



การทำนายดัชนีคุณภาพน้ำโดยใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมกับขั้นตอนวิธีหาค่าเหมาะสม  
ที่สุดแบบกลุ่มอนุภาค

PREDICTION OF WATER QUALITY INDEX USING A EXTREME LEARNING MACHINE  
WITH PARTICLE SWARM OPTIMIZATION ALGORITHM

พรภวิษย์ สารบูรณ์

การทำนายดัชนีคุณภาพน้ำโดยใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตริมกับขั้นตอนวิธีหาค่าเหมาะสม  
ที่สุดแบบกลุ่มอนุภาค



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล  
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ  
ปีการศึกษา 2565  
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

PREDICTION OF WATER QUALITY INDEX USING A EXTREME LEARNING MACHINE  
WITH PARTICLE SWARM OPTIMIZATION ALGORITHM



PORNPAWIT SARABOON

A Master's Project Submitted in Partial Fulfillment of the Requirements  
for the Degree of MASTER OF SCIENCE  
(Data Science)

Faculty of Science, Srinakharinwirot University

2022

Copyright of Srinakharinwirot University

สารนิพนธ์  
เรื่อง  
การทำนายดัชนีคุณภาพน้ำโดยใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมกับขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่ม  
อนุภาค  
ของ  
พรภวิษย์ สารบูรณ์

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล  
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)  
คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก ..... ประธาน  
(อาจารย์ ดร.ศุภร คนธภาคี) (ผู้ช่วยศาสตราจารย์ ดร.รัตน์ชัยนันท์ ธรรมสุจริต)  
..... กรรมการ  
(อาจารย์ ดร.โสภณ มงคลลักษณ์)

ชื่อเรื่อง	การทำนายดัชนีคุณภาพน้ำโดยใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมกับขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค
ผู้วิจัย	พรภวิษย์ สารบุรณ
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2565
อาจารย์ที่ปรึกษา	อาจารย์ ดร. ศุภร คนธภักดี

น้ำจืดเป็นองค์ประกอบที่สำคัญมาก โดยถ้าแบ่งน้ำจืดออกเป็น 100 ส่วนจะมีเพียง 0.3 ส่วนเท่านั้นที่เป็นน้ำบนผิวดินที่มนุษย์สามารถนำไปใช้ได้ ซึ่งในปัจจุบันปัญหาแหล่งน้ำเสื่อมโทรมนั้นเป็นปัญหาที่หลายๆประเทศนั้นเผชิญอยู่รวมถึงประเทศไทย ในการจัดการปัญหาเรื่องคุณภาพน้ำนั้นจะอาศัยการประเมินคุณภาพน้ำของแหล่งน้ำบนผิวดินโดยใช้ดัชนีคุณภาพน้ำ (Water Quality Index :WQI) มาใช้ในการวิเคราะห์เพื่อตัดสินใจ และจัดการปัญหาของคุณภาพ ซึ่งในงานวิจัยนี้ได้นำเทคนิคเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme learning machine : ELM) ร่วมกับนำขั้นตอนวิธีหาค่าที่เหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle swarm optimization algorithm : PSO) หรือเรียกว่า PSO-ELM มาใช้ในการทำนายค่าดัชนีคุณภาพน้ำ โดยจะนำค่าน้ำหนักของโหนดผลลัพธ์ที่ได้จาก ELM ไปทำการปรับเพื่อหาค่าที่ดีที่สุด ที่จะทำให้แบบจำลองทำนายค่าดัชนีคุณภาพน้ำได้แม่นยำยิ่งขึ้น โดยผลที่ได้นั้น PSO-ELM มีค่า RMSE ที่ใกล้เคียงกับแบบจำลอง ELM และแบบจำลอง PSO-ELM นั้นจะใช้เวลาในการประมวลผลมากกว่าแบบจำลอง ELM ซึ่งการใช้แบบจำลอง PSO-ELM ในการปรับค่าน้ำหนักของโหนดผลลัพธ์อาจจะไม่เหมาะสมนักเมื่อเทียบกับเวลาในการประมวลผล ดังนั้นในการใช้งานแบบจำลอง PSO-ELM นั้นควรนำไปใช้ปรับค่าอื่นๆ เช่น จำนวนโหนดชั้นซ่อน (hidden node), ค่าน้ำหนักของโหนดรับเข้า (input weight) หรือ ค่าเอนเอียง (bias) ซึ่งจะทำให้ความแม่นยำของแบบจำลองได้ดีกว่า

คำสำคัญ : เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม, ขั้นตอนวิธีหาค่าที่เหมาะสมที่สุดแบบกลุ่มอนุภาค, ดัชนีคุณภาพน้ำ

Title	PREDICTION OF WATER QUALITY INDEX USING A EXTREME LEARNING MACHINE WITH PARTICLE SWARM OPTIMIZATION ALGORITHM
Author	PORNPAWIT SARABOON
Degree	MASTER OF SCIENCE
Academic Year	2022
Thesis Advisor	Subhorn Khonthapagdee , Ph.D.

Fresh water is a crucial component of all life. However, only 0.3 of a hundred parts of fresh water that can be used by people are surface waters. Nowadays, many nations, including Thailand, are concerned about the issue of water pollution. To manage the water quality problem, water quality assessment of surface water sources is conducted using the Water Quality Index (WQI) to make decisions and deal with quality problems. In this research, extreme machine learning (ELM) techniques were used with the particle swarm optimization algorithm (PSO), known as PSO-ELM. This was used to predict the water quality index. The weight of the output node obtained from the ELM were adjusted to find the best value to make the model more accurate in predicting the water quality index. As a result, PSO-ELM has similar RMSE values to ELM model. However, PSO-ELM models require more computation time than ELM models. The results may not be optimal compared to the processing time. Therefore, when using the PSO-ELM model, it should be used to adjust other parameters, such as the number of hidden nodes, the input weight, or the bias of the model.

Keyword : Extreme Learning Machine, Particle Swarm Optimization, Machine Learning

## กิตติกรรมประกาศ

ขอขอบพระคุณมารดา และครอบครัวที่คอยให้กำลังใจตลอดมา

ขอขอบพระคุณอาจารย์ ดร. ศุภร คนธภักดิ์ ที่ให้ความกรุณามาเป็นอาจารย์ที่คอยสอนและให้คำแนะนำต่างๆด้วยความเอาใจใส่ตลอดมา

ขอขอบพระคุณอาจารย์ในสาขาต่างๆท่านที่คอยเตือน ให้คำปรึกษา และความรู้ต่างๆ

ขอขอบพระคุณส่วนแหล่งน้ำจืด กองจัดการคุณภาพน้ำ กรมควบคุมมลพิษที่ให้ออนุเคราะห์ข้อมูลในการทำวิจัย

ขอบคุณคุณศิริลักษณ์ ศิริคะรินทร์ที่แบ่งปันข้อมูลที่ใช้ในการทำวิจัย ช่วยดำเนินการจัดทำหนังสือขออนุเคราะห์ชุดข้อมูลค่าดัชนีคุณภาพน้ำ และเป็นพี่ที่ดีคอยให้คำปรึกษาตลอด

ขอบคุณคุณอมรกานต์ ใจดี และคุณณัชชา ชินนาพันธ์ที่คอยเตือนเรื่องเอกสาร และคอยกระตุ้นให้ทำวิจัยอยู่ตลอด ขอขอบคุณที่มาเรียนเป็นเพื่อนกัน

ขอบคุณพี่ๆ เพื่อนๆ น้องๆ ที่เรียนด้วยกันที่คอยเตือน คอยให้คำปรึกษา และสุดท้ายสารนิพนธ์นี้จะไม่สามารถสำเร็จได้ถ้าขาดทุกๆท่านที่กล่าวมา

พรภวิษย์ สารบุรณ์

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	ง
บทคัดย่อภาษาอังกฤษ .....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ .....	ช
สารบัญตาราง.....	ฌ
สารบัญรูปภาพ .....	ญ
บทที่ 1 บทนำ.....	1
ที่มาและความสำคัญ .....	1
วัตถุประสงค์ของงานวิจัย .....	4
ขอบเขตของงานวิจัย .....	4
วิธีการดำเนินงานวิจัย .....	5
สมมติฐานในการวิจัย.....	5
ประโยชน์ที่คาดว่าจะได้รับ.....	5
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	6
2.1 ทฤษฎีที่เกี่ยวข้อง .....	6
2.1.1 โครงข่ายประสาทเทียม (Neural Network : NN) .....	6
2.1.2 เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme Learning Machine : ELM) .....	10
2.1.3 ขั้นตอนวิธีเชิงวิวัฒนาการ (Evolutionary Algorithm) .....	12
2.1.4 ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization Algorithm) .....	14
2.2 งานวิจัยที่เกี่ยวข้อง.....	16



บทที่ 3 การดำเนินงานวิจัย .....	28
3.1 การออกแบบโครงสร้างวิธีดำเนินงานวิจัย .....	28
3.2 การจัดเตรียมชุดข้อมูล .....	29
3.2.1 ชุดข้อมูล.....	29
3.2.2 การทำความสะอาด.....	29
3.2.3 การปรับมาตราส่วนข้อมูล (Data scaling) .....	30
3.2.4 การแบ่งข้อมูล .....	31
3.3 การสร้างแบบจำลอง .....	31
3.3.1 แบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (ELM).....	31
3.3.2 แบบจำลองขั้นตอนวิธีหาค่าเหมาะสมที่สุด – เครื่องจักรเรียนรู้แบบ เอ็กซ์ตรีม (PSO-ELM).....	33
3.4 การประเมินประสิทธิภาพของแบบจำลอง (Performance Evaluation) .....	35
บทที่ 4 ผลการดำเนินงานวิจัย.....	37
บทที่ 5 สรุปผลการวิจัย อภิปรายผลและข้อเสนอแนะ .....	42
สรุปผลการวิจัย.....	42
อภิปรายผล .....	43
ข้อเสนอแนะ .....	44
บรรณานุกรม .....	46
ประวัติผู้เขียน.....	50

## สารบัญตาราง

หน้า

ตาราง 1 แสดงการเปรียบเทียบความแม่นยำของฟังก์ชันกระตุ้นที่มีจำนวนโหนดชั้นซ่อนแตกต่างกัน	17
ตาราง 2 แสดงการเปรียบเทียบความแม่นยำและความเร็วในการฝึกสอนระหว่างสองแบบจำลอง	18
ตาราง 3 แสดงการเปรียบเทียบความแม่นยำระหว่าง ELM และ PSO-ELM	19
ตาราง 4 แสดงผลการเปรียบเทียบประสิทธิภาพระหว่าง ELM และ PSO-ELM	20
ตาราง 5 แสดงการเปรียบเทียบค่า RMSE, MAE และ R-squared	21
ตาราง 6 แสดงพารามิเตอร์ของ PSO-ELM	22
ตาราง 7 ค่าความแม่นยำของ PSO-ELM ที่เปรียบเทียบกับแบบจำลองอื่นๆ	23
ตาราง 8 การเปรียบเทียบผลการจำแนกประเภทของ ELM (FS หมายถึงการเลือกคุณสมบัติ)	24
ตาราง 9 สรุปผลการทำงานของแบบจำลองประยุกต์สำหรับทำนายส่วนประกอบคุณภาพน้ำ	25
ตาราง 10 แสดงประสิทธิภาพของแบบจำลอง BPNN	27
ตาราง 11 แสดงประสิทธิภาพของแบบจำลอง RBFNN	27
ตาราง 12 แสดงค่า hyper-parameter ที่กำหนดให้กับแบบจำลอง ELM	32
ตาราง 13 แสดงค่า hyper-parameter ที่กำหนดให้กับ PSO algorithm	34
ตาราง 14 แสดงผลค่า RMSE ของชุดข้อมูลทดสอบ ฟังก์ชันกระตุ้น (Activate function) ที่ดีที่สุด	37
ตาราง 15 แสดงผลการทดลองของแบบจำลอง ELM	37
ตาราง 16 แสดงผลการทดลองของ PSO-ELM ที่มีจำนวนโหนดชั้นซ่อน 50 โหนด	38

## สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 โครงข่ายประสาททางชี้ระ.....	7
ภาพประกอบ 2 โครงข่ายประสาทเทียม.....	7
ภาพประกอบ 3 แสดงสถาปัตยกรรมของโครงข่ายประสาทเทียม.....	8
ภาพประกอบ 4 Feedforward Neural Network (FNN) และ Recurrent Neural Networks (RNN).....	9
ภาพประกอบ 5 โครงสร้างของ Single-Hidden Layer Feedforward Network (SLFNs).....	10
ภาพประกอบ 6 กระบวนการของขั้นตอนวิธีเชิงวิวัฒนาการ.....	13
ภาพประกอบ 7 กระบวนการทำงานของขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค.....	15
ภาพประกอบ 8 สรุปผลการทำงานของแบบจำลองประยุกต์สำหรับทำนายส่วนประกอบคุณภาพน้ำ.....	28
ภาพประกอบ 9 รายละเอียดทางสถิติของแต่ละคุณลักษณะ.....	30
ภาพประกอบ 10 การกระจายตัวของข้อมูลในแต่ละคุณลักษณะ.....	31
ภาพประกอบ 11 ขั้นตอนการทำงานของ ELM-PSO.....	35
ภาพประกอบ 12 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 1.....	39
ภาพประกอบ 13 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 2.....	39
ภาพประกอบ 14 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 3.....	40
ภาพประกอบ 15 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 4.....	40
ภาพประกอบ 16 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 5.....	41
ภาพประกอบ 17 แสดงผลรวมความแตกต่างของ beta ในแต่ละการทดลองแบบจำลอง PSO-ELM กับแบบจำลอง ELM เปรียบเทียบกับ Baseline ค่า RMSE ของแบบจำลอง ELM.....	41

## บทที่ 1

### บทนำ

#### ที่มาและความสำคัญ

น้ำจืดเป็นองค์ประกอบที่สำคัญของสิ่งมีชีวิตต่างๆ แม้ว่าจะเป็นทรัพยากรหมุนเวียนแต่น้ำจืดนั้นคิดเป็นเพียง 3 เปอร์เซ็นต์ของปริมาณน้ำทั้งหมดบนโลก โดยถ้าแบ่งน้ำจืดออกเป็น 100 ส่วนนั้นจะสามารถแบ่งออกได้เป็นน้ำที่ถูกกักเก็บในรูปแบบน้ำแข็ง หิมะ ประมาณ 68.7 ส่วน, เป็นน้ำใต้ดิน ประมาณ 30.1 ส่วน, เป็นความชื้นในดินและบรรยากาศ ประมาณ 0.9 ส่วน และมีเพียง 0.3 ส่วนเท่านั้นที่เป็นน้ำบนผิวดินที่มนุษย์สามารถนำไปใช้ได้

ในปัจจุบันการเพิ่มขึ้นของจำนวนประชากร รวมทั้งการเจริญเติบโตทางเศรษฐกิจของโลกนั้นทำให้มีความต้องการใช้น้ำเพิ่มขึ้นในทุกภาคส่วน ซึ่งมีความเป็นไปได้สูงที่จะส่งผลให้มีความเสี่ยงต่อวิกฤตน้ำ มีรายงานสถานการณ์น้ำของโลกชี้ให้เห็นว่าประชากร 1 ใน 5 คน ไม่สามารถเข้าถึงน้ำสะอาด ขาดแคลนน้ำดื่ม และประชากรครึ่งหนึ่งของโลกขาดแคลนน้ำสะอาดตามสุขาภิบาล ประชากรมากกว่า 5 ล้านคนตายด้วยโรคที่เกิดจากน้ำไม่สะอาดในรอบ 10 ปีที่ผ่านมา สถาบันจัดการน้ำระหว่างประเทศ (IWMI) ประมาณการว่าในราวปี ค.ศ. 2025 ประชากร 4,000 ล้านคน ใน 48 ประเทศจะเผชิญกับปัญหาขาดแคลนน้ำถ้าหากในปัจจุบันยังมีการใช้น้ำฟุ่มเฟือยอยู่

ในส่วนของประเทศไทยนั้นได้เผชิญกับปัญหาเกี่ยวกับน้ำอย่างต่อเนื่อง อาทิเช่น ภัยแล้งที่รุนแรง ปริมาณน้ำสำรองในเขื่อนและอ่างเก็บน้ำไม่เพียงพอ ปัญหาที่มีสาเหตุมาจากชุมชนเมืองภาคอุตสาหกรรม และภาคเกษตรกรรมที่ทำให้แหล่งน้ำเสื่อมโทรม และมีสารพิษปนเปื้อน รวมไปถึงอุทกภัย ซึ่งวิกฤตน้ำดังกล่าวได้สร้างความเสียหายต่อเศรษฐกิจ สังคม และการดำรงชีวิตของประชากรในประเทศอย่างมหาศาล และยังมีแนวโน้มที่ความรุนแรงจะเพิ่มขึ้น ซึ่งสาเหตุเหล่านี้เกิดจากหลายปัจจัย ทั้งยังขาดการบริหารจัดการน้ำอย่างมีประสิทธิภาพ พฤติกรรมการใช้น้ำ ความต้องการใช้น้ำที่เพิ่มมากขึ้น รวมไปถึงการเปลี่ยนแปลงทางสภาพอากาศและภาวะโลกร้อน

ปัญหาแหล่งน้ำเสื่อมโทรมนั้นสาเหตุส่วนใหญ่เกิดมาจากการทิ้งน้ำ และสิ่งปฏิกูลจากแหล่งชุมชน เช่น น้ำที่ใช้ซักฟอกส่วนใหญ่มีสารอินทรีย์ปะปนกับน้ำทิ้ง น้ำเสียจากโรงงานอุตสาหกรรม เช่น ถ้าโรงงานมีการลักลอบทิ้งน้ำเสียลงในแหล่งน้ำจะทำให้น้ำเน่าเสียเพราะมีปริมาณมากและมีสารปนเปื้อนในอัตราที่สูง น้ำเสียที่เกิดจากธรรมชาติ เช่น การเน่าเสียของน้ำเมื่ออยู่ในสภาพที่นิ่งไม่มีการไหลเวียนถ่ายเท และเกิดจากการทำเกษตร เนื่องจากการทำเกษตรส่วนใหญ่ใช้น้ำยาปราบศัตรูพืชกันมากขึ้น ซึ่งทำให้มีสารตกค้าง เมื่อฝนตกจะพัดพาเอาสารเคมีที่

ตกค้างอยู่นั้นลงสู่แหล่งน้ำทำให้เกิดมลพิษทางน้ำได้ ซึ่งมีผลกระทบหลายอย่างไม่ว่าจะเป็นกระทบต่อวงจรชีวิตของสัตว์น้ำ เพราะน้ำเสียที่ปนเปื้อนสารพิษอาจจะทำให้สัตว์น้ำตาย ถ้าน้ำเสียที่เกิดจากออกซิเจนในน้ำลดลงก็อาจจะทำให้พืชและสัตว์น้ำเล็กที่เป็นอาหารของปลานั้นถูกทำลาย ทำให้แหล่งอาหารของสัตว์น้ำนั้นไม่อุดมสมบูรณ์ อาจทำให้เป็นแหล่งแพร่ระบาดของเชื้อโรคไม่ว่าจะเป็น อหิวาตกโรค บิด และท้องเสีย และยังมีผลกระทบต่อเพาะปลูก เพราะน้ำเสียที่มีความเป็นกรดและด่างไม่เหมาะสมสำหรับทำการเกษตรอีกด้วย

ในการประเมินคุณภาพคุณภาพน้ำของแหล่งน้ำบนพื้นดินนั้น หรือแหล่งน้ำจืดในแม่น้ำนั้นประเทศไทยมีหน่วยงานที่ตรวจสอบคุณภาพแหล่งน้ำที่สำคัญ คือ สำนักงานจัดการคุณภาพน้ำ กรมควบคุมมลพิษโดยใช้ดัชนีคุณภาพน้ำ (Water Quality Index :WQI) ที่มีช่วงคะแนนจาก 0 ถึง 100คะแนน และแบ่งออกเป็น 5 ระดับ ได้แก่ ช่วง 91-100 คะแนน จัดเป็นคุณภาพน้ำอยู่ในเกณฑ์ดีมาก ช่วง 71-90 คะแนน จัดเป็นคุณภาพน้ำอยู่ในเกณฑ์ดี ช่วง 61-70 คะแนน จัดเป็นคุณภาพน้ำอยู่ในเกณฑ์พอใช้ ช่วง 31-60 คะแนน จัดเป็นคุณภาพน้ำอยู่ในเกณฑ์เสื่อมโทรม ช่วง 0-30 คะแนน จัดเป็นคุณภาพน้ำอยู่ในเกณฑ์เสื่อมโทรมมาก ซึ่งจะพิจารณาจากเกณฑ์ทั้ง 5 นี้ที่ผู้เชี่ยวชาญให้คะแนนโดยตรวจสอบวัดปริมาณค่าต่างๆจากแหล่งน้ำนั้นๆ โดยค่าที่จะนำมาพิจารณานั้นได้แก่ 1. ปริมาณออกซิเจนที่ละลายในน้ำ (DO) 2. ปริมาณความสกปรกในรูปแบบสารอินทรีย์ (BOD, Biological Oxygen Demand) 3. ปริมาณการปนเปื้อนของแบคทีเรียกลุ่มโคลิฟอร์มทุกชนิด (TCB, Total Coliform Bacteria) 4. ปริมาณการปนเปื้อนของแบคทีเรียกลุ่มฟิคอลโคลิฟอร์ม (FCB, Fecal Coliform Bacteria) 5. ปริมาณแอมโมเนียที่มาจากปุ๋ยเคมี การเกษตร การขับถ่าย อาหารสัตว์น้ำ ซึ่งประโยชน์ของดัชนีคุณภาพน้ำจะช่วยให้แปลความหมายของข้อมูลคุณภาพของน้ำ ที่ได้จากการวิเคราะห์ให้อยู่ในรูปแบบที่ง่ายต่อการเข้าใจเป็นเครื่องมือที่สำคัญ ในการหาแนวโน้ม หาเงื่อนไขที่สำคัญ ทางสิ่งแวดล้อม ดัชนีชี้วัดคุณภาพน้ำ สามารถใช้บ่งบอกคุณลักษณะของน้ำนั้นว่าอยู่ในหลักเกณฑ์ใด ซึ่งมีประโยชน์อย่างมากในด้านการบริหารจัดการน้ำ แบ่งประเภทของน้ำ เพื่อการใช้ประโยชน์ในด้านต่างๆ และบอกได้ถึงพฤติกรรมการใช้ น้ำในบริเวณที่ทำการตรวจวัดว่าบริเวณนั้นมีการปล่อยมลพิษทางน้ำหรือไม่อย่างไร แหล่งที่ทำการตรวจสอบอยู่ในเขตอุตสาหกรรมหรือไม่โดยสามารถนำ ดัชนีชี้วัดคุณภาพน้ำ มาวิเคราะห์และกำหนดแผนการจัดการน้ำ หรือมาตรการการจัดการแหล่งน้ำ เพื่อให้แหล่งน้ำ บริเวณนั้นมีคุณภาพน้ำที่ดีขึ้นและเหมาะสมกับการอุปโภคบริโภคได้อย่างมีประสิทธิภาพ และช่วยในตัดสินใจในการกำหนดนโยบายของรัฐบาลเพื่อให้เกิดประสิทธิภาพสูงสุด กล่าวคือ ดัชนีชี้วัดคุณภาพน้ำ

สามารถช่วยตัดสินใจในเรื่อง การจัดสรรทรัพยากร, การจัดอันดับในการจัดสรร, มาตรฐานในการ บังคับ, การวิเคราะห์แนวโน้มและการให้ข้อมูลต่อสาธารณะ (กรมควบคุมมลพิษ, 2557)

ในกระบวนการวัดและจัดเก็บค่าปริมาณสารต่างๆจากแหล่งน้ำที่จะนำมาคำนวณค่า ดัชนีคุณภาพน้ำนั้นจะถูกดำเนินการโดยสถานีตรวจวัดคุณภาพน้ำอัตโนมัติ ซึ่งอยู่ในแหล่งน้ำต่างๆ ทั้งหมด 75 สถานี กระจายอยู่ใน 45 จังหวัดและครอบคลุมแหล่งน้ำที่สำคัญ จำนวน 31 แหล่งน้ำ ซึ่งสถานีตรวจวัดคุณภาพน้ำอัตโนมัติจะจัดเก็บค่าอุณหภูมิน้ำ, ความเป็นกรด-ด่าง (PH), ออกซิเจนที่ละลาย (DO), การนำไฟฟ้า (Conductivity) และความขุ่น (Turbidity) โดยสถานี ตรวจวัดคุณภาพน้ำอัตโนมัติจะทำการสูบน้ำทุกช่วง 30 นาที และทำการตรวจวัด จากนั้นจะเก็บ บันทึกไว้ในเครื่องบันทึกข้อมูล (Data Logger) และส่งข้อมูลผ่านทางโทรศัพท์เคลื่อนที่ไปยังระบบ ฐานข้อมูลคุณภาพน้ำ และในการจัดเก็บปริมาณค่าสารอื่นๆที่นอกเหนือจากสถานีตรวจวัด คุณภาพน้ำแล้วนั้นจะเป็นการเก็บตัวอย่างน้ำเพื่อนำไปตรวจสอบปริมาณสารอื่นๆในห้องทดลอง อาทิเช่น ค่าปริมาณความสกปรกในรูปแบบสารอินทรีย์ (BOD), ค่าปริมาณการปนเปื้อนของ แบคทีเรียกลุ่มโคลิฟอร์มทุกชนิด (TCB), ค่าปริมาณการปนเปื้อนของแบคทีเรียกลุ่มฟีคอลโคลิ ฟอร์ม (FCB) หรือค่าปริมาณแอมโมเนีย จากนั้นจะต้องทำการตรวจสอบข้อมูลและบันทึกลง ฐานข้อมูลจนแล้วเสร็จ จากนั้นจึงคำนวณค่าดัชนีวัดคุณภาพน้ำเพื่อประเมินสถานการณ์น้ำ (กรม ควบคุมมลพิษ, 2565)

สำหรับงานวิจัยนี้นั้นจะเป็นการนำเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme learning machine : ELM) ซึ่งเป็นโครงข่ายประสาทเทียม (Neural network) ประเภทหนึ่งร่วมกับขั้นตอนวิธี หาค่าที่เหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle swarm optimization algorithm : PSO) มาใช้ ในการทำนายค่าดัชนีคุณภาพน้ำ (Water quality index : WQI) เพื่อเป็นแนวทางนำไป ประยุกต์ใช้กับระบบการวัดและคำนวณค่าดัชนีคุณภาพน้ำที่สามารถทำได้อย่างอัตโนมัติ โดย ใช้แบบจำลองดังกล่าวในการทำนายค่าดัชนีคุณภาพน้ำ

เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme learning machine : ELM) เป็นโครงข่าย ประสาทเทียมแบบป้อนไปข้างหน้า (Single Layer Feed Forward : SLFN) ที่มีความรวดเร็วใน การประมวลผลกว่าโครงข่ายประสาทเทียมแบบดั้งเดิมมากโดยใช้วิธีการกำหนดค่าน้ำหนักและ เอนเอียงที่นำมาใช้สำหรับโหนดชั้นซ่อน (Hidden layer node) ด้วยการสุ่มแทนที่การวนปรับค่า น้ำหนัก (Backpropagation) แบบโครงข่ายประสาทเทียมทั่วไป และในส่วนของค่าน้ำหนักของ ชั้นผลลัพธ์ (Output layer) จะใช้วิธีการคำนวณเมตริกซ์ผกผันแบบมอร์-เพนโรส (Moore- Penrose) ซึ่งจะเห็นได้ว่าความถูกต้องของ ELM นั้นขึ้นอยู่กับค่าน้ำหนักที่ได้มาจากการสุ่มซึ่งมี

ความไม่แน่นอน และโอกาสที่จะได้ค่าที่เหมาะสมนั้นอาจจะต้องใช้จำนวนโหนดชั้นซ่อนเป็นจำนวนมาก (มุสิกะวัน, เขียวชาญวัฒนา, & สุนิติ, 2016)

ขั้นตอนวิธีการเชิงวิวัฒนาการ (Evolutionary algorithm : EA) เป็นวิธีการหนึ่งที่ได้รับค่านิยมอย่างแพร่หลายในการหาค่าที่เหมาะสมที่สุด (Global optimal) ซึ่งขั้นตอนวิธีนี้มันสามารถทำให้หลบเลี่ยงปัญหาค่าเหมาะสมเฉพาะที่ (Local optimal) ได้ โดยเหมาะที่จะนำไปประยุกต์ใช้กับโครงข่ายประสาทเทียมเป็นอย่างมากเพื่อที่จะช่วยในการปรับค่าน้ำหนักเพื่อให้ได้ค่าน้ำหนักที่ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพที่ดีที่สุด โดย ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle swarm optimization algorithm : PSO) ก็เป็นหนึ่งในขั้นตอนวิธีการเชิงวิวัฒนาการที่ได้รับความนิยมนำไปประยุกต์ใช้กับ ELM ซึ่ง PSO นั้นเป็นขั้นตอนวิธีที่เลียนแบบพฤติกรรมทางสังคมของฝูงนก โดยกำหนดให้การบินของนกประกอบตำแหน่งที่นกบินอยู่ (Position) และความเร็วในการเคลื่อนที่ของนก (Velocity) ซึ่งนกแต่ละตัวจะทำหน้าที่หาอาหารไปพร้อมๆกัน ซึ่งนกแต่ละตัวนั้นจะมีการส่งสัญญาณเพื่อสื่อสารกันในกลุ่มว่าเพื่อแลกเปลี่ยนข้อมูลระหว่างกันเพื่อให้ทราบตำแหน่งที่มีอาหารอยู่และเคลื่อนที่ไปยังแหล่งอาหารนั้น ซึ่งนกแต่ละตัวก็เปรียบเหมือนกับอนุภาค (Particle) จำนวนมากที่เคลื่อนที่ไปบนพื้นที่ๆต้องการหาค่าที่เหมาะสมที่สุด (Han, Yao, & Ling, 2013)

### วัตถุประสงค์ของงานวิจัย

1. เพื่อศึกษาและประยุกต์ใช้เทคนิคเครื่องจักรเรียนรู้แบบเอ็กซ์ตริมกับการทำนายค่าตัวเลขต่อเนื่อง
2. ศึกษาและปรับปรุงประสิทธิภาพของแบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตริม โดยใช้ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค

### ขอบเขตของงานวิจัย

1. ข้อมูลที่ใช้สำหรับงานวิจัยเป็นค่าปริมาณสารต่างๆที่อยู่ในน้ำและค่าดัชนีคุณภาพน้ำ ซึ่งข้อมูลของสำนักงานสิ่งแวดล้อม จำนวน 3006 รายการ
2. ใช้การเครื่องจักรเรียนรู้แบบเอ็กซ์ตริมในการสร้างแบบจำลอง
3. ใช้เทคนิคขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคมาใช้ในการปรับค่าน้ำหนักของเครื่องจักรเรียนรู้แบบเอ็กซ์ตริม
4. ใช้วิธีการวัดประสิทธิภาพด้วยตัววัดประสิทธิภาพ Root mean square error (RMSE) , Mean square error (MSE), และเวลาในการประมวลผล

### วิธีการดำเนินงานวิจัย

1. ทบทวนวรรณกรรมและงานวิจัย (Literature Review) ที่เกี่ยวข้อง
2. ศึกษาเครื่องมือและอัลกอริทึมที่จะนำมาใช้ในงานวิจัย
3. เก็บข้อมูลที่ใช้ในงานวิจัย
4. ออกแบบขั้นตอนวิธีการทดลอง
5. ศึกษา และทดลองงานตามขั้นตอนวิธีที่กำหนดไว้
6. วิเคราะห์ ประเมินผลและสรุปผลการวิจัย

### สมมติฐานในการวิจัย

1. ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มสามารถหาค่าน้ำหนักที่เหมาะสมที่ทำให้แบบจำลองมีความแม่นยำที่สูงกว่าการไม่ใช้ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่ม

### ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถนำแบบจำลองที่ได้จากการวิจัยนี้ไปใช้ในการทำนายค่าดัชนีคุณภาพน้ำได้
2. สามารถประยุกต์การใช้งานเทคนิคขั้นตอนวิธีหาค่าเหมาะสมที่สุดกับโครงข่ายประสาทเทียมหรือแบบจำลองอื่นๆได้



## บทที่ 2


### เอกสารและงานวิจัยที่เกี่ยวข้อง

#### 2.1 ทฤษฎีที่เกี่ยวข้อง

งานวิจัยนี้เป็นงานวิจัยที่นำเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme Learning Machine : ELM) ซึ่งเป็นโครงข่ายประสาทเทียม (Neural Network : NN) ประเภทหนึ่งมาใช้ร่วมกับขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization Algorithm : PSO) เพื่อใช้ในการทำนายค่าดัชนีคุณภาพน้ำ (Water Quality Index : WQI) โดยงานวิจัยนี้มีการศึกษาและนำเอาทฤษฎีต่างๆมาประยุกต์ใช้กับงานวิจัย ดังนี้

##### 2.1.1 โครงข่ายประสาทเทียม (Neural Network : NN)


Neural Network หรือโครงข่ายประสาทเทียมได้มีการเริ่มต้นขึ้นในปี ค.ศ. 1943 โดย Warren S. McCulloch นักประสาทวิทยา และ Walter Pitts นักตรรกะ ได้เสนอแบบจำลองเซลล์ประสาทในลักษณะแบบจำลองทางคณิตศาสตร์ เพื่ออธิบายการทำงานอันซับซ้อนของสมอง โดยหลักการสำคัญเบื้องต้นที่นำไปประยุกต์ใช้ในโครงข่ายประสาทเทียมนั้นมาจากการจำลองการทำงานของเซลล์ประสาท (Neuron) ของมนุษย์ ซึ่งแต่ละเซลล์ประสาทจะมีหลักการสื่อสารกันผ่านการกระตุ้นด้วยศักย์ไฟฟ้า กล่าวคือกระแสประสาทเริ่มต้นส่งสัญญาณจากตัวเซลล์ (Cell Body) ผ่านแกนประสาทนำออก (Axon) ไปยังจุดประสานประสาท หรือไซแนปส์ (Synapse) ซึ่งจะสื่อสารเชื่อมต่อกับเซลล์ประสาทอื่นๆผ่านใยประสาทน้ำเข้า (Dendrite) ณ จุดที่เซลล์ประสาททำการสื่อสารกัน โดยการเชื่อมต่อระหว่างเซลล์ประสาทรุนั้นเป็นสิ่งสำคัญในการทำงานของโครงข่ายประสาท ขนาดและความแข็งแรงของจุดประสานประสาทรุนั้นประสาท หรือไซแนปส์นั้นจะเปลี่ยนแปลงการรับรู้ต่างๆที่ผ่านมา ซึ่งในโครงข่ายประสาทเทียมได้นำมาประยุกต์ใช้และเรียกว่า ค่าถ่วงน้ำหนัก (Weight) (สงวนสิทธิ์, 2562)



ภาพประกอบ 1 โครงข่ายประสาททางชีวะ

ที่มา : <https://cs231n.github.io/neural-networks-1/#add>

โครงข่ายประสาทเทียมนั้นจะมีหน่วยการคำนวณพื้นฐานคือเซลล์ประสาท (Neuron) ซึ่งเรียกอีกอย่างว่า โหนด (Node) โดยจะรับอินพุต (Input) จากโหนดอื่น หรือจากแหล่งภายนอก จากนั้นจะคำนวณเอาต์พุต (Output) ในแต่ละโหนดจะกำหนดค่าน้ำหนัก (Weight) และจากนั้นโหนดจะใช้ฟังก์ชันกับผลรวมถ่วงน้ำหนักของแต่ละอินพุต แนวคิดคือค่าถ่วงน้ำหนักนั้นสามารถเรียนรู้และควบคุมอิทธิพลและทิศทางที่มีผลต่อโหนดหนึ่งไปยังอีกโหนดหนึ่งได้ แต่ละโหนดจะส่งต่อข้อมูลกันไปเรื่อยๆ โดยที่พวกมันจะรวมเข้าด้วยกันด้วย Activate function และได้เป็นเอาต์พุตออกมา



ภาพประกอบ 2 โครงข่ายประสาทเทียม

ที่มา : <https://cs231n.github.io/neural-networks-1/#add>

องค์ประกอบของโครงข่ายประสาทเทียมประกอบไปด้วย

1) โหนดรับเข้า (Input Nodes) โหนดนี้อยู่ในชั้นรับเข้า (Input Layer) เป็นโหนดสำหรับรับข้อมูลจากภายนอกและส่งต่อซึ่งจะไม่มีค่าคำนวณใดๆในชั้นนี้


2) โหนดซ่อน (Hidden Nodes) โหนดนี้อยู่ในชั้นซ่อน (Hidden Layer) ในชั้นซ่อนนี้จะเป็นชั้นที่ทำการประมวลผลหรือคำนวณ โดยทำการคำนวณและส่งค่าถ่วงน้ำหนักจากชั้นรับเข้าไปยังชั้นต่อไป

3) โหนดส่งออก (Output Nodes) โหนดนี้จะอยู่ในชั้นส่งออก (Output Layer) โดยชั้นนี้จะเป็นชั้นสุดท้ายและจะใช้ Activate Function ในการหาผลลัพธ์ที่ต้องการ

4) การเชื่อมต่อและการถ่วงน้ำหนัก (Connection and Weight) ในโครงข่ายจะมีหลายๆการเชื่อมต่อ แต่แต่ละการเชื่อมต่อจะถ่ายโอนเอาต์พุตของนิวรอน  $i$  ไปยังอินพุตของนิวรอน  $j$  ในที่นี้ นิวรอน  $i$  นั้นมาก่อนนิวรอน  $j$  และนิวรอน  $j$  จะรับค่าที่มาจาก  $i$  โดยในการเชื่อมต่อแต่ละครั้งจะได้รับน้ำหนักมาด้วย ( $W_{ij}$ )

5) ฟังก์ชันกระตุ้น (Activate Function) ฟังก์ชันกระตุ้นของโหนดจะเป็นตัวกำหนดเอาต์พุตจากอินพุตที่ได้รับมา โดยจะรับผลรวมการประมวลผลทั้งหมดจากทุกอินพุตเข้ามาภายในนิวรอนเดียวและคำนวณเอาต์พุตออกมาแล้วส่งต่อไปยังชั้นซ่อนถัดไป ตัวอย่าง ฟังก์ชันกระตุ้นได้แก่ Sigmoid, Tanh, ReLU, Leaky ReLU

6) กฎการเรียนรู้ (Learning Rule) คือขั้นตอนวิธี (Algorithm) ที่ปรับเปลี่ยนพารามิเตอร์ของโครงข่ายประสาทเทียม เพื่อให้อินพุตที่กำหนดในเครือข่ายสร้างผลลัพธ์ที่ต้องการ โดยปกติแล้วกระบวนการเรียนรู้จะเหมือนกับการปรับเปลี่ยนน้ำหนักและเกณฑ์ (Thresholds)




ภาพประกอบ 3 แสดงสถาปัตยกรรมของโครงข่ายประสาทเทียม

ที่มา : <http://neuralnetworksanddeeplearning.com/chap1.html>

ประเภทของโครงข่ายประสาทเทียมนั้นมีหลายประเภทและแต่ละประเภทยังมีย่อยลงไปอีก แต่ประเภทที่นิยมใช้หลักๆนั้นมีดังนี้

1) โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feedforward Neural Network : FNN) เป็นโครงข่ายประสาทเทียมที่จะเชื่อมต่อระหว่างหน่วยที่ไม่เป็นวัฏจักร โดยโครงข่ายนี้จะส่งข้อมูลไปในทิศทางเดียวจากอินพุตโหนดไปยังโหนดซ่อนในชั้นถัดๆไปจนถึงเอาต์พุตโหนด ซึ่งจะมีการทำซ้ำหรือเกิดวัฏจักรในโครงข่ายนี้ ตัวอย่างรูปแบบโครงข่ายประสาทที่จัดอยู่ในประเภทนี้ได้แก่ Single-layer perceptron, Multi-layer perceptron (MLP), Convolutional Neural Network (CNN) เป็นต้น

2) โครงข่ายประสาทเทียมที่เกิดซ้ำ (Recurrent Neural Networks : RNN) เป็นโครงข่ายประสาทเทียมที่จะเชื่อมต่อระหว่างหน่วยในรูปแบบวัฏจักร โดยจะมีการถ่ายทอดแบบกลับหลังหรือเรียกว่า Backpropagation จากการประมวลผลสุดท้ายไปยังการประมวลผลก่อนหน้า ซึ่งโครงข่ายประสาทเทียมประเภทนี้นิยมนำไปประยุกต์กับงานต่างๆอาทิเช่น การรู้จำลายนิ้วมือ, การรู้จำคำพูด และงานด้านการประมวลผลแบบเป็นลำดับ เป็นต้น




ภาพประกอบ 4 Feedforward Neural Network (FNN) และ Recurrent Neural Networks (RNN)

ที่มา : [https://www.researchgate.net/figure/Feed-forward-and-recurrent-ANN-architecture\\_fig1\\_315111480](https://www.researchgate.net/figure/Feed-forward-and-recurrent-ANN-architecture_fig1_315111480)

### 2.1.2 เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme Learning Machine : ELM)

Extreme Learning Machine หรือ ELM ถูกนำเสนอโดย Huang และคณะ ในปี 2006 เป็นขั้นตอนวิธีแบบ Single-Hidden Layer Feedforward Network (SLFNs) ที่ใช้งานได้ง่าย และสามารถทำงานได้อย่างรวดเร็วเพราะมีเพียงแค่ชั้นนำเข้า, ชั้นซ่อนหนึ่งชั้น และชั้นผลลัพธ์ และไม่จำเป็นต้องกำหนดพารามิเตอร์ใดๆเองเพราะค่าพารามิเตอร์ อาทิเช่น น้ำหนัก และค่าเอนเอียงจะถูกกำหนดด้วยการสุ่ม ซึ่ง ELM จะไม่มีทำการถ่ายทอดแบบกลับหรือเรียกว่า Backpropagation แบบ RNN แต่จะใช้เมตริกผกผันแบบมอร์-เพนโรสของเมตริก (Moore-Penrose generalized inverse) มากำหนดค่าน้ำหนักแทน (Huang, Zhou, Ding, & Zhang, 2012) (มุสิกะวัน et al., 2016)



ภาพประกอบ 5 โครงสร้างของ Single-Hidden Layer Feedforward Network (SLFNs)

ที่มา : <https://towardsdatascience.com/introduction-to-extreme-learning-machines-c020020ff82b>

วิธีการคำนวณของ ELM นั้น สำหรับตัวอย่างที่ใช้สอนจำนวน  $N$  รายการ จะถูกนำไปใช้สอน ซึ่งจะอยู่ในรูปแบบ  $(x_i, t_i), i = 1, 2, \dots, N$  โดยที่  $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in R^n$  และ  $t_i = (t_{i1}, t_{i2}, \dots, t_{im})^T \in R^m$  กับ ELM จำนวน  $L$  โหนดชั้นซ่อนโดยนำไปใช้กับฟังก์ชันกระตุ้น  $g(x)$  ซึ่งสามารถเขียนสมการได้ดังนี้

$$f_L(x) = \sum_{i=1}^L \beta_i g_i(x) = \sum_{i=1}^L g_i(w_i \times x + b_i), i = 1, \dots, N$$

โดยที่ :  $L$  คือ จำนวนโหนดชั้นซ่อน

$N$  คือ จำนวนตัวอย่างฝึกสอน

$\beta$  คือ เวกเตอร์น้ำหนักระหว่าง  $i$ -th โหนดชั้นซ่อนกับชั้นผลลัพธ์

$w$  คือ เวกเตอร์น้ำหนักระหว่างชั้นนำเข้ากับชั้นซ่อน

$g$  คือ ฟังก์ชันกระตุ้น

$b$  คือ ค่าเอนเอียง

$x$  คือ เวกเตอร์รับเข้า

จากสมการที่ 1 สามารถแสดงเป็นรูปแบบเมตริกซ์ได้ดังนี้

$$H\beta = T$$

เมื่อ :

$$H = \begin{bmatrix} g(w_1 \times x_1 + b_1) & \dots & g(w_L \times x_1 + b_L) \\ \vdots & \dots & \vdots \\ g(w_1 \times x_N + b_1) & \dots & g(w_L \times x_N + b_L) \end{bmatrix}_{N \times L}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

โดยที่ :  $m$  คือ จำนวนของผลลัพธ์

$H$  คือ เมตริกซ์ผลลัพธ์ของชั้นซ่อน

$T$  คือ เมตริกซ์ผลลัพธ์ของข้อมูลฝึกสอน

และสามารถหาค่าเมตริกซ์น้ำหนัก  $\beta$  ที่ชั้นผลลัพธ์โดยวิธีการหาค่ากำลังสองน้อยที่สุดดังนี้

$$\hat{\beta} = H^+T$$

เมื่อ :  $H^+$  คือเมตริกผกผันแบบมอร์-เพนโรสของเมตริกและเป็นค่าประมาณที่มีนอร์มต่ำสุด

ขั้นตอนการเรียนรู้ของ ELM นั้นมีดังนี้

- 1) สุ่มค่าน้ำหนัก  $w_i$  และค่าเอนเอียง  $b_{i,i} = 1, \dots, L$
- 2) คำนวณชั้นซ่อน  $H$
- 3) คำนวณเมตริกผลลัพธ์  $\hat{\beta} = H^+T$
- 4) ใช้  $\hat{\beta}$  ในการทำนายข้อมูลทดสอบ (Test data)  $T = H\hat{\beta}$

(Guang-Bin, Qin-Yu, & Chee-Kheong, 2004; Wei & Dai, 2021)

### 2.1.3 ขั้นตอนวิธีเชิงวิวัฒนาการ (Evolutionary Algorithm)

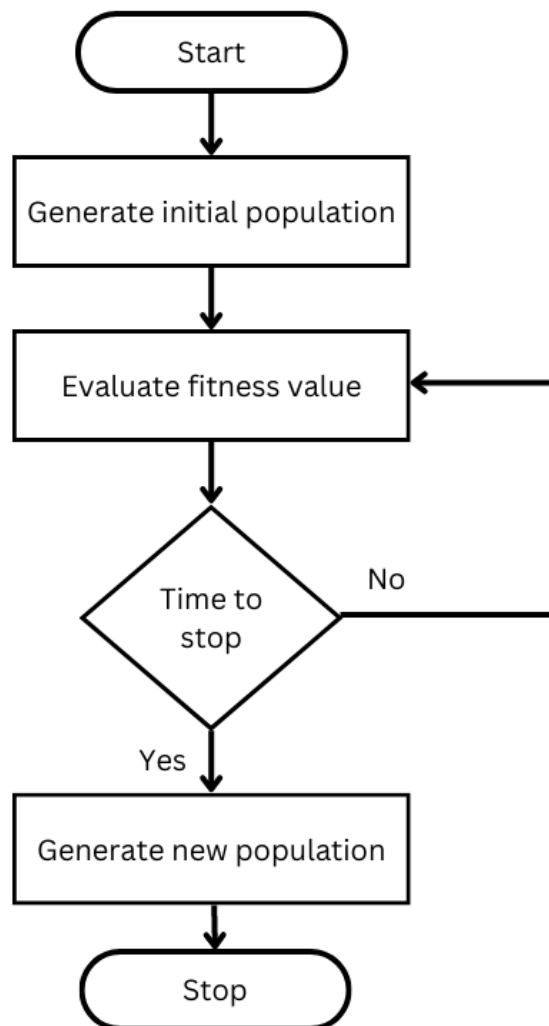
Evolutionary Algorithm (EA) หรือขั้นตอนวิธีเชิงวิวัฒนาการ เป็นส่วนหนึ่งของการคำนวณเชิงวิวัฒนาการโดยใช้พื้นฐานมาจากขั้นตอนวิธีหาค่าเหมาะสมแบบ metaheuristic ซึ่งการทำงานของ EA นั้นจะเลียนแบบวิวัฒนาการทางธรรมชาติ อาทิเช่น การสืบพันธุ์ (reproduction), การกลายพันธุ์ (mutation), การรวมตัวกันใหม่ (recombination) และการคัดเลือก (selection) โดยสามารถนำไปประยุกต์ใช้กับการแก้ปัญหาหรือหาค่าผลลัพธ์กับปัญหาที่หลากหลายด้าน เพราะว่า EA สามารถพัฒนาหรือค้นหาคำตอบที่เหมาะสมที่สุดได้อย่างรวดเร็ว (Popyack, 2016)

กระบวนการทำงานของขั้นตอนวิธีเชิงวิวัฒนาการนั้นมีดังนี้

- 1) เริ่มจากการสร้างประชากร (Populations) โดยการสุ่ม
- 2) ประเมินค่าความเหมาะสมในแต่ละประชากร
- 3) ตรวจสอบว่าครบจำนวนครั้งที่กำหนดหรือได้ค่าที่เหมาะสมหรือไม่
  - 3.1) ถ้ายังไม่ครบจำนวนครั้งที่กำหนดหรือยังไม่ได้ค่าที่เหมาะสมให้คัดเลือก (selection) ประชากรมา
  - 3.2) สืบพันธุ์ (reproduction) ประชากรที่คัดเลือกขึ้นมาเข้าด้วยกันเพื่อให้ได้ประชากรใหม่ในรุ่นถัดไป
  - 3.3) ในประชากรบางตัวอาจจะเกิดการกลายพันธุ์ (Mutation) ตามค่าที่กำหนดไว้
  - 3.4) ประเมินค่าความเหมาะสมในแต่ละประชากร

3.5) ทำวนซ้ำไปเรื่อยจนครบรอบที่กำหนดหรือได้ค่าที่เหมาะสมแล้ว

ประเภทของขั้นตอนวิธีเชิงวิวัฒนาการนั้นสามารถแบ่งได้เป็นสองชนิดคือวิวัฒนาการด้านพันธุกรรม และวิวัฒนาการด้านพฤติกรรม ซึ่งแต่ละชนิดก็มีหลากหลายรูปแบบซึ่งจะถูกนำไปใช้ในการแก้ปัญหาที่ต่างกันออกไป อาทิเช่น ขั้นตอนวิธีเชิงพันธุกรรม (Genetic algorithm), การโปรแกรมเชิงพันธุกรรม (Genetic Programming), การโปรแกรมเชิงวิวัฒนาการ (Evolutionary programming), กลยุทธ์เชิงวิวัฒนาการ (Evolutionary strategy), ข่ายประสาทวิวัฒนาการ (Neuroevolutionary), ความฉลาดแบบกลุ่ม (Swarm intelligence), วิธีการลอกเลียน (Memetic Algorithm) (ปาลวิสุทธิ, 2016)



ภาพประกอบ 6 กระบวนการของขั้นตอนวิธีเชิงวิวัฒนาการ



### 2.1.4 ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization Algorithm)

Particle Swarm Optimization Algorithm (PSO) หรือขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคเป็นขั้นตอนวิธีแบบหนึ่งที่ใช้ในการหาค่าเหมาะสมที่สุดที่เลียนแบบการหาอาหารของฝูงนกหรือฝูงปลา เมื่อนกหรือปลาค้นหาอาหารจะสามารถแบ่งปันข้อมูลการค้นพบ และช่วยให้ทั้งฝูงสามารถไปถึงแหล่งอาหารที่ดีที่สุดได้ (Han et al., 2013) โดยลักษณะขั้นตอนการทำงานนั้นจะคล้ายๆกับขั้นตอนวิธีเชิงพันธุกรรมคือกำหนดกลุ่มประชากรขึ้นมาจากสุ่ม แต่ว่า PSO นั้นจะมีการหาผลลัพธ์โดยการกำหนดค่าความเร็ว (velocity) ซึ่งนกหรือปลาแต่ละตัวนั้นจะถูกเรียกว่าอนุภาค (Particles) และการบินหรือการว่ายน้ำนั้นก็หมายถึงการเคลื่อนที่ไปบนไฮเปอร์สเปซ (Hyperspace) แต่ละอนุภาคที่อยู่บนไฮเปอร์สเปซนั้นจะทำการหาจุดเหมาะสมที่สุด ในความเร็วที่กำหนดโดยในแต่ละครั้งที่ทำวนซ้ำเพื่อหาค่าที่เหมาะสมที่สุดนั้นแต่ละอนุภาคจะทำการปรับเปลี่ยนเวกเตอร์ของทิศทางการเคลื่อนที่ตามอิทธิพลของตำแหน่งที่ดีที่สุดของแต่ละอนุภาค (pbest) รวมไปถึงตำแหน่งที่ดีที่สุดของอนุภาคอื่นๆหรือของฝูง (gbest) (Eberhart & Kennedy, 1995)

ในการกำหนดจำนวนและตำแหน่งของอนุภาค หรือ  $p$  ในรอบ  $t$  ว่า  $X^i(t)$  ซึ่งเมื่อเขียนให้อยู่ในรูปของคู่อันดับนั้นสามารถเขียนได้ดังนี้

$$X^i(t) = (x^i(t), y^i(t))$$

ในส่วนของความเร็วของแต่ละ  $p$  นั้นสามารถเขียนแทนได้ดังนี้

$$V^i(t) = (v_x^i(t), v_y^i(t))$$

ในรอบถัดไปนั้นตำแหน่งของแต่ละ  $p$  จะต้องถูกปรับค่าซึ่งเขียนแทนได้ดังนี้

$$X^i(t+1) = X^i(t) + V^i(t+1)$$

หรือ

$$x^i(t+1) = x^i(t) + v_x^i(t+1)$$

$$y^i(t+1) = y^i(t) + v_y^i(t+1)$$

และในขณะเดียวกันนั้นความเร็วก็จะถูกปรับด้วยกฎดังนี้

$$V^i(t+1) = wV^i(t) + c_1r_1(pbest^i - X^i(t)) + c_2r_2(gbest - X^i(t))$$

โดยที่ :  $r_1$  และ  $r_2$  คือเลขที่สุ่มระหว่าง 0 และ 1

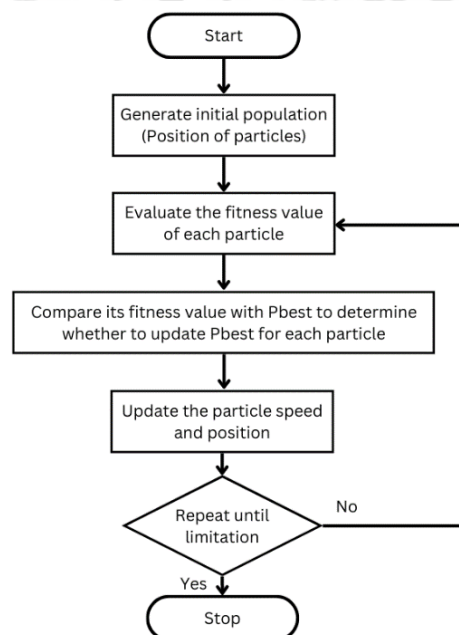
$w, c_1, c_2$  คือ พารามิเตอร์ของ PSO

$pbest^1$  คือ ตำแหน่งที่ทำให้ค่า  $f(x)$  ที่ดีที่สุดเท่าที่เคยสำรวจโดย p

$gbest$  คือ ตำแหน่งที่ดีที่สุดที่สำรวจโดย p ทั้งหมด

ในกระบวนการทำงานของขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคดังนี้

- 1) กำหนดจุดข้อมูล
- 2) ประเมินค่าความเหมาะสมของแต่ละอนุภาค
- 3) ในแต่ละอนุภาคให้เปรียบเทียบค่าความเหมาะสมกับ pbest เพื่อพิจารณาว่าจะปรับ pbest หรือไม่
- 4) อัปเดตความเร็วและตำแหน่งของอนุภาค
- 5) ทำวนซ้ำที่ขั้นตอนที่ 2 จนครบจำนวนครั้งที่กำหนดหรือได้ค่าที่เหมาะสม



ภาพประกอบ 7 กระบวนการทำงานของขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค

## 2.2 งานวิจัยเกี่ยวข้อง

ในงานวิจัยนี้ได้ทำการค้นคว้างานวิจัยที่เกี่ยวกับการใช้งานเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม และการนำขั้นตอนวิธีหาค่าเหมาะสมที่สุดมาประยุกต์ใช้งานร่วมกันดังนี้

2.2.1 วิจัยเรื่อง Extreme Learning Machine for Regression and Multiclass Classification โดย G. B. Huang, H. Zhou, X. Ding and R. Zhang

งานวิจัยนี้กล่าวถึงการนำเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมไปใช้งานแบบรีเกรสชันและแบบจำแนกประเภทหลายๆประเภท โดยงานนี้แสดงให้เห็นว่าสามารถนำ ELM ไปใช้ในงานดังกล่าวได้โดยตรง ซึ่งถ้าพิจารณาจากการเพิ่มประสิทธิภาพแล้วนั้น เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมมีข้อจำกัดที่น้อยกว่าเมื่อเทียบกับ LS-SVM และ PSVM ในทางทฤษฎี เมื่อนำ ELM มาเปรียบเทียบกับ LS-SVM และ PSVM นั้น ELM จะได้รับคำตอบที่ดีกว่าและใช้ความซับซ้อนในการคำนวณนั้นต่ำกว่า แล้ว ELM สามารถประมาณค่าฟังก์ชันที่เป้าหมายเป็นค่าต่อเนื่องใดๆ และจำแนกประเภทใดๆได้ จากการตรวจสอบโดยผลการจำลอง ELM มีแนวโน้มที่จะมีความสามารถในการปรับขนาดได้ดีกว่าและบรรลุประสิทธิภาพที่คล้ายกัน (สำหรับกรณีคลาสถดถอยและไบนารี) หรือดีกว่ามาก (สำหรับกรณีหลายคลาส) โดยรวมที่ความเร็วการเรียนรู้ที่เร็วกว่ามาก (สูงถึงพันเท่า) กว่า SVM แบบดั้งเดิม และ LS-SVM

2.2.2 วิจัยเรื่อง Prediction of Air Quality Index by Extreme Learning Machines โดย B. Baran

งานวิจัยนี้เป็นงานวิจัยที่นำเสนอการใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมมาใช้สำหรับการทำนายค่าดัชนีคุณภาพอากาศ โดยมีการเลือกคุณลักษณะ (feature) มาใช้ได้แก่อุณหภูมิ, ความชื้น, ความดัน, ความเร็วลม PM10 และ SO<sub>2</sub> ซึ่งได้ทำการทดลองโดยใช้ฟังก์ชันกระตุ้น (activate function) คือ Sigmoid, Sin และ Hardlim โดยกำหนดจำนวนโหนดชั้นซ่อน (hidden node) ที่แตกต่างกัน และใช้โปรแกรม MATLAB ในการสร้างและฝึกสอนแบบจำลอง

โดยการประเมินประสิทธิภาพนั้นแบบจำลองที่ใช้ฟังก์ชันกระตุ้น Hardlim ที่กำหนดจำนวนโหนดชั้นซ่อน 50 โหนด ได้ค่าความแม่นยำ (accuracy score) สูงที่สุด ซึ่งการทดสอบนั้นมีผลดังตาราง 1

ตาราง 1 แสดงการเปรียบเทียบความแม่นยำของฟังก์ชันกระตุ้นที่มีจำนวนโหนดชั้นซ่อนแตกต่างกัน

Activate code and hidden neuron	Test time (s)	Average test accuracy (%)
Sig-5	0.0004340	52.50
Sin-5	0.0003412	22.50
Hardlim-5	0.0004032	55.00
Sig-20	0.0003233	52.50
Sin-20	0.0003271	25.83
Hardlim-20	0.0003893	60.00
Sig-50	0.0003748	60.00
Sin-50	0.0003624	33.33
Hardlim -50	0.0004156	74.17
Sin-70	0.0003687	70.83
Sig-70	0.0003682	25.00
Hardlim -70	0.0004052	60.00
Sig-90	0.0003932	67.50
Sin-90	0.0003884	30.83
Hardlim-90	0.0004133	68.33
Sig-108	0.0004263	73.33
Sin-108	0.0004406	19.17
Hardlim-108	0.0004607	71.67

ที่มา : (Baran, 2019)

2.2.3 บทวิจัยเรื่อง Prediction of soil moisture based on Extreme Learning Machine for an apple orchard โดย Y. Liu, L. Mei and S. K. Ooi

งานวิจัยนี้เป็นงานวิจัยที่นำเสนอการใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมมาใช้ในการทำนายความชื้นในดินเพื่อการจัดสรรน้ำในพื้นที่ชลประทานอย่างมีประสิทธิภาพ

โดยความชื้นในดินไม่เพียงได้รับผลกระทบจากความชื้นในดินตามลำดับเวลาก่อนหน้าเท่านั้น แต่ ยังได้รับผลกระทบจากปัจจัยสภาพอากาศด้วย

ในการฝึกสอนแบบจำลองนี้ งานวิจัยนี้ได้ใช้ชุดข้อมูลขนาดใหญ่ที่ได้รับจากสวน แอปเปิ้ล Dookie ในรัฐวิกตอเรีย ประเทศออสเตรเลีย ซึ่งผลลัพธ์แสดงให้เห็นว่าแบบจำลอง สามารถทำนายแนวโน้มในอนาคตของความชื้นในดินได้อย่างแม่นยำ และนี่สามารถเป็นข้อมูล สนับสนุนการตัดสินใจที่มีประโยชน์สำหรับการจัดตารางการชลประทานในอนาคตคือแบบจำลอง การเรียนรู้ของเครื่องจักรแบบเอ็กซ์ตรีม มีความแม่นยำในการทำนายที่สูงกว่า และมีความเร็วใน การเรียนที่รวดเร็วกว่าแบบจำลอง Support vector machine โดยมีผลการทดลองดังตาราง 2

ตาราง 2 แสดงการเปรียบเทียบความแม่นยำและความเร็วในการฝึกสอนระหว่างสองแบบจำลอง

Model	Weather and previous time series of soil moisture	MAE
ELM N = 3	15 min	0.0338
	30 min	0.0410
	45 min	0.0445
	60 min	0.0483
SVM N = 7	15 min	0.0326
	30 min	0.0909
	45 min	0.1388
	60 min	0.1794

ที่มา : (Yue, Long, & Su Ki, 2014)

2.2.4 บทวิจัย เรื่อง Design and implementation of the data prediction model based on PSO-ELM โดย X. Wei and J. Dai

งานวิจัยนี้เป็นงานวิจัยที่นำเสนอการออกแบบและการนำเครื่องจักรเรียนรู้แบบ เอ็กซ์ตรีมมาใช้ในการฝึกฝนแบบจำลองโดยมีการนำขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคมาใช้ในการหาค่าความเบี่ยงเบน (Bias) ที่เหมาะสมของชั้นซ่อน (hidden layer) และค่าน้ำหนักของเวกเตอร์รับเข้า (Input vector) ซึ่งในงานวิจัยนี้จะเปรียบเทียบระหว่างการฝึกสอน

เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมเพียงอย่างเดียวกับเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมที่นำขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคมาใช้ร่วมกัน โดยจะใช้แม่นยำของผลการทำนายสำหรับข้อมูลปริมาณออกเทนของน้ำมันเบนซินที่แตกต่างกันมาเป็นตัววัด

ในการทำการความแม่นยำผู้วิจัยได้แบ่งชุดของข้อมูลทดสอบออกเป็น 3 ชุดและใช้ค่า  $R^2$  เป็นค่าที่ใช้วัดความแม่นยำ โดยมีผลความแม่นยำนั้น ELM-PSO นั้นมีความแม่นยำกว่า ELM ทั้ง 3 การทดสอบโดยมีผลดังตาราง 3

ตาราง 3 แสดงการเปรียบเทียบความแม่นยำระหว่าง ELM และ PSO-ELM

Gasoline Octane Value	Accuracy	
	ELM	PSO-ELM
Test set one	83.67%	94.43%
Test set two	78.53%	93.91%
Test set three	69.28%	95.73%

ที่มา : (Wei & Dai, 2021)

2.2.5 บทวิจัยเรื่อง A hybrid Particle swarm optimization - Extreme Learning Machine approach for Intrusion Detection System โดย M. H. Ali, M. Fadlizolkipi, A. Firdaus and N. Z. Khidzir

งานวิจัยนี้เป็นงานวิจัยที่นำเสนอการนำขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มมาประยุกต์ใช้กับเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมเพื่อลดผลกระทบต่อความแม่นยำของแบบจำลองที่เกิดจากการสุ่มค่าพารามิเตอร์ภายในแบบจำลอง ซึ่งงานวิจัยนี้ได้ออกแบบ PSO-ELM ขึ้นมาโดยในแต่ละอนุภาคของ PSO นั้นจะเป็นค่าน้ำหนักของ ELM นอกจากนี้ การเพิ่มประสิทธิภาพจำเป็นต้องเลือกทั้งค่าน้ำหนักและจำนวนเซลล์ประสาทที่จำเป็นในชั้นซ่อน และใช้ sigmoid เป็นฟังก์ชันกระตุ้น (activate function) ในเอาต์พุตของแต่ละโหนดชั้นซ่อน นอกจากนี้ พารามิเตอร์ PSO ได้ตั้งค่าจำนวนการวนซ้ำ 100 ครั้ง และจำนวนอนุภาค 50 รายการและพารามิเตอร์อื่น ๆ เช่น  $C_1$ ,  $C_2$ ,  $W$  จะกำหนดตามค่ามาตรฐาน

ในการประเมินประสิทธิภาพงานวิจัยนี้ได้ใช้ชุดข้อมูล NSL\_KDD มาใช้ในการวัดความแม่นยำโดยเปรียบเทียบกันระหว่างการใช้ ELM เพียงอย่างเดียวกับการใช้ PSO-ELM ที่มี

จำนวนโหนดในชั้นซ่อนที่แตกต่างกันออกไป ซึ่งจะเห็นได้ว่าค่า Max.Acc ของ PSO-ELM นั้นมากกว่า ELM และจะเพิ่มมากขึ้นเมื่อจำนวนโหนดในชั้นซ่อนเพิ่มมากขึ้น ในจำนวนโหนดในชั้นซ่อนเท่ากับ 55 โหนด PSO-ELM จะมีค่า Max.Acc อยู่ที่ 0.9864 เลยทีเดียว ดังตาราง 4

ตาราง 4 แสดงผลการเปรียบเทียบประสิทธิภาพระหว่าง ELM และ PSO-ELM

No.Neurons	Model	Max.Acc	Avr.ACC	DR	FAR
10	ELM	0.9255	0.8956	0.9047	0.1545
	PSO-ELM	0.949	0.9388	0.9285	0.0822
25	ELM	0.9521	0.9471	0.9418	0.0695
	PSO-ELM	0.9725	0.9687	0.9674	0.0415
35	ELM	0.9631	0.9548	0.9501	0.0591
	PSO-ELM	0.9817	0.9791	0.9759	0.0211
50	ELM	0.9709	0.9652	0.9593	0.0478
	PSO-ELM	0.9864	0.9845	0.9806	0.0132

ที่มา : (Ali, Fadlizolkipi, Firdaus, & Khidzir, 2018)

2.2.6 บทวิจัยเรื่อง A delay prediction model for high-speed railway: an extreme learning machine tuned via particle swarm optimization โดย Y. Li, X. Xu, J. Li and R. Shi งานวิจัยนี้ได้นำเสนอการใช้งานขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคไปใช้ในการหาไฮเปอร์พารามิเตอร์ที่เหมาะสมนั้นคือจำนวนโหนดชั้นซ่อนให้กับแบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม เพื่อนำไปใช้ในการทำนายระยะเวลาล่าช้าของรถไฟ โดยงานวิจัยนี้ได้ตั้งค่าต่างๆให้กับ PSO ดังนี้ จำนวนรอบการวนซ้ำ 10 รอบ, จำนวนอนุภาค 40 รายการ, ขอบเขตในการค้นหาของอนุภาค [1,1000] และใช้ RMSE สำหรับฟิตเนสฟังก์ชัน ซึ่งได้มีการเปรียบเทียบประสิทธิภาพกับแบบจำลองอื่นๆจำนวน 6 แบบจำลอง โดย PSO-ELM นั้นได้ค่า RMSE น้อยที่สุด ดังตาราง 5

ตาราง 5 แสดงการเปรียบเทียบค่า RMSE, MAE และ R-squared

Model	RMSE	MAE	R-squared
PSO-ELM	2.13	0.89	0.98
KNN	3.97	0.86	0.95
ANN	4.77	1.12	0.92
Decision Tree	3.06	1.48	0.97
Lasso	2.60	1.40	0.97
GBDT	3.20	1.52	0.96
XGB	2.14	0.92	0.98

ที่มา : (Li, Xu, Li, & Shi, 2020)

2.2.7 งานวิจัยเรื่อง A Fault Diagnosis Method for Satellite Reaction Wheel Based on PSO-ELM โดย Z. Zhu, Y. Pang and Y. Chen

งานวิจัยนี้เป็นงานวิจัยที่นำแบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมมาใช้ในการวินิจฉัยข้อผิดพลาดของดาวเทียม และได้นำขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคใช้ในการปรับค่าน้ำหนักที่ได้จากชั้นผลลัพธ์เพื่อเพิ่มประสิทธิภาพของแบบจำลอง ซึ่งงานวิจัยนี้พบว่าการทำงานของ PSO-ELM นั้นสามารถลดระยะเวลาในการคำนวณการวินิจฉัยข้อผิดพลาดของดาวเทียมที่ได้เมื่อเทียบกับแบบจำลองโครงข่ายประสาทเทียมแบบบ่อนกลับแบบดั้งเดิมโดยงานวิจัยนี้ได้กำหนดพารามิเตอร์ที่สำคัญให้กับ PSO-ELM ดังตาราง 6



ตาราง 6 แสดงพารามิเตอร์ของ PSO-ELM

Parameter Name	Parameter Size
Number of Particles	100
Acceleration constant (C1, C2)	(2.4, 1.6)
Inertia Constant	[0.4, 0.8]
Transfer Function	Sigmoidal Function
Number of Hidden Neurons	5

ที่มา : (Zhu, Pang, & Chen, 2022)

และได้ประเมินค่าความแม่นยำของแบบจำลองโดยใช้ MAE กับ  $R^2$  ซึ่งได้ 0.017 และ 0.9733 ตามลำดับ

2.2.8 วิจัยเรื่อง Prediction of Thermal System Parameters Based on PSO-ELM Hybrid Algorithm โดย L. Ma, L. Zhao and X. Wang

งานวิจัยนี้นำเสนอแนวทางการปรับปรุงประสิทธิภาพให้กับ เครื่องจักรเรียนรู้แบบ เอ็กซ์ตรีม (ELM) เพื่อทำนายพารามิเตอร์การทำงานของระบบระบายความร้อนโดยใช้ขั้นตอนวิธี หาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (PSO)

ELM เป็นโครงข่ายประสาทเทียมแบบฟีดฟอร์เวิร์ดที่มีชั้นซ่อนชั้นเดียว ซึ่งมีความสามารถในการนำไปใช้สำหรับเรียนรู้ได้ดีและมีความสามารถในการเรียนรู้ที่รวดเร็ว อย่างไรก็ตาม ELM นั้นไม่สามารถกำหนดจำนวนโหนดชั้นซ่อนได้อย่างอัตโนมัติ การเลือกพารามิเตอร์ ELM ที่เหมาะสมที่สุดสามารถปรับปรุงประสิทธิภาพได้ ในวิจัยฉบับนี้ มีการใช้ PSO แบบค่าไม่ต่อเนื่องเพื่อปรับจำนวนโหนดชั้นซ่อนให้เหมาะสมเพื่อเพิ่มประสิทธิภาพ ELM ผลการจำลองแสดงให้เห็นว่าอัลกอริทึมแบบไฮบริดที่นำเสนอ นั้นแม่นยำและมีประสิทธิภาพมากกว่าสำหรับการทำนายพารามิเตอร์ของระบบระบายความร้อน

โดยกระบวนการฝึกสอนได้มีการทำให้เป็นมาตรฐาน (normalized) ให้อยู่ระหว่าง -1 ถึง 1 และได้ตั้งค่า PSO ดังนี้ จำนวนอนุภาค 10 รายการ, จำนวนรอบวนซ้ำ 50 รอบ, มิติการค้นหา คือ 1 และ  $C_1$  กับ  $C_2$  คือ 1.4962 และ 0.7298 ตามลำดับ

ผลการสร้างแบบจำลองแสดงให้เห็นว่าค่าที่ทำนายของ PSO-ELM นั้นเหมาะสมกับค่าจริงมากกว่าค่าทำนายโดย ELM และแสดงให้เห็นว่าอัลกอริทึมแบบไฮบริดที่นำเสนอขึ้นนี้มีประสิทธิภาพและแม่นยำสำหรับการทำนายพารามิเตอร์ของระบบระบายความร้อน

2.2.9 งานวิจัยเรื่อง Efficient Classification of Parkinson's Disease Using Extreme Learning Machine and Hybrid Particle Swarm Optimization โดย M. K. Shahsavari, H. Rashidi and H. R. Bakhsh

งานวิจัยนี้กล่าวถึงการเพิ่มประสิทธิภาพแบบจำลองที่ใช้ในการจำแนกโรคพาคินสันสำหรับผู้ป่วยที่มีสุขภาพแข็งแรง โดยงานวิจัยนี้ได้นำเรื่องจักรเรียนรู้แบบเอ็กซ์ตรีมมาใช้เพราะว่าแบบจำลองชนิดนี้มีความแม่นยำและความรวดเร็วในการทำงาน และอีกสิ่งที่จะทำให้ประสิทธิภาพของแบบจำลองเพิ่มมากขึ้นคือการเลือกองค์ประกอบคุณลักษณะของชุดข้อมูล (Feature selection) จึงได้มีการนำขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคมาใช้ในการเลือกองค์ประกอบคุณลักษณะที่เกี่ยวข้องอย่างมีประสิทธิภาพโดย PSO นั้นสามารถหาค่าที่เหมาะสมที่ (Global optimum) ได้อย่างรวดเร็ว

และงานวิจัยนี้แสดงให้เห็นว่าการใช้งาน Hybrid PSO-ELM นั้นมีประสิทธิภาพดีที่สุด นอกจากนั้นการเลือกใช้ Hybrid PSO ในการหาคุณลักษณะที่สำคัญสามารถหาคุณลักษณะที่ทำให้แบบจำลองมีประสิทธิภาพดีที่สุดดังตาราง 7 และตาราง 8

ตาราง 7 ค่าความแม่นยำของ PSO-ELM ที่เปรียบเทียบกับแบบจำลองอื่นๆ

Method	Performance measure			
	Accuracy	Recall	Precision	F-score
AdaBoost	83.94	91.30	85.71	88.41
NN	83.59	91.33	86.39	88.97
SVM	86.08	93.48	87.76	90.52
Proposed method	88.72	94.33	90.48	92.36

ที่มา : (Shahsavari, Rashidi, & Bakhsh, 2016)

ตาราง 8 การเปรียบเทียบผลการจำแนกประเภทของ ELM (FS หมายถึงการเลือกคุณสมบัติ)

Method	No.of selected feature elements	Performance measure			
		Accuracy	Recall	Precision	F-score
Entire feature space	22	85.36	93.14	87.14	90.44
GA-FS	14	85.98	93.72	87.29	90.39
FA-FS	14	86.27	93.56	87.84	90.60
PSO-FS	13	86.91	93.78	88.19	90.89
Hybrid PSO-FS	12	88.72	94.33	90.48	92.36

ที่มา : (Shahsavari et al., 2016)

#### 2.2.10 วิจัยเรื่อง Water quality prediction using machine learning methods โดย A.

H. Haghiabi, A. H. Nasrolahi and A. Parsaie

งานวิจัยนี้เป็นงานวิจัยที่นำโครงข่ายประสาทเทียม (ANN), วิธีการจัดการข้อมูลแบบกลุ่ม (GMDH) และเครื่องเวกเตอร์สนับสนุน (SVM) มาทำนายองค์ประกอบของคุณภาพน้ำของแม่น้ำทางตะวันตกเฉียงใต้ของอิหร่าน โดยมีการทดสอบฟังก์ชันถ่ายโอนของ ANN และเคอร์เนลประเภทต่างๆของ SVM

จากผลการทดสอบนั้นพบว่าฟังก์ชันถ่ายโอน Tansig ของ ANN และเคอร์เนล RBF ของ SVM ทำให้การทำนายนั้นมีประสิทธิภาพดีที่สุดจากการทดลองทั้งหมด และทั้งสองแบบจำลองนี้มีประสิทธิภาพที่สูงกว่าเล็กน้อยเมื่อเปรียบเทียบกับแบบจำลอง GMDH และแบบจำลองที่มีประสิทธิภาพมากที่สุดคือ SVM ซึ่งสูงกว่า ANN เพียงเล็กน้อยเท่านั้น โดยมารายละเอียดดังตาราง 9

ตาราง 9 สรุปผลการทำงานของแบบจำลองประยุกต์สำหรับทำนายส่วนประกอบคุณภาพน้ำ

Row	Output	GMDH			SVM			ANN		
		Stage	$R^2$	RMSE	K-F	$R^2$	RMSE	T-F	$R^2$	RMSE
1	Ca	Train	0.83	0.333	RBF	0.96	0.160	Tansig	0.92	0.238
		Test	0.85	0.313		0.94	0.193		0.84	0.295
2	Cl	Train	0.87	0.297	RBF	0.97	0.147	Tansig	0.94	0.193
		Test	0.88	0.312		0.95	0.210		0.96	0.178
3	Ec	Train	0.97	29.71	RBF	0.97	26.35	Tansig	0.98	23.88
		Test	0.99	13.84		0.98	28.81		0.96	35.14
4	$HCO_3$	Train	0.87	0.355	RBF	0.96	0.190	Tansig	0.96	0.192
		Test	0.89	0.334		0.95	0.219		0.92	0.290
5	Mg	Train	0.76	0.345	RBF	0.93	0.184	Tansig	0.92	0.197
		Test	0.79	0.332		0.93	0.199		0.90	0.212
6	Na	Train	0.78	0.317	RBF	0.94	0.157	Tansig	0.85	0.250
		Test	0.77	0.326		0.93	0.186		0.86	0.251
7	$SO_4$	Train	0.36	0.321	RBF	0.77	0.190	Tansig	0.74	0.185
		Test	0.26	0.297		0.68	0.204		0.68	0.240
8	TDS	Train	0.97	19.34	RBF	0.98	16.40	Tansig	0.98	16.60
		Test	0.99	7.22		0.97	22.31		0.97	19.39
9	pH	Train	0.25	0.358	RBF	0.59	0.270	Tansig	0.29	0.33
		Test	0.22	0.361		0.33	0.340		0.29	0.355

ที่มา : (Haghiabi, Nasrolahi, & Parsaie, 2018)

2.2.11 งานวิจัยเรื่อง Performance of machine learning methods in predicting water quality index based on irregular data set: application on Illizi region (Algerian southeast) โดย K. Saber, E. Ahmed, Islam, A. R. M. Towfiqul and K. Samir

งานวิจัยนี้เป็นงานวิจัยที่นำเสนอการทำนายค่าดัชนีคุณภาพน้ำโดยใช้ขั้นตอนวิธีการเรียนรู้ของเครื่องชนิดต่างๆ ได้แก่ Artificial neural network (ANN), Multi linear regression (MLR), Support vector regression (SVM), M5P tree, Random forest(RF), Locally weighted linear regression (LWLR), Random subspace (RSS) และ Additive regression (AR) โดยงานวิจัยมีเป้าหมายเพื่อลดการใช้เวลาในการคำนวณ WQI ซึ่งใช้พารามิเตอร์ทั้งหมดเป็นอินพุต และเพื่อใช้ในสถานการณ์วิกฤตที่ไม่สามารถทำการคำนวณแบบปกติได้เนื่องจากค่าพารามิเตอร์บางตัวไม่มีค่าหรือสูญหายไป

ในการประเมินแบบจำลองนั้นได้ใช้เมตริกทางสถิติหลายอย่าง ได้แก่ ค่าสัมประสิทธิ์สหสัมพันธ์ (R) ค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (MAE) ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยรูด (RMSE) ค่าความคลาดเคลื่อนสัมบูรณ์สัมพัทธ์ (RAE) และค่าความคลาดเคลื่อนกำลังสองสัมพัทธ์แบบรูด (RRSE)

โดยการวิจัยได้แบบออกเป็น 2 สถานการณ์ ในสถานการณ์แรกเป็นเรื่องของความเร็วในการประมวลผลพบว่า MLR ดีที่สุดโดยได้ค่าต่างๆดังนี้  $R = 1$ ,  $MAE = 1.4572 \times 10^{-08}$ ,  $RMSE = 2.1418 \times 10^{-08}$ ,  $RAE = 1.2573 \times 10^{-10}\%$  และ  $RRSE = 3.1708 \times 10^{-08}\%$  ในสถานการณ์ที่สองคือเมื่อมีบางพารามิเตอร์ที่ไม่มีค่าหรือหายไปซึ่งพบว่า RF ดีที่สุดโดยได้ค่าต่างๆดังนี้  $R = 0.9984$ ,  $MAE = 1.9942$ ,  $RMSE = 3.2488$ ,  $RAE = 4.693$  และ  $RRSE = 5.9642$

2.2.12 งานวิจัยเรื่อง Application of artificial intelligence (AI) techniques in water quality index prediction: a case study in tropical region, Malaysia โดย H. Mohammed, S. Saadi Shartoo, Y. Zaher Mundher, A. Haitham Abdulmohsin, H. Aini and E. Ahmed

เป็นงานวิจัยที่นำ Artificial Neural Networks (ANNs) และ Radial Basis Function Neural Network (RBFNN) มาใช้ในการทำนายค่าดัชนีคุณภาพน้ำในสภาพแวดล้อมเขตร้อน (มาเลเซีย) ข้อมูลที่นำมาใช้สำหรับการวิจัยนี้คือการตรวจวัดตัวแปรคุณภาพน้ำรายเดือนและดัชนีคุณภาพน้ำที่ประเมินได้ ตัวแปรคุณภาพน้ำ ได้แก่ ออกซิเจนละลายน้ำ (DO) ความต้องการออกซิเจนทางชีวเคมี (BOD) ความต้องการออกซิเจนทางเคมี (COD) แอมโมเนียแคลไนโตรเจน (NH3-N) สารแขวนลอย (SS) และค่า PH ที่ใช้ในการประเมิน WQI สำหรับประเทศมาเลเซีย

ชุดข้อมูลมีจำนวน 5233 รายการในช่วงเวลาตั้งแต่มกราคม 2544 ถึงตุลาคม 2553 และแบ่งออกเป็น 2 ชุด ชุดแรกใช้สำหรับฝึกสอนแบบจำลองซึ่งเป็นข้อมูลในช่วงเวลาระหว่างปี 2544-2551 และข้อมูลที่เหลือ ใช้สำหรับทดสอบแบบจำลอง

ในส่วนของการทำงาน งานวิจัยนี้ได้แบบออกเป็น 2 สถานการณ์ สถานการณ์แรกคือใช้พารามิเตอร์จำนวน 6 ตัวในการฝึกสอนแบบจำลอง และสถานการณ์ที่ 2 คือใช้พารามิเตอร์จำนวน 5 ตัวในการฝึกสอนแบบจำลอง โดยแบบจำลอง RBFNN มีประสิทธิภาพที่ดีที่สุดในทั้งสองสถานการณ์ ดังตาราง 10 และตาราง 11

ตาราง 10 แสดงประสิทธิภาพของแบบจำลอง BPNN

Model	First scenario				Second scenario		
	Architecture	R2	RMSE	NE	Architecture	R2	RMSE
M1	6-2-1	0.6853	0.0983	0.7156	5-2-1	0.7001	0.0981
M2	6-4-1	0.7409	0.07634	0.7631	5-4-1	0.6976	0.0928
M3	6-6-1	0.7309	0.0801	0.0801	5-6-1	0.7007	0.0867
M4	6-8-1	0.7472	0.0699	0.0699	5-8-1	0.6593	0.1018
M5	6-10-1	0.7267	0.0783	0.07434	5-10-1	0.5109	0.1314

ตาราง 11 แสดงประสิทธิภาพของแบบจำลอง RBFNN

Model	First scenario				Second scenario		
	Spread values	R2	RMSE	NE	Spread values	R2	RMSE
M1	0.2	0.9552	0.0294	0.0168	0.2	0.9228	0.0405
M2	0.4	0.9242	0.0399	0.9165	0.5	0.9228	0.0405
M3	0.6	0.9852	0.0168	0.9852	0.6	0.9807	0.0194
M4	0.8	0.9872	0.0168	0.9871	0.8	0.9705	0.0247
M5	1.0	0.9820	0.0168	0.9819	1.0	0.8999	0.0452

## บทที่ 3 การดำเนินงานวิจัย

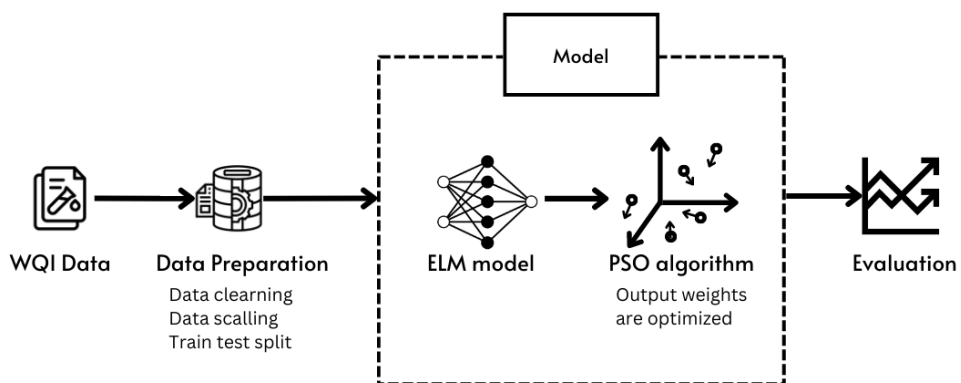
ในส่วนของขั้นตอนงานวิจัยนั้นผู้วิจัยได้มีการพัฒนาการสร้างแบบจำลองทำนายดัชนีคุณภาพน้ำโดยใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมและขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค โดยมีขั้นตอนการดำเนินงานดังนี้

1. การออกแบบโครงสร้างวิธีดำเนินงานวิจัย
2. การจัดเตรียมชุดข้อมูล
3. การสร้างแบบจำลอง
4. การประเมินผล

### 3.1 การออกแบบโครงสร้างวิธีดำเนินงานวิจัย

โครงสร้างวิธีดำเนินงานวิจัยประกอบไปด้วยกระบวนการดังนี้

- 3.1.1 การเก็บข้อมูล (Data collection)
- 3.1.2 การจัดเตรียมข้อมูล (Data preparation)
- 3.1.3 แบบจำลอง (Model)
  - 3.1.3.1 แบบจำลองสำหรับฝึกสอน
  - 3.1.3.2 ขั้นตอนวิธีสำหรับเพิ่มประสิทธิภาพแบบจำลอง
- 3.1.4 การประเมินประสิทธิภาพของแบบจำลอง (Performance Evaluation)



ภาพประกอบ 8 สรุปผลการทำงานของแบบจำลองประยุกต์สำหรับทำนายส่วนประกอบคุณภาพน้ำ

## 3.2 การเตรียมชุดข้อมูล

### 3.2.1 ชุดข้อมูล

งานวิจัยนี้ได้ใช้ข้อมูลคุณภาพน้ำในแม่น้ำจากเว็บไซต์แม่น้ำบ้านเฮาซึ่งเป็นระบบฐานข้อมูลสารสนเทศเพื่อใช้งานรายงานสถานการณ์น้ำบนแม่น้ำสายหลักของประเทศไทย คุณภาพน้ำ โดยงานวิจัยนี้ใช้ข้อมูลจากแม่น้ำ 4 สายได้แก่ ปิง วัง ยม น่าน ซึ่งเป็นข้อมูลตั้งแต่ปี 2552 จนถึงปี 2564 โดยมีจำนวน 3006 รายการ และประกอบไปด้วยรายละเอียดของข้อมูลดังนี้

Station คือ สถานีที่เก็บตัวอย่างน้ำ

Province คือ จังหวัดของสถานีที่เก็บตัวอย่างน้ำ

Data คือ วันที่ทำการเก็บตัวอย่างน้ำ

River คือ ชื่อแม่น้ำที่เก็บตัวอย่างน้ำ

WQI คือ ค่าดัชนีคุณภาพน้ำ

DO คือ ค่าออกซิเจนละลาย

BOD คือ ค่าสิ่งสกปรกในรูปอินทรีย์สาร

TCB คือ ค่าโคลิฟอร์มแบคทีเรีย

FCB คือ ค่าฟีคัลโคลิฟอร์มแบคทีเรีย

NH3 คือ ค่าแอมโมเนีย

โดยผู้วิจัยได้ทำการเลือกเฉพาะรายละเอียดบางรายการมาเป็นเวกเตอร์คุณลักษณะ (Feature vector) และผลลัพธ์เท่านั้น ซึ่งกำหนดให้ DO, BOD, TCB, FCB และ NH3 เป็นเวกเตอร์คุณลักษณะ และ WQI กำหนดให้เป็นผลลัพธ์

### 3.2.2 การทำความสะอาด

จากการที่ได้ทำการสำรวจข้อมูลที่นำมาใช้ในการวิจัยนั้นเบื้องต้นพบปัญหาดังนี้

- 1) พบค่าว่าง (Null) ให้คอลัมน์ WQI และ คอลัมน์ NH3 และได้แก้ปัญหาโดยการลบข้อมูลรายการที่มีค่าว่างออก
- 2) พบตัวระบุพิเศษในคอลัมน์ TCB, FCB, NH3 และได้แก้ปัญหาโดยการตัดอักขระพิเศษที่พบออก
- 3) พบตัวอักษร ND ในคอลัมน์ TCB, FCB, NH3 ซึ่งเกิดจากการที่ค่านั้นน้อยอยู่ในระดับที่น้อยมากจนไม่สามารถวัดค่าได้ และได้แก้ปัญหาโดยแทนด้วยค่า 0
- 4) พบว่าคอลัมน์ TCB, FCB, NH3 มีประเภทข้อมูลเป็นตัวอักษร (String) และได้แก้ปัญหาโดยการแปลงประเภทข้อมูลเป็นเลขทศนิยม (Float)



### 3.2.3 การปรับมาตรฐานข้อมูล (Data scaling)

หลังจากที่ดูความสะอาดข้อมูลเรียบร้อยแล้วนั้น ผู้วิจัยได้ทำการสำรวจข้อมูลอีกครั้งเพื่อดูรายละเอียดต่างๆ ข้อมูลพบว่าข้อมูลคุณลักษณะแต่ละคุณลักษณะนั้นมีช่วงที่กว้างค่อนข้างมากดังภาพประกอบ 9


	WQI	DO	BOD	TCB	FCB	NH3
count	1742.000000	1742.000000	1742.000000	1742.000000	1742.000000	1742.000000
mean	64.995555	6.149736	2.211860	15242.607348	4179.212974	0.257615
std	10.933573	1.609339	6.331822	29113.838571	12535.800589	0.747555
min	17.498615	0.000000	0.000000	0.000000	0.000000	0.000000
25%	58.000000	5.200000	1.100000	1700.000000	330.000000	0.070000
50%	63.000000	6.000000	1.580000	5000.000000	1100.000000	0.170000
75%	70.000000	7.000000	2.200000	16000.000000	2800.000000	0.300000
max	96.231440	23.400000	188.000000	160000.000000	160000.000000	16.700000

ภาพประกอบ 9 รายละเอียดทางสถิติของแต่ละคุณลักษณะ

จากภาพที่ 9 จะเห็นได้ว่า TCB และ FCB นั้นมีค่าสูงสุดอยู่ 160,000 ซึ่งห่างจาก DO, BOD และ NH3 อย่างมาก ซึ่งถ้านำข้อมูลเหล่านี้เข้าไปฝึกฝนกับแบบจำลองโดยตรงอาจจะทำให้แบบจำลองให้ความสำคัญกับคุณลักษณะที่มีค่าสูงได้ ผู้วิจัยจึงได้ทำการแก้ปัญหาโดยการทำการปรับค่าของทุกๆคุณลักษณะให้อยู่ในระดับเดียวกันด้วยการทำ Robust Scaler ซึ่งเป็นการปรับมาตรฐานคุณลักษณะ (Feature scaling) ประเภทหนึ่งที่ใช้ค่ามัธยฐาน (Median) และควอไทล์ (Quartile) แทนการใช้ค่าเฉลี่ย (Mean) กับค่าความแปรปรวน (Variance) เพื่อให้ค่าที่ได้ไม่ได้รับผลกระทบจากข้อมูลที่มีค่าห่างจากข้อมูลตัวอื่นๆมาก (Outlier) ซึ่งสามารถสมการดังนี้

$$\frac{x_i - Q_1(x)}{Q_3(x) - Q_1(x)}$$

โดยที่  $Q_1$  คือ ควอไทล์ที่ 1 และ  $Q_2$  คือ ควอไทล์ที่ 2



ภาพประกอบ 10 การกระจายตัวของข้อมูลในแต่ละคุณลักษณะ

### 3.2.4 การแบ่งข้อมูล

หลังจากที่ทำความสะอาดข้อมูลปรับมาตรฐานข้อมูลแล้วทำให้จำนวนข้อมูล 2361 รายการ ในส่วนของการแบ่งข้อมูลนั้นผู้วิจัยได้ทำการกำหนดดังนี้

- 1) ข้อมูลฝึกสอนจำนวน 1770 รายการ
- 2) ข้อมูลทดสอบจำนวน 591 รายการ

## 3.3 การสร้างแบบจำลอง

### 3.3.1 แบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (ELM)

ในงานวิจัยนี้ได้นำโค้ด (code) ของแบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมมาจาก <https://github.com/5663015/elm> โดยโค้ดของแบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมนั้นจะมี hyper-parameter ที่ต้องระบุดังนี้

- 1) Hidden\_unit คือ จำนวนโหนดภายในชั้นซ่อน
- 2) activation\_function คือ ฟังก์ชันกระตุ้นที่ต้องการใช้งาน ประกอบด้วย sigmoid, relu, sin, tanh และ leaky\_relu
- 3) x คือ เวกเตอร์คุณลักษณะที่ใช้ในการฝึกสอน
- 4) y คือ เวกเตอร์ป้ายกำกับ
- 5) C คือ ตัวเลขสำหรับการทำ regularization
- 6) elm\_type คือ การกำหนดประเภทของแบบจำลองว่าเป็น Classification หรือ Regression

นอกจากนี้จะต้องระบุขั้นตอนวิธี (algorithm) สำหรับคำนวณเบต้าเมทริกซ์ (beta matrix) ซึ่งเป็นเมทริกซ์น้ำหนัก (weight matrix) จากชั้นซ่อน (hidden layer) ไปยังชั้นผลลัพธ์ (output layer) โดยมีให้เลือกดังนี้

- 1) no\_re คือ วิธีคำนวณที่ไม่มีการทำ regularization โดยมีสมการคำนวณคือ

$$\beta = H^+T$$

2) solution1 คือ วิธีคำนวณที่ทำ regularization ซึ่งจะต้องมีการกำหนดค่า C โดย

$$\text{มีสมการคำนวณคือ } \beta = H^T \left( \frac{I}{C} + HH^T \right)^{-1} T$$

3) solution2 คือ วิธีคำนวณที่ทำ regularization ซึ่งจะต้องมีการกำหนดค่า C โดย

$$\text{มีสมการคำนวณคือ } \beta = \left( \frac{I}{C} + H^T H \right)^{-1} H^T T$$

และได้มีการทดลองเพื่อหา hyper-parameter ที่เหมาะสมกับชุดข้อมูลเพื่อนำไปใช้สำหรับสร้างแบบจำลองขั้นตอนวิธีหาค่าเหมาะสมที่สุด - เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (PSO-ELM) ซึ่งใช้ข้อมูลฝึกสอนจำนวน 1316 รายการ โดยกำหนดขั้นตอนวิธีคำนวณคือ solution1 เพราะจำนวนข้อมูลนั้นมีจำนวนที่ไม่ได้เยอะ และได้มีการกำหนด hyper-parameter ขึ้นดังตาราง 12

ตาราง 12 แสดงค่า hyper-parameter ที่กำหนดให้กับแบบจำลอง ELM

จำนวน node	C	ฟังก์ชันกระตุ้น
625	0.5	sigmoid
		relu
		sin
		tanh
		Leaky_relu
125	0.5	sigmoid
		relu
		sin
		tanh
		Leaky_relu
50	0.5	sigmoid
		relu
		sin
		tanh
		Leaky_relu

ตาราง 12 (ต่อ)

จำนวน node	C	ฟังก์ชันกระตุ้น
25	0.5	sigmoid
		Relu
		Sin
		Tanh
		Leaky_relu
5	0.5	sigmoid
		relu
		sin
		tanh
		Leaky_relu

### 3.3.2 แบบจำลองขั้นตอนวิธีหาค่าเหมาะสมที่สุด – เครื่องจักรเรียนรู้แบบ เอ็กซ์ตรีม (PSO-ELM)

ในงานวิจัยนี้เลือกให้แบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมและขั้นตอนวิธีหาค่าเหมาะสมที่สุดมาใช้ในการทำนายค่าดัชนีคุณภาพน้ำ โดยกระบวนการนั้นผู้วิจัยจะใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมในการฝึกสอนโดยใช้ข้อมูลฝึกสอนจำนวน 1316 รายการ โดยได้กำหนดค่าต่างๆให้กับแบบจำลองดังนี้

- 1) กำหนด Activate Function (ฟังก์ชันกระตุ้น) คือ Sigmoid
- 2) กำหนด Objective Function  $\beta = H^T \left( \frac{I}{C} + HH^T \right)^{-1} T$
- 3) กำหนด C (ตัวแปรของ Regularization) คือ 0.5
- 4) กำหนด Hidden unit (โหนดชั้นซ่อน) จำนวน 5, 25, 50, 125 และ 625

จากนั้นผู้วิจัยได้ออกแบบขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคเพื่อนำเอาค่าน้ำหนักของโหนดผลลัพธ์จากการทดลองที่ใช้จำนวนโหนดชั้นซ่อนจำนวน 50 โหนด ไปทำการหาค่าน้ำหนักที่เหมาะสมให้กับแบบจำลองซึ่งปกติแล้วตำแหน่งเริ่มต้นและความเร็วของแต่ละอนุภาคจะเกิดจากการสุ่ม แต่ในงานวิจัยนี้ได้กำหนดตำแหน่งเริ่มต้นด้วยค่าน้ำหนักของชั้นผลลัพธ์ที่ได้

จาก ELM และสุ่มค่าที่อยู่ระหว่าง -999.9999 ถึง 999.9999 โดยให้จำนวนรอบในการทำซ้ำจำนวน 100 รอบ กำหนดจำนวนอนุภาคคือ 3000 อนุภาค และมีการกำหนดค่าอื่นๆดังตาราง 13

ตาราง 13 แสดงค่า hyper-parameter ที่กำหนดให้กับ PSO algorithm

ครั้งที่	w	C1	C2
1	0.5	0.1	0.9
2	0.5	0.3	0.7
3	0.5	0.5	0.5
4	0.5	0.7	0.3
5	0.5	0.9	0.1

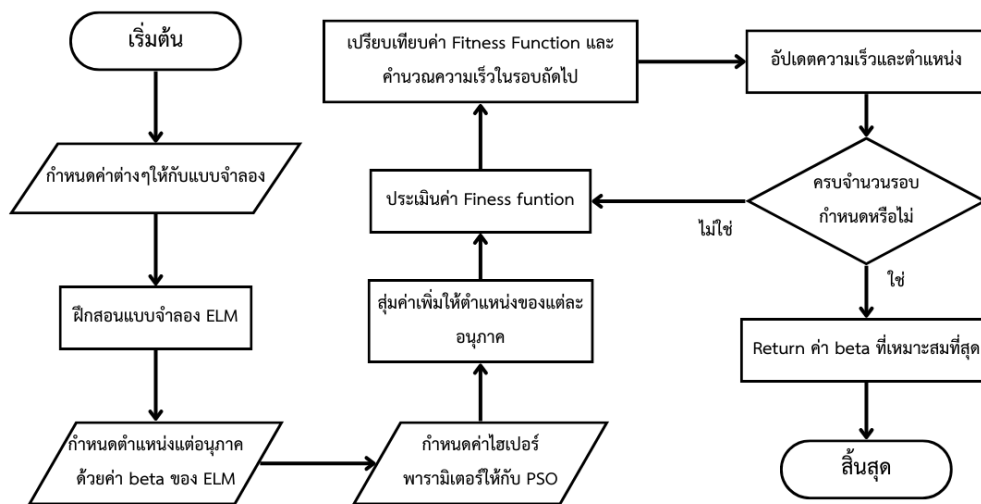
และกำหนดค่าฟิตเนส (Fitness value) เป็น RMSE โดยมีเป้าหมายเพื่อลดค่า RMSE

โดย PSO-ELM ในงานวิจัยนี้มีขั้นตอนการทำงานดังนี้

- 1) กำหนดชุดข้อมูลที่ใช้ในการเรียนรู้ ซึ่งประกอบด้วยเวกเตอร์รับเข้า (input vectors) และเวกเตอร์ผลลัพธ์ (Output vectors)
- 2) สร้าง PSO-ELM โดยมีการกำหนดจำนวนโหนดชั้นรับเข้า, จำนวนโหนดชั้นซ่อน, จำนวนโหนดชั้นผลลัพธ์, ฟังก์ชันกระตุ้น, ค่า C และ Objective function
- 3) สร้างประชากรหรืออนุภาค ให้มีการกำหนดตำแหน่งและความเร็วในตอนเริ่มต้น โดยกำหนดให้ค่าน้ำหนักที่ได้จากชั้นผลลัพธ์เป็นตำแหน่งเริ่มต้นให้กับทุกๆอนุภาค ส่วนความเร็วของแต่ละอนุภาคนั้นจะกำหนดด้วยการสุ่มค่า
- 4) เลือกค่าน้ำหนักที่เหมาะสม ซึ่งจะมีการทำวนซ้ำจำนวน 100 รอบ, จำนวนอนุภาค 3000 รายการ และปัจจัยการเรียนรู้ต่างๆที่กล่าวมาข้างต้น
- 5) ใช้ความคลาดเคลื่อนกำลังสอง (RMSE) ของเครื่องจักรเรียนรู้เป็นฟังก์ชันค่าเหมาะสม (Fitness function) โดยจะมีการคำนวณค่าเหมาะสมของแต่ละอนุภาค และมีการคำนวณค่าสูงสุดของแต่ละอนุภาค รวมถึงคำนวณค่าสูงสุดจากทุกๆอนุภาค
- 6) ทำการเปรียบเทียบ ปรับปรุงความเร็ว และตำแหน่งของอนุภาคอย่างต่อเนื่อง

- 7) ตรวจสอบเงื่อนไขว่าครบจำนวนวนซ้ำแล้วหรือได้ค่าคลาดเคลื่อนที่ต่ำสุดแล้ว ถ้าเป็นเช่นนั้นให้หยุดที่ค่าน้ำหนักผลลัพธ์ของ ELM ที่ปรับให้เหมาะสมโดย PSO ถ้าไม่เป็นเช่นนั้นให้กลับไปทำขั้นตอนที่ 5 และทำซ้ำต่อไป

ซึ่งกระบวนการจะเป็นไปตามภาพประกอบ 11 ดังนี้



ภาพประกอบ 11 ขั้นตอนการทำงานของ ELM-PSO

### 3.4 การประเมินประสิทธิภาพของแบบจำลอง (Performance Evaluation)

ในงานวิจัยนี้มีการใช้งานมาตรวัดประสิทธิภาพเพื่อใช้ประเมินความแม่นยำให้กับแบบจำลอง ได้แก่ Mean square error (MSE) , Root mean square error (RMSE) และผลรวมความแตกต่างของค่าน้ำหนักของเข้าพุตโหนดระหว่างแบบจำลอง ELM และแบบจำลอง PSO-ELM

#### 3.4.1 Mean square error (MSE)

ค่า MSE เป็นการวัดค่าสัมบูรณ์ของความพอดี ซึ่งคำนวณโดยผลรวมของกำลังสองของค่าคลาดเคลื่อนในการทำนายซึ่งเป็นเอาต์พุตจริงลบเอาต์พุตที่ทำนายแล้วหารด้วยจำนวนข้อมูล จะให้ค่าสัมบูรณ์ว่าผลลัพธ์ที่ทำนายเบี่ยงเบนไปจากจำนวนจริงมากน้อยเพียงใด โดยมีการคำนวณดังนี้

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

### 3.4.2 Root Mean Square Error (RMSE)

คือค่ารากที่สองของ MSE มีการใช้บ่อยกว่า MSE เพราะประการแรก บางครั้งค่า MSE อาจใหญ่เกินไปที่จะเปรียบเทียบได้ง่าย ประการที่สอง MSE คำนวณโดยกำลังสองของข้อผิดพลาด ดังนั้นรากที่สองจึงนำค่านี้กลับไปสู่ข้อผิดพลาดในการคาดคะเนในระดับเดิม และทำให้ง่ายต่อการตีความ โดยมีการคำนวณดังนี้

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

### 3.4.3 ผลรวมความแตกต่างของค่าน้ำหนักของเอาพุตโหนดระหว่างแบบจำลอง ELM และแบบจำลอง PSO-ELM

คือค่าผลรวมความแตกต่างของค่าน้ำหนักของเอาพุตโหนดระหว่างแบบจำลอง ELM และแบบจำลอง PSO-ELM โดยมีการคำนวณดังนี้

$$\sum_{i=0}^n (|ELM\beta_i - PSOELM\beta_i|)$$

## บทที่ 4

### ผลการดำเนินงานวิจัย

การวิจัยนี้ได้แบ่งการทดลองเป็น 2 แบบคือ การทดลองของแบบจำลอง ELM และการทดลองของแบบจำลอง PSO-ELM โดยได้มีการทดลองเพื่อเลือกฟังก์ชันกระตุ้นที่เหมาะสมเพื่อนำไปใช้ในการทดลองทั้งสองก่อนซึ่งมีผลดังตาราง 14

ตาราง 14 แสดงผลค่า RMSE ของชุดข้อมูลทดสอบ ฟังก์ชันกระตุ้น (Activate function) ที่ดีที่สุด

Function node	Sigmoid	Relu	Sin	Tanh	Leaky_relu
5	10.158	38.744	50.524	32.773	50.615
25	5.808	13.861	13.196	10.830	8.758
50	5.054	9.110	15.837	5.548	6.667
125	4.754	6.087	11.810	5.365	14.753
625	4.256	6.697	8.396	4.786	9.959

จากตาราง 14 จะเห็นได้ว่าในทุกๆการทดลองที่จำนวนโหนดต่างๆนั้นฟังก์ชันกระตุ้นนั้นได้ค่า RMSE น้อยที่สุด ดังนั้นจึงนำฟังก์ชันกระตุ้น sigmoid ไปใช้ในการสร้างแบบจำลอง ELM และแบบจำลอง PSO-ELM ต่อไป โดยการทดลองแบบจำลอง ELM นั้นมีผลดังตาราง 15

ตาราง 15 แสดงผลการทดลองของแบบจำลอง ELM

การทดลอง	จำนวน โหนดชั้น ซ่อน	ผลลัพธ์				เวลา (วินาที)
		train		test		
		RMSE	MSE	RMSE	MSE	
1	5	6.617	43.79	7.448	55.47	0.0025177001953125
2	25	5.411	29.28	6.183	38.23	0.0027587413787841797
3	50	4.684	21.94	5.136	26.38	0.00251007080078125
4	125	4.519	20.42	4.879	23.81	0.023756027221679688
5	625	3.735	13.95	4.263	18.17	0.09894108772277832



จากการทดลองของแบบจำลอง ELM นั้นจะเห็นได้ว่ายิ่งจำนวนโหนดชั้นซ่อนมากขึ้นนั้นก็ทำให้มีค่าความคลาดเคลื่อนลดลง รวมถึงใช้ระยะเวลาในการฝึกสอนเพิ่มมากขึ้นเล็กน้อย และจะเห็นได้ว่าการทดลองที่มีจำนวน โหนดชั้นซ่อน 50 โหนดนั้นมีค่า RMSE ไม่ได้ต่างจากการทดลองที่มีโหนดชั้นซ่อน 125 โหนดมากนัก และจำนวนโหนดชั้นซ่อนที่ไม่มากเกินไปทำให้สามารถวิเคราะห์ผลได้ง่าย จึงได้เลือกแบบจำลอง ELM ที่กำหนดโหนดชั้นซ่อน 50 โหนดไปใช้ในแบบจำลอง PSO-ELM ต่อไป

จากนั้นจึงได้นำการทดลองของแบบจำลอง ELM ที่กำหนดจำนวนชั้นซ่อน 50 โหนดนั้นมาหาค่าน้ำหนักของโหนดเข้าที่พุดโดยใช้ PSO โดยได้กำหนดรอบในการวนซ้ำ 100 รอบ และจำนวนอนุภาค 3000 อนุภาค ซึ่งผลการทดลองของ PSO-ELM จะได้ผลดังตาราง 16


ตาราง 16 แสดงผลการทดลองของ PSO-ELM ที่มีจำนวนโหนดชั้นซ่อน 50 โหนด

การทดลอง	ค่า parameter ที่กำหนด			ผลลัพธ์				เวลา h:mm:ss
	w	c1	c2	train		test		
				RMSE	MSE	RMSE	MSE	
1	0.5	0.1	0.9	5.695	32.437	7.086	50.214	0:09:26
2	0.5	0.3	0.7	6.016	36.194	5.912	34.953	0:09:26
3	0.5	0.5	0.5	6.383	40.744	8.402	70.600	0:09:22
4	0.5	0.7	0.3	7.795	60.754	9.080	82.451	0:09:31
5	0.5	0.9	0.1	6.281	39.455	6.828	46.618	0:09:13


จากการทดลองของ PSO-ELM นั้นจะเห็นได้ว่าการนำ PSO มาใช้ในการหาค่าน้ำหนักที่โหนดผลลัพธ์นั้น การทดลองที่ดีที่สุดคือการทดลองที่ 2 ซึ่งกำหนดค่า w คือ 5, C1 คือ 0.3 และ c2 คือ 0.7 โดยได้ค่า RMSE ที่ชุดข้อมูลทดสอบ (Test data) คือ 5.912 ซึ่งดีที่สุดเมื่อเทียบกับการทดลองอื่นๆ

โดยจากการทดลองทั้ง 2 แบบจำลองนี้สามารถบอกได้ว่าการคำนวณค่าน้ำหนักของโหนดผลลัพธ์ของแบบจำลอง ELM ที่ใช้เมตริกฝึกแบบมอร์-เพนโรสในการคำนวณนั้นสามารถหาค่าน้ำหนักของโหนดผลลัพธ์จากชุดข้อมูล จำนวนโหนด ค่าน้ำหนักของโหนดรับเข้า และค่า

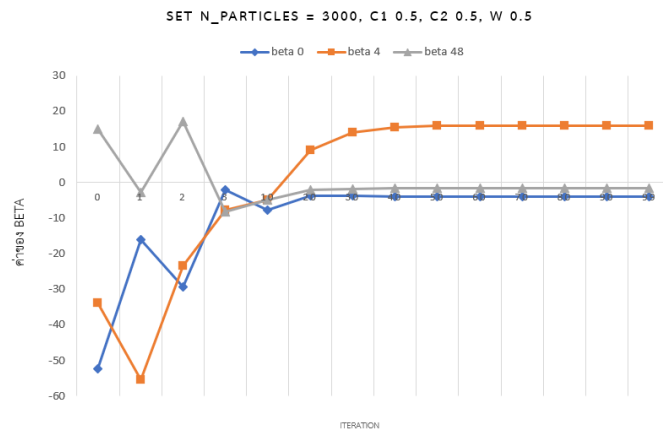
เบี่ยงเบนที่จะทำให้การทำนายค่าดัชนีคุณภาพน้ำมีความแม่นยำได้ดีที่สุดแล้ว เนื่องจากกาทดลองของแบบจำลอง PSO-ELM นั้นเมื่อมีการเพิ่มค่าให้กับค่าน้ำหนักของโหนดชั้นซ่อนเพื่อที่จะนำมาเป็นจุดเริ่มต้นของอนุภาค เมื่อ PSO ประมวลผลเสร็จสิ้น ค่าน้ำหนักของโหนดชั้นซ่อนที่ได้ออกมาจะเป็นค่าที่ไม่มีการเปลี่ยนแปลงแล้วหรือเป็นค่าที่เปลี่ยนแปลงเพียงเล็กน้อยก่อนจะครบรอบของการประมวลผล (Converge) ดังภาพประกอบ 12, 13, 14, 15 และมีค่าใกล้เคียงกับค่าที่ได้จากแบบจำลอง ELM ในทุกๆการทดลองของแบบจำลอง PSO-ELM



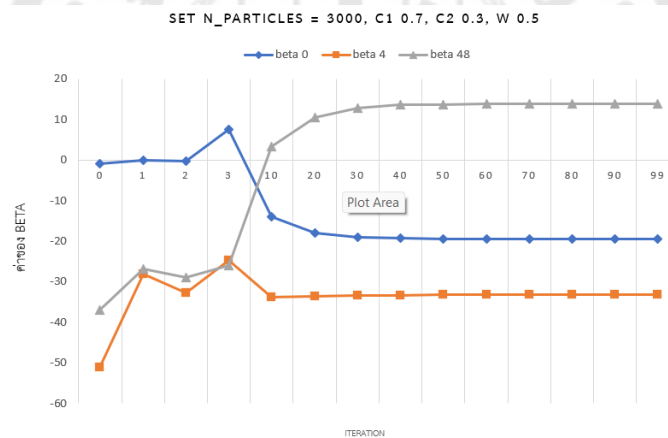
ภาพประกอบ 12 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 1




ภาพประกอบ 13 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 2



ภาพประกอบ 14 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 3

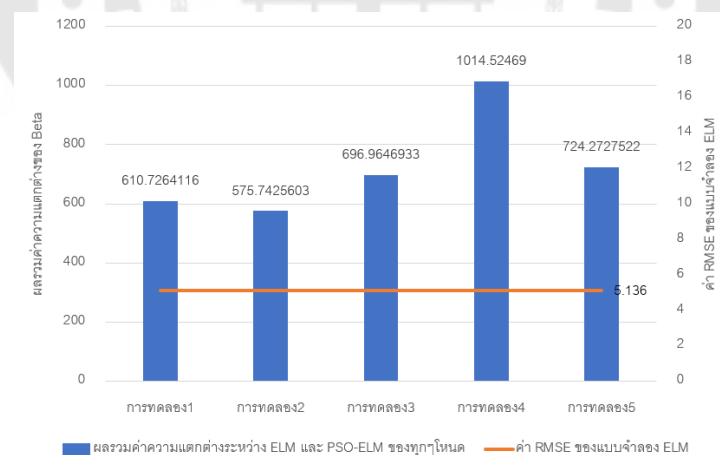


ภาพประกอบ 15 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 4



ภาพประกอบ 16 แสดงค่า beta ของอนุภาคที่ดีที่สุดในแต่ละรอบของการทดลองที่ 5

นอกจากนี้เมื่อนำค่าน้ำหนักของเอาพุตโหนดที่ได้จากแบบจำลอง PSO-ELM มาหาผลรวมของค่าความแตกต่างแล้วนั้นพบว่า ถ้าการทดลองของแบบจำลอง PSO-ELM มีผลรวมค่าความแตกต่างที่สูงขึ้นก็จะให้ได้แบบจำลองมีค่าความคลาดที่สูงตามไปด้วยดังภาพประกอบ 17



ภาพประกอบ 17 แสดงผลรวมความแตกต่างของ beta ในแต่ละการทดลองแบบจำลอง PSO-ELM กับแบบจำลอง ELM เปรียบเทียบกับ Baseline ค่า RMSE ของแบบจำลอง ELM

ซึ่งจะเห็นได้ว่ากราฟแท่งที่แสดงถึงผลรวมของค่าความต่างนั้นยิ่งสูงมาก จะยิ่งมีระยะที่ห่างจาก Base line หรือค่า RMSE ของแบบจำลอง ELM ซึ่งหมายถึงจะยิ่งมีค่า RMSE ที่แยกกว่าแบบจำลอง ELM นั้นเอง

## บทที่ 5

### สรุปผลการวิจัย อภิปรายผลและข้อเสนอแนะ

งานวิจัยนี้เป็นการนำแบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีมาไปใช้ในการทำนายค่าดัชนีคุณภาพน้ำ โดยมีการประยุกต์ใช้เทคนิคขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคมาใช้ในการปรับค่าน้ำหนักของโหนดผลลัพธ์เพื่อให้แบบจำลองมีความแม่นยำมากขึ้น โดยได้มีการนำการทดลองมาเปรียบเทียบ และสรุปผลซึ่งสามารถแบ่งหัวข้อในการสรุปผลได้ดังนี้

1. สรุปผลการวิจัย
2. อภิปรายผลการวิจัย
3. ข้อเสนอแนะ

#### สรุปผลการวิจัย

จากการทดลองของแบบจำลอง ELM และแบบจำลอง PSO-ELM นั้นได้ข้อสรุปคือแบบจำลอง ELM นั้นมีความรวดเร็วในการเรียนรู้และมีประสิทธิภาพอย่างมากเมื่อมีจำนวนโหนดชั้นซ่อนที่เพิ่มมากขึ้น ซึ่งถ้าสามารถหาค่าน้ำหนักของโหนดรับเข้าและค่าเบี่ยงเบนได้เหมาะสมกับจำนวนโหนดและชุดข้อมูลฝึกสอนก็จะทำให้ได้ค่าน้ำหนักของโหนดผลลัพธ์ที่ทำให้สามารถคำนวณค่าดัชนีคุณภาพน้ำได้แม่นยำมากขึ้น โดยในงานวิจัยนี้พบว่า สำหรับชุดข้อมูลดัชนีคุณภาพของแม่น้ำในประเทศไทยนั้นได้ฟังก์ชันกระตุ้นที่ดีที่สุด Sigmoid function และจำนวนโหนดชั้นซ่อนที่ดีที่สุดคือ 625 ซึ่งได้ค่าความคลาดเคลื่อน (RMSE) คือ 4.263 ซึ่งในส่วนของแบบจำลอง PSO-ELM นั้นได้นำการทดลองของแบบจำลอง ELM ที่ใช้จำนวนโหนดชั้นซ่อน 50 โหนดซึ่งได้ค่าความคลาดเคลื่อน (RMSE) 5.136 มาใช้ โดยมีจำนวนการทดลอง 5 การทดลองซึ่งในแต่ละการทดลองจะกำหนดค่าของพารามิเตอร์ที่แตกต่างกัน หลังจากที่ได้ปรับปรุงน้ำหนักของโหนดผลลัพธ์แล้วนั้นการทดลองที่ได้ความคลาดเคลื่อน (RMSE) ที่น้อยที่สุดนั้นคือการทดลองที่ 2 ซึ่งกำหนดพารามิเตอร์  $w$  คือ 0.5, กำหนดพารามิเตอร์  $c_1$  คือ 0.3 และ  $c_2$  คือ 0.7 โดยได้ค่าความคลาดเคลื่อน (RMSE) คือ 5.912 และพบว่าค่าน้ำหนักของโหนดผลลัพธ์หลังการปรับปรุงมีค่าแตกต่างจากน้ำหนักของโหนดผลลัพธ์ที่ได้จากแบบจำลอง ELM แต่ผลลัพธ์ของค่าความคลาดเคลื่อนของแบบจำลอง PSO-ELM ที่ได้นั้นมีความใกล้เคียงกับแบบจำลอง ELM แต่ค่อนข้างที่จะต้องใช้เวลาในการประมวลผลที่นานกว่า

## อภิปรายผล

เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme learning machine :ELM) เป็นแบบจำลองที่ใช้งานได้ง่าย และสามารถทำงานได้อย่างรวดเร็วเพราะเป็นโครงข่ายประสาทเทียมแบบฟีดฟอร์เวิร์ดที่มีชั้นซ่อนชั้นเดียว (Single-Hidden Layer Feedforward Network :SLFNs) ซึ่งประกอบไปด้วยชั้นนำเข้า, ชั้นซ่อนเพียงหนึ่งชั้น และชั้นผลลัพธ์ และไม่จำเป็นต้องกำหนดพารามิเตอร์ใดๆเอง เพราะค่าพารามิเตอร์ อาทิเช่น น้ำหนัก และค่าเอนเซียงจะถูกกำหนดด้วยการสุ่ม ซึ่ง ELM จะไม่มีทำการถ่ายทอดแบบกลับหรือเรียกว่า Backpropagation แบบ RNN แต่จะใช้เมตริกผกผันแบบมอร์-เพนโรสของเมตริก (Moore-Penrose generalized inverse) ด้วยเหตุนี้จึงโดยมีงานวิจัยอื่นๆที่นำแบบจำลอง ELM ไปประยุกต์ใช้กับขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm optimization algorithm :PSO) ในการเพิ่มประสิทธิภาพให้กับแบบจำลอง ELM เช่น บทวิจัยเรื่อง A delay prediction model for high-speed railway: an extreme learning machine tuned via particle swarm optimization โดยงานวิจัยนี้จะใช้ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคไปใช้ในการหาจำนวนโหนดชั้นซ่อนที่เหมาะสมให้กับแบบจำลองเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม หรือบทวิจัยเรื่อง A hybrid Particle swarm optimization - Extreme Learning Machine approach for Intrusion Detection System การนำ PSO มาประยุกต์ใช้กับแบบจำลอง ELM โดยการหาค่าน้ำหนักเกิดจากการสุ่มค่าพารามิเตอร์ภายในเพื่อลดผลกระทบต่อความแม่นยำของแบบจำลองที่แบบจำลอง ซึ่งงานวิจัยส่วนใหญ่จะนำ PSO ไปใช้ในการปรับจำนวนโหนดในชั้นซ่อน, นำไปหาค่าน้ำหนัก และค่าเบี่ยงเบนแทนการสุ่มจากตัวแบบจำลอง เพื่อจะลดความไม่แน่นอนในการสุ่มและเพื่อเพิ่มความแม่นยำให้กับแบบจำลอง ซึ่งจากงานวิจัยต่างๆนั้นยังไม่มียานวิจัยใดที่ได้นำ PSO มาปรับค่าน้ำหนักของโหนดเข้าชุดเพื่อเพิ่มความแม่นยำให้กับแบบจำลองมาก่อน

ในงานวิจัยนี้ขั้นตอนวิธี PSO ที่เลือกมาใช้เรียกว่า PSO แบบมาตรฐาน (standard PSO) ซึ่งเป็นขั้นตอนวิธีการค้นหาวิธีการแก้ปัญหา (solution) สำหรับปัญหาฟังก์ชันแบบไม่เป็นเชิงเส้น (nonlinear function) ที่เหมาะสมที่สุด โดยใช้พื้นที่ที่ความจำต่ำและเขียนภาษาคอมพิวเตอร์เพียงแค่มก๊อบรรทัดเท่านั้นนอกจากนั้นยังใช้เวลาการคำนวณที่น้อย ถึงอย่างไรก็ตาม PSO แบบมาตรฐานนั้นก็ยังสามารถค้นหาผลลัพธ์ที่ดีหรือเหมาะสมออกมาได้ในการนำไปใช้งานหลายรูปแบบ การพบผลลัพธ์ที่ไม่เปลี่ยนแปลงก่อนเวลาอันควร (Convergence) นั้นยังคงเป็นปัญหาที่เกิดขึ้นเมื่อใช้งาน PSO แบบมาตรฐาน กล่าวอีกนัยหนึ่งคือเมื่ออนุภาคใน PSO แบบมาตรฐานมีแนวโน้มที่จะเคลื่อนที่เข้าใกล้ gbest ซึ่งเป็น Local optimum อนุภาคจะ

สูญเสียความสามารถในการค้นหา Global optimum (Eberhart & Kennedy, 1995; Kennedy & Eberhart, 1995) ซึ่งในงานวิจัยนี้พบว่า เมื่อใช้ PSO ในการปรับน้ำหนักโหนดชั้นผลลัพธ์ (beta) นั้นพบว่าเพียงไม่กี่รอบการวนซ้ำเท่านั้นแต่สถานะก็เริ่มลู่ออกและไม่มีการเปลี่ยนแปลงอีก ดังภาพประกอบ 12 – 15 จากจุดนี้จึงทำให้ผู้วิจัยคาดว่าเป็นสาเหตุที่ทำให้แบบจำลอง PSO-ELM นั้นได้ค่าความคลาดเคลื่อน (RMSE) ที่ต่ำกว่าแบบจำลอง ELM แม้ว่าจะมีการปรับน้ำหนักโหนดชั้นผลลัพธ์ (beta) แล้วก็ตาม

นอกจากนี้แบบจำลอง ELM ที่ผู้วิจัยนำมาใช้ในแบบจำลอง PSO-ELM นั้น ไม่ได้มีการปรับพารามิเตอร์ที่เหมาะสมที่สุดกับข้อมูลชุดนี้ จากตรงนี้จึงทำให้ผู้วิจัยคาดว่าอาจจะเป็นอีกสาเหตุที่ทำให้แบบจำลอง PSO-ELM นั้นได้ค่าความคลาดเคลื่อน (RMSE) ที่ต่ำกว่าแบบจำลอง ELM

ในงานวิจัยนี้เลือกชุดข้อมูลดัชนีคุณภาพของแม่น้ำในประเทศไทยมาใช้คือแม่น้ำ ปิง วัง ยม และน่านโดยได้ความอนุเคราะห์มาจากกรมควบคุมมลพิษซึ่งมีความน่าสนใจที่จะนำมาใช้งานกับแบบจำลอง ELM ซึ่งจะนำมาทำนายค่าดัชนีคุณภาพน้ำซึ่งเป็นค่าต่อเนื่อง

จากการทดลองของแบบจำลอง ELM และแบบจำลอง PSO-ELM นั้นได้ข้อสรุปว่าแบบจำลอง PSO-ELM นั้นได้ค่าความคลาดเคลื่อน (RMSE) ที่ต่ำกว่าเพียงเล็กน้อยซึ่งได้ 5.912 และใช้เวลาที่มากกว่าแบบจำลอง ELM ซึ่งแบบจำลอง PSO-ELM ใช้เวลาในการประมวลผลคือ

9 นาที 26 วินาที ซึ่งเมื่อพิจารณาจากค่าน้ำหนักของโหนดผลลัพธ์ที่ออกมาเมื่อนำมาเทียบกับของ ELM แล้วนั้นก็มีความใกล้เคียงกัน

### ข้อเสนอแนะ

1) ควรเพิ่มการทดลองกับชุดข้อมูลสาธารณะที่มีการปรับพารามิเตอร์ในระดับหนึ่งแล้ว เช่น งานวิจัยเรื่อง Evolutionary extreme learning machine based on particle swarm optimization and clustering strategies (Pacífico & Ludermir, 2013) ซึ่งเป็นงานวิจัยที่ใช้งาน PSO-ELM มาเปรียบเทียบกับประสิทธิภาพกับแบบจำลองอื่นๆ ผู้วิจัยสามารถนำค่าพารามิเตอร์ที่มีการปรับค่าแล้วมาใช้เพื่อคำนวณ baseline ของค่าความคลาดเคลื่อนของแบบจำลองได้ ซึ่งข้อมูลสาธารณะเหล่านี้สามารถเข้าถึงได้ง่าย ทำให้ช่วยลดขั้นตอนการเตรียมข้อมูลลงได้

2) จากสาเหตุที่คาดว่าจะเกิดจากการที่ PSO นั้นจะสูญเสียความสามารถในการค้นหาค่า Global optimum นั้นงานวิจัยในปัจจุบันมีการปรับปรุงขั้นตอนวิธี PSO ให้มีประสิทธิภาพมากยิ่งขึ้น เช่น งานวิจัย Comparative study of the use of fuzzy logic in improving particle swarm optimization variants for mathematical functions using co-evolution ( Valdez,

Vazquez, Melin, & Castillo, 2017) มีการประยุกต์ใช้ระบบตรรกะคลุมเครือ (Fuzzy logic system) มาใช้ใน PSO เพื่อปรับปรุงพารามิเตอร์แบบไดนามิก ซึ่งสามารถปรับปรุงประสิทธิภาพของ PSO ได้ และในงานวิจัย Particle swarm optimization with damping factor and cooperative mechanism (He et al., 2019) ได้เพิ่ม damping factor ซึ่งเป็นพารามิเตอร์ที่สามารถเพิ่มกลไกการทำงานระหว่างฝูงของอนุภาค เพื่อให้ PSO ลู่เข้าสู่ค่า Global minimum เร็วที่สุด





## บรรณานุกรม

- Ali, M. H., Fadlizolkipi, M., Firdaus, A., & Khidzir, N. Z. (2018). A hybrid Particle swarm optimization -Extreme Learning Machine approach for Intrusion Detection System. 2018 *IEEE Student Conference on Research and Development (SCOReD)*, 1-4. RetriveForm<https://ieeexplore.ieee.org/abstract/document/8711287>
- Baran, B. (2019). Prediction of Air Quality Index by Extreme Learning Machines. 2019 *International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1-8. Retrive form<https://ieeexplore.ieee.org/document/8875910>
- Eberhart, R., & Kennedy, J. (1995). A new optimizer using particle swarm theory. *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, 39-43. RetriveForm<https://ieeexplore.ieee.org/document/494215>
- Guang-Bin, H., Qin-Yu, Z., & Chee-Kheong, S. (2004). Extreme learning machine: a new learning scheme of feedforward neural networks. 2004 *IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541)*, 2, 985-990 vol.982. Retrieved Form<https://ieeexplore.ieee.org/document/1380068>
- Haghiabi, A. H., Nasrolahi, A. H., & Parsaie, A. (2018). Water quality prediction using machine learning methods. *Water Quality Research Journal*, 53(1), 3-13. RetriveForm<https://doi.org/10.2166/wqrj.2018.025>
- Han, F., Yao, H.-F., & Ling, Q.-H. (2013). An improved evolutionary extreme learning machine based on particle swarm optimization. *Neurocomputing (Amsterdam)*, 116, 87-93. RetriveForm:<https://www.sciencedirect.com/science/article/pii/S0925231212007205>
- He, M., Liu, M., Wang, R., Jiang, X., Liu, B., & Zhou, H. (2019). Particle swarm optimization with damping factor and cooperative mechanism. *Applied Soft Computing*, 76, 45-52. Retrive Form<https://www.sciencedirect.com/science/article/pii/S1568494618306823>
- Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2012). Extreme Learning Machine for

- Regression and Multiclass Classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), 513-529. Retrieved Form <https://ieeexplore.ieee.org/abstract/document/6035797>
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, 1942-1948 vol.1944. Retrieve Form <https://ieeexplore.ieee.org/document/488968>
- Li, Y., Xu, X., Li, J., & Shi, R. (2020). A delay prediction model for high-speed railway: an extreme learning machine tuned via particle swarm optimization. *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*, 1-5. Retrieve Form <https://ieeexplore.ieee.org/document/9294457>
- Pacifico, L. D. S., & Ludermir, T. B. (2013). Evolutionary extreme learning machine based on particle swarm optimization and clustering strategies. *The 2013 International Joint Conference on Neural Networks (IJCNN)*, 1-6. Retrieved Form <https://ieeexplore.ieee.org/document/6706751>
- Popyack, J. L. (2016). Gusz Eiben and Jim Smith (Eds): Introduction to evolutionary computing. *Genetic Programming and Evolvable Machines*, 17(2), 197-199. Retrieve Form <https://doi.org/10.1007/s10710-016-9267-7>
- Shahsavari, M. K., Rashidi, H., & Bakhsh, H. R. (2016). Efficient classification of Parkinson's disease using extreme learning machine and hybrid particle swarm optimization. *2016 4th International Conference on Control, Instrumentation, and Automation (ICCIA)*, 148-154. Retrieve Form <https://ieeexplore.ieee.org/document/7483152>
- Valdez, F., Vazquez, J. C., Melin, P., & Castillo, O. (2017). Comparative study of the use of fuzzy logic in improving particle swarm optimization variants for mathematical functions using co-evolution. *Applied Soft Computing*, 52, 1070-1083. Retrieve Form <https://www.sciencedirect.com/science/article/pii/S1568494616304835>
- Wei, X., & Dai, J. (2021). Design and implementation of the data prediction model based on PSO-ELM. *2021 7th International Symposium on Mechatronics and Industrial Informatics (ISMII)*, 272-275.

RetriveForm<https://ieeexplore.ieee.org/document/9407509>

Yue, L., Long, M., & Su Ki, O. (2014). Prediction of soil moisture based on Extreme Learning Machine for an apple orchard. 2014 *IEEE 3rd International Conference on Cloud Computing and Intelligence Systems*, 400-404. Retrive Form<https://ieeexplore.ieee.org/abstract/document/7175768>

Zhu, Z., Pang, Y., & Chen, Y. (2022). A Fault Diagnosis Method for Satellite Reaction Wheel Based on PSO-ELM. 2022 *41st Chinese Control Conference (CCC)*, 4002-4007. RetriveForm<https://ieeexplore.ieee.org/document/9902163>

กรมควบคุมมลพิษ, ส. ส. (2557). คู่มือการดำเนินการติดตามตรวจสอบคุณภาพน้ำแหล่งน้ำผิวดิน. Retrive Form<http://iwis.pcd.go.th/officer/document/download/9/9.pdf>.

กรมควบคุมมลพิษ, ส. ส. (2565). ระบบสถานีคุณภาพน้ำอัตโนมัติ. Retrive Form<http://iwis.pcd.go.th/officer/document/download/174/174.pdf>.

ปาลวิสุทธิ, ภ. (2016). การเพิ่มประสิทธิภาพขั้นตอนวิธี ด้านวิวัฒนาการแบบหลาย วัตถุประสงค์ ด้วยทฤษฎี ความอลวน. *Information Technology Journal*. RetriveForm[https://ph01.tci-thaijo.org/index.php/IT\\_Journal/article/view/53561](https://ph01.tci-thaijo.org/index.php/IT_Journal/article/view/53561)

มุสิกะวัน, ภ., เขียวชาญวัฒนา, ส., & สุนิติ, ค. (2016). เครื่องจักรเรียนรู้เอ็กซ์ตรีมเชิงวิวัฒนาการ โดยใช้พื้นฐานของขั้นตอนการค้นหาค่าที่เหมาะสมแบบสเต็ปไฮสแอนด์คอมและขั้นตอนวิธีแบบหึ่งห้อย. *Information Technology Journal*. RetriveForm[https://ph01.tci-thaijo.org/index.php/IT\\_Journal/article/view/54182](https://ph01.tci-thaijo.org/index.php/IT_Journal/article/view/54182)

สงวนสิทธิ์, ป. (2562). *Artificial Intelligence with Machine Learning, AI สร้างได้ด้วยแมชชีนเลิร์นนิ่ง Python Edition*. บริษัท ไอดีซี พรีเมียร์ จำกัด: 1 พฤศจิกายน 2562.



## ประวัติผู้เขียน

ผลงานตีพิมพ์ -  
รางวัลที่ได้รับ -

