99412>.

- Perol, T., Gharbi, M., & Denolle, M. (2018). Convolutional neural network for earthquake detection and location. *Science Advances*, 4(2), 1-8.
- Porte, P., Isaac, R. K., Mahilang, K. K. S., Sonboier, K., & Minj, P. (2018). Groundwater Level Prediction Using Artificial Neural Network Model. *Int. J. Curr. Microbiol. App. Sci*, 7(2), 2947-2954.
- Purnomo, H., Hartomo, K., & Prasetyo, S. (2017). Artificial Neural Network for Monthly Rainfall Rate Prediction. *The IOP Conference Series: Materials Science and Engineering*, 1-9.
- Putra, R., Nurhidayat, A., & Wicaksono, A. (2018). *Implementation of Neural Network to Determine the New College Students*. Paper presented at the IOP Conference Series: Materials Science and Engineering, 1-6.
- 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.
- Ramesh, V., Parkavi, P., & Yasodha, P. (2011). Performance analysis of data mining techniques for placement chance prediction. *International Journal of Scientific & Engineering Research*, 2(8), 1-7.
- Rasel, H. M., & Imteaz, M. A. (2016). Application of Artificial Neural Network for Seasonal Rainfall Forecasting: A Case Study for South Australia. *Proceedings of the World Congress on Engineering*, 1.
- Reeves, C. (1996). Hybrid genetic algorithms for bin-packing and related problems. *Annals of Operations Research*, 63, 371-396.
- Rehman, A. U., Ur Rehman, S., Babar, Z. H., Qadeer, M. K., & Seelro, F. A. (2018). Offline Signature Recognition and Verification System Using Artificial Neural

- Network. *University of Sindh Journal of Information and Communication Technology*, 2(1), 73-80.
- Reno, V., Mosca, N., Marani, R., Nitti, M., D'Orazio, T., & Stella, E. (2018). *Convolutional Neural Networks based ball detection in tennis games*. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 1871-1877.
- Rizwan, J. M., Krishnan, P. N., Karthikeyan, R., & Kumar, S. R. (2016). Multi layer perception type artificial neural network based traffic control. *Indian Journal of Science and Technology*, 9(5), 1-6.
- Saidi-Mehrabad, M., & Bairamzadeh, S. (2018). Design of a hybrid genetic algorithm for parallel machines scheduling to minimize job tardiness and machine deteriorating costs with deteriorating jobs in a batched delivery system. *Journal of Optimization in Industrial Engineering*, 11(1), 35-50.
- Samhitha, S. V., & Srikanth, P. G. (2017). Prediction of rainfall using inverse distance weighting method and artificial neural networks in Ponnaiyar river basin. *Indian Journal of Scientific Research*, 144-148.
- Saxena, A., Verma, N., & Tripathi, K. (2014). Neuro-genetic hybrid approach for rainfall forecasting. *Int J Comput Sci Inf Technol*, 5(2), 1291-1295.
- Sevenster, S., & Engelbrecht, A.P. (1996). *GARTNet: A Genetic Algorithm for Routing in Telecommunications Networks*. CESA96 IMACS/IEEE Multiconference on Computational Engineering in Systems Applications, Symposium on Control, Optimization and Supervision, 1106-1111.
- Shaikh, L., & Sawlani, K. (2017). A rainfall prediction model using artificial neural network. *International Journal of Technical Research and Applications*, 5(2), 45-48.
- Shehu, A. U., Yelwa, S. A., Sawa, B. A., & Adegbehin, A. B. (2016). The Influence of El - Niño Southern Oscillation (ENSO) Phenomenon on Rainfall Variation in

- Kaduna Metropolis, Nigeria. *Journal of Geography, Environment and Earth Science International*, 8(1), 1-9.
- Sibanda, W., & Pretorius, P. (2012). Artificial neural networks-a review of applications of neural networks in the modeling of hiv epidemic. *International Journal of Computer Applications*, 44(16), 1-9.
- Sihananto, A. N., & Mahmudy, W. F. (2017). Rainfall Forecasting Using Backpropagation Neural Network. *Journal of Information Technology and Computer Science*, 2(2), 66-76.
- Singh, S. K., Lo, E. Y.-M., & Qin, X. (2017). Cluster Analysis of Monthly Precipitation over the Western Maritime Continent under Climate Change. *Climate*, 5(84), 1-20.
- Stephen, I., & Ben-Edigbe, J. (2018). Effects of Rainfall on Driver Behaviour and Gap Acceptance at Multilane Roundabouts. *The Open Transportation Journal*, 12(1), 192-202.
- Sweet Eyes. (2012, March 8). *ลักษณะภูมิประเทศของประเทศไทย*. ค้นเมื่อ 25 กรกฎาคม 2560, จาก <http://www.vcharkarn.com/vcafe/197055>.
- Tafoughalti, K., El Faleh, E., Moujahid, Y., & Ouargaga, F. (2018). *Climate Change Impact on Rainfall: How will Threaten Wheat Yield?* Paper presented at the E3S Web of Conferences, 1-7.
- Tahir, T., Hashim, A., & Yusof, K. (2018). *Statistical downscaling of rainfall under transitional climate in Limbang River Basin by using SDSM*. Paper presented at the IOP Conference Series: Earth and Environmental Science.
- Teong, K. V., Sukarno, K., Chang, J. H. W., Chee, F. P., Ho, C. M., & Dayou, J. (2017). The Monsoon Effect on Rainfall and Solar Radiation in Kota Kinabalu. *Transactions on Science and Technology*, 4(4), 460-465.
- Thai PBS. (2014, June 11). *ร่องมรสุมตัวการที่ทำให้เกิดฝนตกชุก*. ค้นเมื่อ 14 มกราคม 2561, จาก <https://news.thaipbs.or.th/content/175998>.

- Tikoo, S., & Malik, N. (2016). Detection of Face using Viola Jones and Recognition using Back Propagation Neural Network. *International Journal of Computer Science and Mobile Computing*, 5(5), 288-295.
- Toeybeast. (2018, June 30). ไขข้อสงสัย ฤดูฝนประเทศไทยพร้อมสาเหตุที่ฝนชอบตกในป่า (บนภูเขาสูง). ค้นเมื่อ 15 กรกฎาคม 2561, จาก <https://lifestyle.campus-star.com/knowledge/121395.html>.
- Tokle, H. M., & Joshi, J. A. (2016). PRECIPITATION (RAINFALL) FORECASTING USING ARTIFICIAL NEURAL NETWORK. *International Journal of Modern Trends in Engineering and Science*, 3(12), 91-96.
- Uddin, M. A., Jameel, M., & Razak, H. A. (2015). Application of artificial neural network in fixed offshore structures. *Indian Journal of Marine Sciences*, 44(3).
- Vakili, M., Khosrojerdi, S., Aghajannezhad, P., & Yahyaei, M. (2017). A hybrid artificial neural network-genetic algorithm modeling approach for viscosity estimation of graphene nanoplatelets nanofluid using experimental data. *International Communications in Heat and Mass Transfer*, 82, 40-48.
- Wahyuni, E., Fauzan, L., Abriyani, F., Muchlis, N., & Ulfa, M. (2018). Rainfall prediction with backpropagation method. *Journal of Physics: Conference Series*, 983, 1-6.
- 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.
- Weerid Hooncharoen. (2015, February 10). คลื่นกระแสลมตะวันตก. สืบค้นจาก http://weeridnewsdiary.blogspot.com/2015/02/blog-post_44.html.
- West, P. M., Brockett, P. L., & Golden, L. L. (1997). A comparative analysis of neural networks and statistical methods for predicting consumer choice. *Marketing Science*, 16(4), 370-391.
- Whitley, D. (1994). A Genetic Algorithm Tutorial. *Statistics and Computing*, 4(2), 65-85.

- Yan, S. (2015). The Prediction of Food Safety Composite Index based on BP Neural Network and GA Algorithm. *Advance Journal of Food Science and Technology*, 8(2), 101-104.
- Yang, X. S. (2008). *Nature-Inspired Metaheuristic Algorithms*. United Kingdom: Luniver Press.
- Yashwant, S., & Sananse, S. (2015). Comparing Neural Network and Multiple Regressions Models to Estimate Monthly Rainfall Data. *International Journal of Science and Research*, 4(12), 1307-1312.
- 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.
- Yu, L., Zhong, S., Heilman, W. E., & Bian, X. (2017). A comparison of the effects of El Niño and El Niño Modoki on subdaily extreme precipitation occurrences across the contiguous United States. *Journal of Geophysical Research: Atmospheres*, 122(14), 7401-7415.

ภาคผนวก

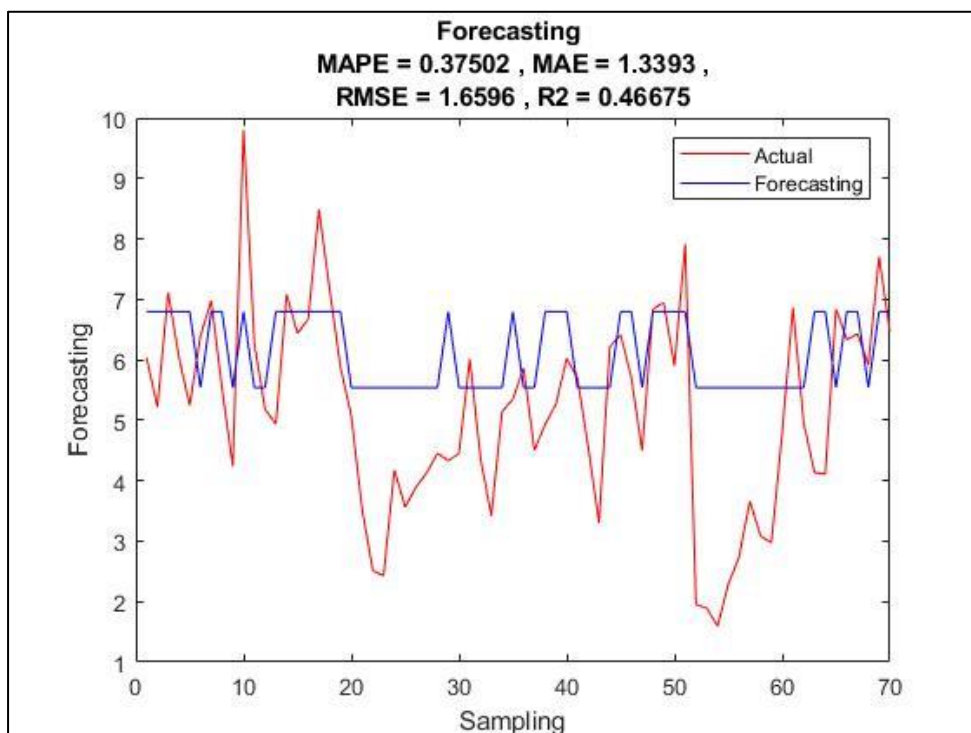
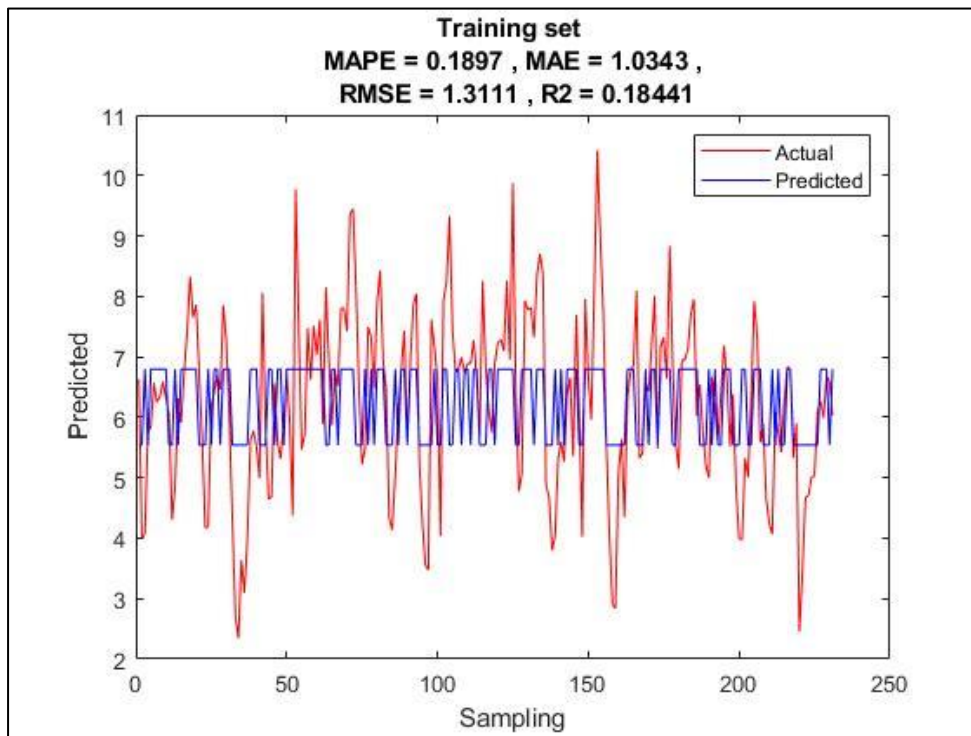
ภาคผนวก ก

ผลการวิเคราะห์ความแม่นยำของสถานการณ์ทั้ง 5 ของตัวแบบพยากรณ์ทั้ง 6 แบบ แยกตามฤดูกาล



ภาคผนวก ก-1 ผลการวิเคราะห์ความแม่นยำสำหรับข้อมูลขนาด 300 จำนวน ของตัวแบบพยากรณ์
ทั้ง 6 แบบ แยกตามฤดูกาล

1. ฤดูร้อน



1.1 Asadi-GA-ANN





1.2 Asadi-GA(New)-ANN



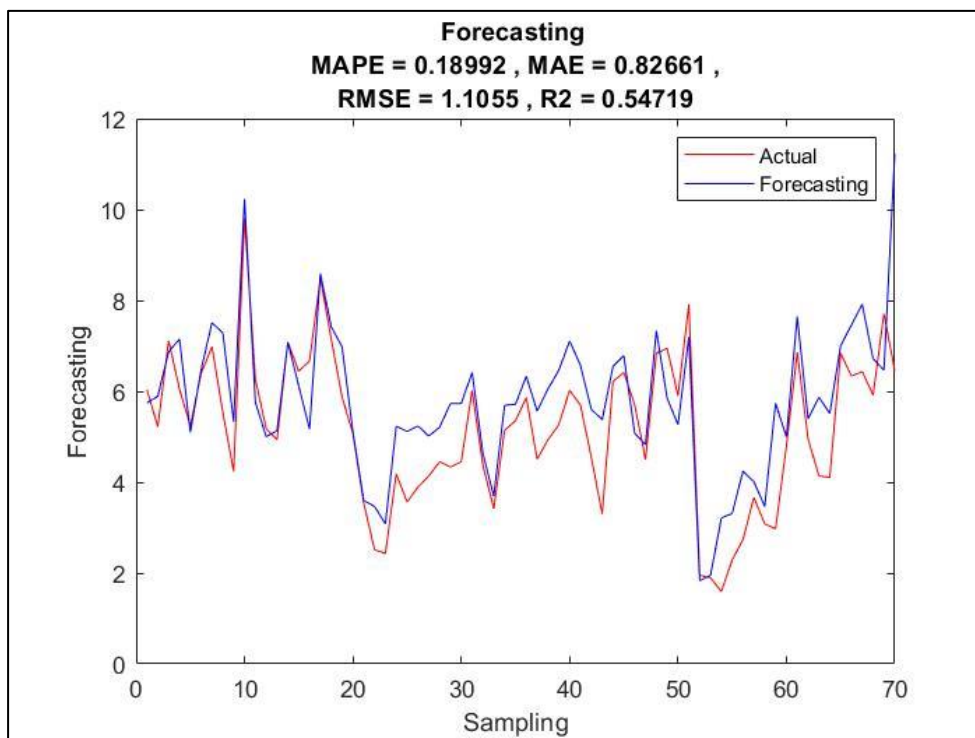

1.3 Asadi-GA-BPNN





1.4 Wang-GA-ANN



1.5 Wang-GA(New)-ANN





1.6 Wang-GA-BPNN





2. ฤๅฒณ



2.1 Asadi-GA-ANN





2.2 Asadi-GA(New)-ANN



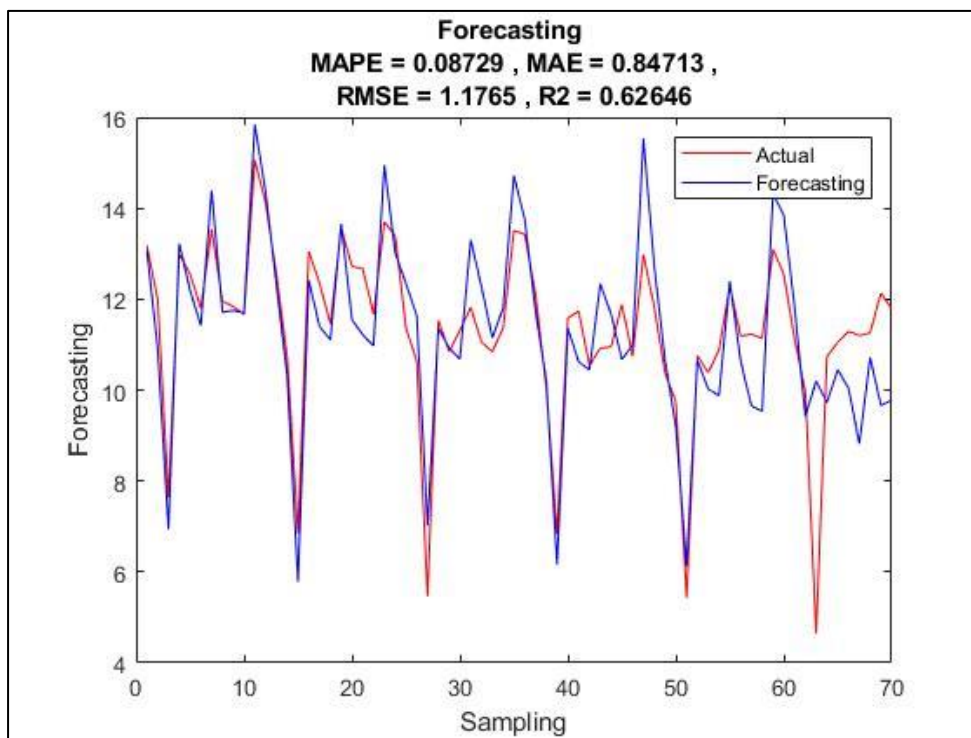

2.3 Asadi-GA-BPNN





2.4 Wang-GA-ANN



2.5 Wang-GA(New)-ANN





2.6 Wang-GA-BPNN





3. ฤดูหนาว



3.1 Asadi-GA-ANN





3.2 Asadi-GA(New)-ANN





3.3 Asadi-GA-BPNN





3.4 Wang-GA-ANN



3.5 Wang-GA(New)-ANN





3.6 Wang-GA-BPNN





ภาคผนวก ก-2 ผลการวิเคราะห์ความแม่นยำสำหรับข้อมูลขนาด 400 จำนวน ของตัวแบบพยากรณ์
ทั้ง 6 แบบ แยกตามฤดูกาล

1. ฤดูร้อน



1.1 Asadi-GA-ANN





1.2 Asadi-GA(New)-ANN





1.3 Asadi-GA-BPNN





1.4 Wang-GA-ANN



1.5 Wang-GA(New)-ANN





1.6 Wang-GA-BPNN





2. ฤๅฒณ



2.1 Asadi-GA-ANN





2.2 Asadi-GA(New)-ANN





2.3 Asadi-GA-BPNN





2.4 Wang-GA-ANN



2.5 Wang-GA(New)-ANN





2.6 Wang-GA-BPNN





3. ฤดูกาล



3.1 Asadi-GA-ANN





3.2 Asadi-GA(New)-ANN





3.3 Asadi-GA-BPNN





3.4 Wang-GA-ANN



3.5 Wang-GA(New)-ANN





3.6 Wang-GA-BPNN





ภาคผนวก ก-3 ผลการวิเคราะห์ความแม่นยำสำหรับข้อมูลขนาด 500 จำนวน ของตัวแบบพยากรณ์
ทั้ง 6 แบบ แยกตามฤดูกาล

1. ฤดูร้อน



1.1 Asadi-GA-ANN





1.2 Asadi-GA(New)-ANN





1.3 Asadi-GA-BPNN





1.4 Wang-GA-ANN



1.5 Wang-GA(New)-ANN





1.6 Wang-GA-BPNN





2. ฤกษ์ฝน



2.1 Asadi-GA-ANN





2.2 Asadi-GA(New)-ANN





2.3 Asadi-GA-BPNN





2.4 Wang-GA-ANN



2.5 Wang-GA(New)-ANN





2.6 Wang-GA-BPNN





3. ฤดูหนาว



3.1 Asadi-GA-ANN





3.2 Asadi-GA(New)-ANN





3.3 Asadi-GA-BPNN





3.4 Wang-GA-ANN



3.5 Wang-GA(New)-ANN





3.6 Wang-GA-BPNN





ภาคผนวก ก-4 ผลการวิเคราะห์ความแม่นยำสำหรับข้อมูลขนาด 1000 จำนวน ของตัวแบบพยากรณ์ทั้ง 6 แบบ แยกตามฤดูกาล

1. ฤดูร้อน



1.1 Asadi-GA-ANN





1.2 Asadi-GA(New)-ANN





1.3 Asadi-GA-BPNN





1.4 Wang-GA-ANN



1.5 Wang-GA(New)-ANN





1.6 Wang-GA-BPNN





2. ฤๅผๅน



2.1 Asadi-GA-ANN





2.2 Asadi-GA(New)-ANN





2.3 Asadi-GA-BPNN





2.4 Wang-GA-ANN



2.5 Wang-GA(New)-ANN





2.6 Wang-GA-BPNN





3. ฤดูหนาว



3.1 Asadi-GA-ANN





3.2 Asadi-GA(New)-ANN





3.3 Asadi-GA-BPNN





3.4 Wang-GA-ANN



3.5 Wang-GA(New)-ANN





3.6 Wang-GA-BPNN





ภาคผนวก ก-5 ผลการวิเคราะห์ความแม่นยำสำหรับข้อมูลขนาด 1100 จำนวน ของตัวแบบพยากรณ์ทั้ง 6 แบบ แยกตามฤดูกาล

1. ฤดูร้อน



1.1 Asadi-GA-ANN





1.2 Asadi-GA(New)-ANN





1.3 Asadi-GA-BPNN





1.4 Wang-GA-ANN



1.5 Wang-GA(New)-ANN





1.6 Wang-GA-BPNN





2. ฤๅผๅน



2.1 Asadi-GA-ANN





2.2 Asadi-GA(New)-ANN





2.3 Asadi-GA-BPNN





2.4 Wang-GA-ANN



2.5 Wang-GA(New)-ANN





2.6 Wang-GA-BPNN


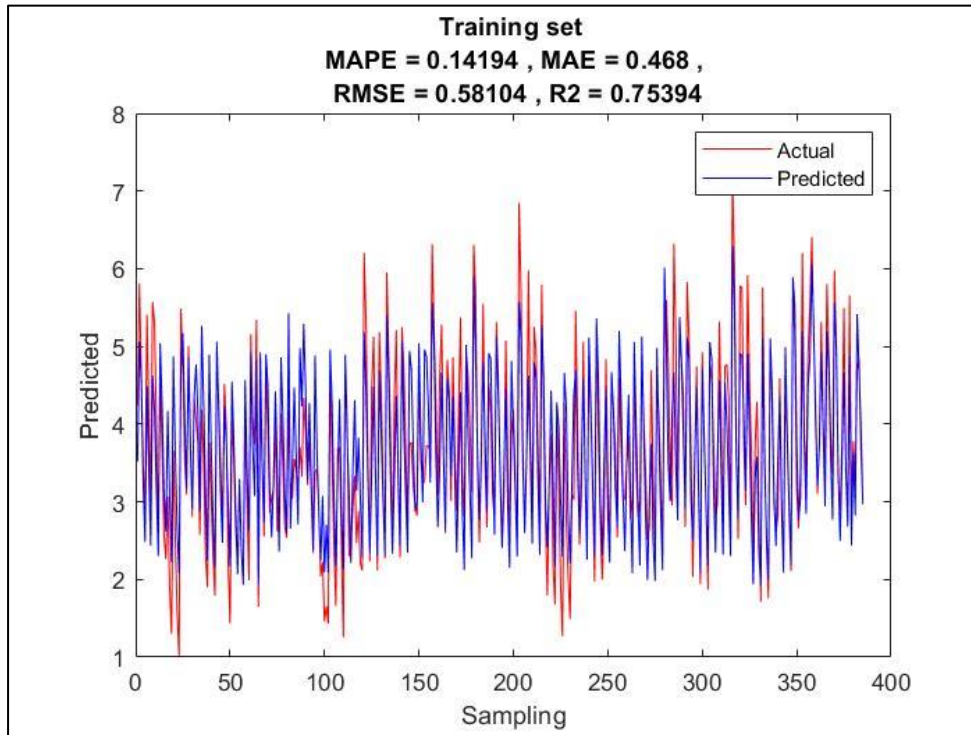


3. ฤดูหนาว



3.1 Asadi-GA-ANN





3.2 Asadi-GA(New)-ANN





3.3 Asadi-GA-BPNN





3.4 Wang-GA-ANN



3.5 Wang-GA(New)-ANN



3.6 Wang-GA-BPNN




ภาคผนวก ข

ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ที่ใช้
โครงข่ายประสาทเทียมที่มีการคัดเลือกแบบแข่งขันที่พัฒนาขึ้นของวิธี GA
(ตัวแบบพยากรณ์ Wang-GA(New)-ANN)

ภาคผนวก ข-1 ผลการพยากรณ์ปริมาณน้ำฝนในภาคกลางของประเทศไทยโดยใช้ตัวแบบพยากรณ์ Wang-GA(New)-ANN แยกตามฤดูกาล

1. ฤดูร้อน

1.1 ผลการวิเคราะห์ประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝน




1.2 ผลการวิเคราะห์ปริมาณน้ำฝนทั้ง 12 ตำแหน่ง

ตำแหน่ง	พ.ศ.	ปริมาณน้ำฝน	พ.ศ.	ปริมาณน้ำฝน	พ.ศ.	ปริมาณน้ำฝน	พ.ศ.	ปริมาณน้ำฝน	พ.ศ.	ปริมาณน้ำฝน
1	2562	6.1645	2563	6.4914	2564	3.1324	2565	6.7584	2566	6.9618
2	2562	4.4227	2563	5.2098	2564	1.9733	2565	5.6110	2566	6.1718
3	2562	4.0723	2563	4.2031	2564	1.9724	2565	4.2257	2566	4.8392
4	2562	3.1045	2563	3.5351	2564	2.4066	2565	4.6568	2566	5.3329
5	2562	3.2502	2563	3.2919	2564	1.6069	2565	2.8718	2566	4.4435
6	2562	5.3889	2563	6.7352	2564	1.9275	2565	6.1836	2566	7.2242
7	2562	5.2818	2563	6.1043	2564	2.9437	2565	6.5357	2566	7.0575
8	2562	5.6162	2563	5.3706	2564	3.7499	2565	6.1519	2566	7.1829
9	2562	5.4731	2563	5.7759	2564	3.3541	2565	5.9340	2566	6.9797
10	2562	5.4818	2563	6.9466	2564	3.4642	2565	7.4118	2566	7.2830
11	2562	5.9572	2563	6.8580	2564	5.1617	2565	7.8871	2566	6.5214
12	2562	6.3511	2563	6.1670	2564	5.4053	2565	6.7278	2566	5.7943

2. ฤดูฝน

2.1 ผลการวิเคราะห์ประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝน




2.2 ผลการวิเคราะห์ปริมาณน้ำฝนทั้ง 12 ตำแหน่ง

ตำแหน่ง	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน
1	2562	13.7589	2563	13.7450	2564	14.6844	2565	13.6807	2566	13.6794
2	2562	13.4728	2563	13.4076	2564	11.7390	2565	12.6735	2566	14.0092
3	2562	12.1479	2563	11.7166	2564	10.8679	2565	11.2006	2566	12.3542
4	2562	10.7337	2563	9.9271	2564	9.8582	2565	9.8480	2566	10.8276
5	2562	14.0411	2563	5.9957	2564	7.1589	2565	10.6603	2566	5.5891
6	2562	10.7692	2563	11.3116	2564	10.3254	2565	10.7196	2566	12.5317
7	2562	11.2728	2563	11.2593	2564	9.9231	2565	11.0976	2566	12.0193
8	2562	11.3306	2563	10.7405	2564	11.2884	2565	10.9936	2566	11.3256
9	2562	12.7974	2563	12.0884	2564	13.1141	2565	11.2083	2566	11.5427
10	2562	11.3816	2563	11.1338	2564	11.5268	2565	10.8671	2566	12.8096
11	2562	11.5342	2563	11.5681	2564	11.0546	2565	11.5648	2566	12.7827
12	2562	11.5528	2563	11.0356	2564	11.0055	2565	10.8912	2566	11.6448

3. ฤดูกาล

3.1 ผลการวิเคราะห์ประสิทธิภาพความแม่นยำของตัวแบบพยากรณ์ปริมาณน้ำฝน



3.2 ผลการวิเคราะห์ปริมาณน้ำฝนทั้ง 12 ตำแหน่ง

ตำแหน่ง	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน	พ.ศ.	ปริมาณ น้ำฝน
1	2562	5.4394	2563	6.1115	2564	6.3194	2565	6.4135	2566	7.2025
2	2562	4.5148	2563	5.3252	2564	6.1518	2565	5.5107	2566	5.8848
3	2562	3.0300	2563	3.6776	2564	4.2740	2565	3.8818	2566	3.9070
4	2562	2.4882	2563	2.5948	2564	3.5377	2565	2.9451	2566	2.8961
5	2562	3.1879	2563	3.2824	2564	3.4016	2565	3.9139	2566	3.5934
6	2562	4.5235	2563	5.8641	2564	5.4900	2565	5.2828	2566	5.8748
7	2562	3.1049	2563	4.6404	2564	3.9940	2565	3.1852	2566	3.7307
8	2562	1.9986	2563	2.8571	2564	3.0663	2565	2.9506	2566	3.1613
9	2562	4.5691	2563	5.4674	2564	5.6621	2565	5.1364	2566	5.4786
10	2562	3.4629	2563	5.3195	2564	4.9015	2565	4.3973	2566	4.7684
11	2562	2.7704	2563	4.3602	2564	3.9648	2565	3.6433	2566	3.4703
12	2562	2.3388	2563	3.3566	2564	3.0639	2565	2.7666	2566	3.2662

ภาคผนวก ค

เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์

ที่ ๐๖๙/๒๕๖๑



เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์
วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา
มหาวิทยาลัยบูรพา

๑. ชื่อเรื่องคุณิพนธ์

ชื่อเรื่อง: การพัฒนาการคัดเลือกแบบแข่งขันของวิธีทางพันธุกรรมสำหรับการพยากรณ์ปริมาณน้ำฝน
โดยใช้โครงข่ายประสาทเทียม

TITLE: DEVELOPMENT OF TOURNAMENT SELECTION OF GENETIC ALGORITHM FOR RAINFALL
FORECASTING MODEL USING ARTIFICIAL NEURAL NETWORK

๒. ชื่อนิสิต: นางสาวปิยธิดา ต.ไชยสุวรรณ

หลักสูตร ปรัชญาดุษฎีบัณฑิต (Ph.D.) สาขาวิชา การวิจัยและสถิติทางวิทยาการปัญญา
รหัส ๕๗๘๑๐๐๑๗

๓. ผลการพิจารณาของคณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์

คณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา
มหาวิทยาลัยบูรพา ได้พิจารณาแล้วเห็นว่า คำขอคุณิพนธ์ดังกล่าวเป็นไปตามหลักการของจริยธรรม
การวิจัยในมนุษย์ โดยที่ผู้วิจัยเคารพสิทธิและศักดิ์ศรีในความเป็นมนุษย์ ไม่มีการล่วงละเมิดสิทธิ สวัสดิภาพ
และไม่ก่อให้เกิดอันตรายแก่ตัวอย่างการวิจัย กลุ่มตัวอย่าง และผู้เข้าร่วมในโครงการวิจัย

จึงเห็นสมควรให้ดำเนินการวิจัยในขอบข่ายของคำขอคุณิพนธ์ที่เสนอได้ ตั้งแต่วันที่ออกเอกสาร
รับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์ฉบับนี้ จนถึงวันที่ ๒๙ กรกฎาคม พ.ศ. ๒๕๖๓

ออกให้ ณ วันที่ ๓๐ ตุลาคม พ.ศ. ๒๕๖๑

ลงนาม

(ผู้ช่วยศาสตราจารย์ ดร.ภัทราวดี มากมี)
คณบดีวิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา
มหาวิทยาลัยบูรพา