

การทำนายดัชนีคุณภาพน้ำโดยใช้เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม

กับขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค

พรวิชัย สารบูรณ์¹, ศุภร คนธภักดิ์²

บทคัดย่อ

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 โดยผลที่ได้ นั้น PSO-ELM มีค่า RMSE ที่ใกล้เคียงกับแบบจำลอง ELM และ แบบจำลอง PSO-ELM นั้นจะใช้เวลาในการประมวลผลมากกว่าแบบจำลอง ELM ซึ่งการใช้แบบจำลอง PSO-ELM ในการปรับค่าน้ำหนักของโหนดผลลัพธ์อาจจะไม่เหมาะสมนักเมื่อเทียบกับเวลาในการประมวลผล ดังนั้นในการใช้งานแบบจำลอง PSO-ELM นั้นควรนำไปใช้ปรับค่าอื่นๆ เช่น จำนวนโหนดชั้นซ่อน (hidden node), ค่าน้ำหนักของโหนดรับเข้า (input weight) หรือ ค่าเอนเอียง (bias) ซึ่งจะให้ความแม่นยำของแบบจำลองได้ดีกว่า

คำสำคัญ : เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม, ขั้นตอนวิธีหาค่าเหมาะสมแบบกลุ่มอนุภาค, การเรียนรู้ของเครื่อง

¹ หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

² คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

* Corresponding author: Tel.: 063-0978456 E-mail address: Pornpawit.sar@g.swu.ac.th

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

Pornpawit Saraboon^{1*}, Subhorn Khonthapagdee²

Abstract

Fresh water is a crucial component. 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, it relies on the water quality assessment of surface water sources 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. It was used to predict the water quality index. The weights of the output node obtained from the ELM will be 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.

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

¹ Data Science, Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

² Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

* Corresponding author: Tel.: 063-0978456 E-mail address: Pornpawit.sar@g.swu.ac.th

บทนำ

น้ำจืดเป็นองค์ประกอบที่สำคัญของสิ่งมีชีวิตต่างๆ แม้ว่าจะเป็นทรัพยากรหมุนเวียนแต่น้ำจืดนั้นคิดเป็นเพียง 3 เปอร์เซ็นต์ของปริมาณน้ำทั้งหมดบนโลก โดยถ้าแบ่งน้ำจืดออกเป็น 100 ส่วนนั้นจะมีเพียง 0.3 ส่วนเท่านั้นที่เป็นน้ำบนผิวดินที่มนุษย์สามารถนำไปใช้ได้ ในปัจจุบันปัญหาแหล่งน้ำเสื่อมโทรมนั้นเป็นปัญหาที่หลายๆประเทศนั้นเผชิญอยู่รวมถึงประเทศไทย ซึ่งปัญหานี้มีสาเหตุส่วนใหญ่มาจากการทิ้งน้ำ และสิ่งปฏิกูลจากแหล่งชุมชน น้ำเสียจากโรงงานอุตสาหกรรม น้ำเสียที่เกิดจากธรรมชาติ และเกิดจากการทำเกษตร ซึ่งมีผลกระทบต่อหลายอย่างไม่ว่าจะเป็นกระทบต่อวงจรชีวิตของสัตว์น้ำ ทำให้เป็นแหล่งแพร่ระบาดของเชื้อโรค และยังมีผลกระทบต่อเพาะปลูกอีกด้วย

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. ปริมาณการปนเปื้อนของแบคทีเรียกลุ่มฟีคอลโคลิฟอร์ม (FCB, Fecal Coliform Bacteria) 5. ปริมาณแอมโมเนียที่มาจากปุ๋ยเคมีการเกษตร การขับถ่าย อาหารสัตว์น้ำ ซึ่งประโยชน์ของดัชนีคุณภาพน้ำจะช่วยให้แปลความหมายของข้อมูลคุณภาพของน้ำ ที่ได้จากการวิเคราะห์ให้อยู่ในรูปแบบที่ง่ายต่อการเข้าใจเป็นเครื่องมือที่สำคัญในการหาแนวโน้ม หาเงื่อนไขที่สำคัญทางสิ่งแวดล้อม สามารถใช้บ่งบอกคุณลักษณะของน้ำนั้นว่าอยู่ในหลักเกณฑ์ใด และนำไปวิเคราะห์เพื่อช่วยตัดสินใจในเรื่อง การจัดสรรทรัพยากร, การจัดอันดับในการจัดสรร, มาตรฐานในการบังคับ, การวิเคราะห์แนวโน้มและการให้ข้อมูลต่อสาธารณะ

สำหรับงานวิจัยนี้นั้นจะเป็นการนำเครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme learning machine : ELM) ซึ่งเป็นโครงข่ายประสาทเทียม (Neural network) ประเภทหนึ่งมาใช้ในการทำนายค่าดัชนีคุณภาพน้ำ (Water quality index : WQI) ร่วมกับนำขั้นตอนวิธีหาค่าที่เหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle swarm optimization algorithm : PSO) มาใช้สำหรับหาค่าน้ำหนักที่เหมาะสมที่สุดของเอ้าท์พุทโหนด (beta)

ทฤษฎีที่เกี่ยวข้อง

เครื่องจักรเรียนรู้แบบเอ็กซ์ตรีม (Extreme learning machine : ELM)

Extreme Learning Machine หรือ ELM ถูกนำเสนอโดย Huang และคณะ [1] ในปี 2006 เป็นขั้นตอนวิธีแบบ Single-Hidden Layer Feedforward Network (SLFNs) ที่ใช้งานได้ง่าย และสามารถทำงานได้อย่างรวดเร็วเพราะมีเพียงแค่ชั้นนำเข้า, ชั้นซ่อนหนึ่งชั้น และชั้นผลลัพธ์ และไม่จำเป็นต้องกำหนดพารามิเตอร์ใดๆเองเพราะค่าพารามิเตอร์ อาทิเช่น น้ำหนัก และค่าเอนเอียง จะถูกกำหนดด้วยการสุ่ม ซึ่ง ELM จะไม่มีทำการถ่ายทอดแบบกลับหรือเรียกว่า Backpropagation แบบ RNN แต่จะใช้เมตริก

ผกผันแบบมอร์-เพนโรสของเมตริก (Moore-Penrose generalized inverse) มากำหนดค่าน้ำหนักแทน โดยมีขั้นตอนการเรียนรู้ดังนี้

ขั้นตอนที่ 1: นำตัวอย่างฝึกสอนจำนวน N รายการไปฝึกสอนกับ ELM จำนวน L โหนดชั้นซ่อนโดยนำไปใช้กับฟังก์ชันกระตุ้น $g(x)$ ซึ่งตัวอย่างฝึกสอนจะอยู่ในรูปแบบ $(x_i, t_i), i = 1, 2, \dots, N$ ซึ่ง $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in R^n$ และ $t_i = (t_{i1}, t_{i2}, \dots, t_{im})^T \in R^m$ ซึ่งสามารถเขียนได้ดังสมการที่ 1

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

ขั้นตอนที่ 2: คำนวณชั้นซ่อน H ตามจำนวนโหนดชั้นซ่อนซึ่งการคำนวณของ ELM นั้นจะมีการสุ่มค่าเวกเตอร์น้ำหนักระหว่างโหนดรับเข้า (Input node) กับโหนดชั้นซ่อน (Hidden node) w_i และค่าเอนเอียง $b_i, i = 1, \dots, L$ ในการคำนวณนั้นจะใช้ฟังก์ชัน $g(x)$ ดังสมการที่ 2

$$\sum_{i=1}^N \beta_i g(w_i \cdot x_i + b_i) = t_i \quad (2)$$

ซึ่งสามารถเขียนในรูปแบบเมตริกซ์ได้ดังสมการที่ 3

$$H\beta = T \quad (3)$$

ขั้นตอนที่ 3: คำนวณค่าเมตริกซ์น้ำหนัก β ที่ชั้นผลลัพธ์ โดยวิธีการหาค่ากำลังสองน้อยที่สุดดังสมการที่ 4

$$\hat{\beta} = H^+T \quad (4)$$

เมื่อ H^+ คือเมตริกผกผันแบบมอร์-เพนโรสของเมตริกและเป็นค่าประมาณที่มีนอร์มต่ำสุด

ขั้นตอนวิธีหาค่าเหมาะสมแบบกลุ่มอนุภาค (Particle swarm optimization algorithm : PSO)

Eberhart และ Kennedy [2] ได้นำเสนอขั้นตอนวิธีที่เหมาะสมที่สุดแบบกลุ่มอนุภาคเป็นขั้นตอนวิธีแบบหนึ่งที่ใช้ในการหาเหมาะสมที่สุดที่เลียนแบบการหาอาหารของฝูงนกหรือฝูงปลา โดย PSO จะมีการหาผลลัพธ์โดยการกำหนดค่าความเร็ว (velocity) ให้กับอนุภาค (Particles) และซึ่งจะเคลื่อนที่ไปบนไฮเปอร์สเปซ (Hyperspace) แต่ละอนุภาคที่อยู่บนไฮเปอร์สเปซนั้นจะทำการหาจุดเหมาะสมที่สุด ในความเร็วที่กำหนดโดยในแต่ละครั้งที่ทำวนซ้ำเพื่อหาค่าที่เหมาะสมที่สุดนั้นแต่ละอนุภาคจะทำการปรับเปลี่ยนเวกเตอร์ของทิศทางเคลื่อนที่ตามอิทธิพลของตำแหน่งที่ดีที่สุดของแต่ละอนุภาค (pbest) รวมไปถึงตำแหน่งที่ดีที่สุดของอนุภาคอื่นๆหรือของฝูง (gbest) ในกระบวนการทำงานของขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคมีดังนี้

ขั้นตอนที่ 1: กำหนดจุดอนุภาคหรือ p ในรอบ t ว่า $x^i(t)$ ซึ่งสามารถเขียนให้อยู่ในรูปแบบคู่อันดับได้ดังสมการที่ 5

$$X^i(t) = (x^i(t), y^i(t)) \quad (5)$$

ขั้นตอนที่ 2: ประเมินค่าความเหมาะสมของแต่ละอนุภาคตาม Fitness function ที่กำหนด

ขั้นตอนที่ 3: ในแต่ละอนุภาคให้เปรียบเทียบค่าความเหมาะสมกับ $pbest$ เพื่อพิจารณาว่าจะปรับ $pbest$ หรือไม่

ขั้นตอนที่ 4: อัปเดตความเร็วและตำแหน่งของอนุภาค ซึ่งความเร็วของแต่ละอนุภาคนั้นจะถูกปรับดังสมการที่ 6

$$V^i(t+1) = wV^i(t) + c_1r_1(pbest^i - X^i(t)) + c_2r_2(gbest - X^i(t)) \quad (6)$$

ขั้นตอนที่ 5: ทำวนซ้ำที่ขั้นตอนที่ 2 จนครบจำนวนครั้งที่กำหนดหรือได้ค่าที่เหมาะสม

วิธีดำเนินการ

ในการวิจัยนี้ได้นำ PSO algorithm มาใช้ในการหาค่าที่เหมาะสมที่สุดให้กับค่าน้ำหนักของเอาต์พุตโหนดที่ได้มาจาก ELM โดยแบบจำลอง PSO-ELM นี้จะถูกนำมาใช้ในการทำนายค่าดัชนีคุณภาพน้ำ ซึ่งการหาค่าน้ำหนักของเอาต์พุตโหนดที่เหมาะสมที่สุดนั้นจะใช้ค่าน้ำหนักของเอาต์พุตโหนดเป็นตำแหน่งเริ่มต้นในแต่ละอนุภาค และเพิ่มสุ่มค่าเพิ่มให้กับแต่ละอนุภาคเพื่อให้ตำแหน่งเริ่มต้นนั้นมีความแตกต่างกันออกไป และ PSO จะใช้ค่า RMSE เป็น Fitness function ซึ่งมีสูตรการคำนวณคือ

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (7)$$

โดยขั้นตอนการทำงานของ PSO-ELM มีดังนี้

ขั้นตอนที่ 1: ฝึกสอน ELM ด้วยชุดข้อมูลฝึกสอน

ขั้นตอนที่ 2: กำหนดตำแหน่งของแต่ละอนุภาคด้วยค่าน้ำหนักของเอาต์พุตโหนดโดยมีจำนวนอนุภาคเท่ากับจำนวนเอาต์พุตโหนด

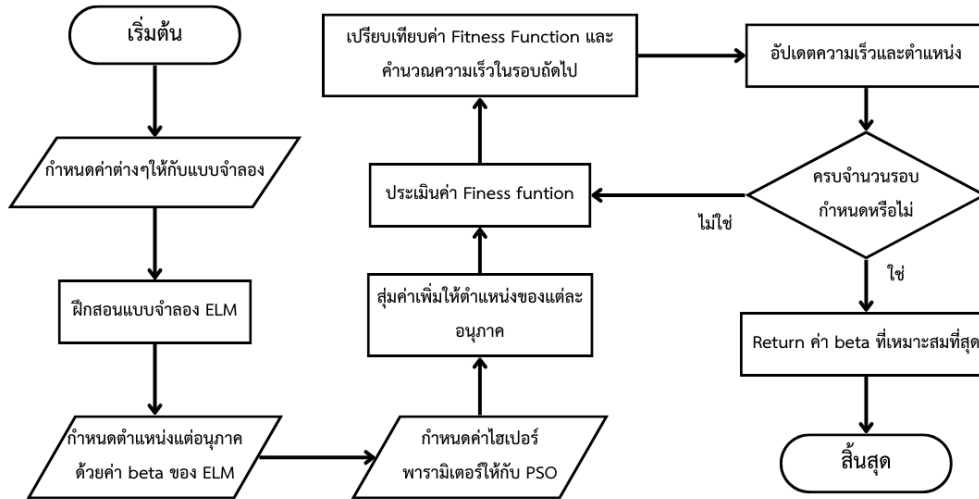
ขั้นตอนที่ 3: สุ่มค่าเพิ่มให้แต่ละตำแหน่งของแต่ละอนุภาค

ขั้นตอนที่ 4: กำหนดค่าน้ำหนักของเอาต์พุตโหนดใหม่ให้กับแบบจำลอง ELM ที่ฝึกสอนในขั้นตอนที่ 1 ด้วยค่าตำแหน่งของแต่ละอนุภาค เพื่อคำนวณหาค่า Fitness function ด้วยการฝึกสอนแบบจำลอง ELM โดยมีค่า RMSE เป็นค่า Fitness

ขั้นตอนที่ 5: เปรียบเทียบค่า Fitness และคำนวณความเร็วให้กับแต่ละอนุภาค

ขั้นตอนที่ 6: อัปเดตความเร็วและตำแหน่งของแต่ละอนุภาค

ขั้นตอนที่ 7: ทำวนซ้ำจนกว่าจะครบจำนวนรอบที่กำหนด



รูปภาพที่ 1 แสดงผังขั้นตอนการทำงานของ PSO-ELM

การฝึกสอนแบบจำลอง ELM นั้นใช้ข้อมูลฝึกสอนจำนวน 1316 รายการ และได้กำหนด hyper-parameter ต่างๆให้กับแบบจำลองดังนี้

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

จากนั้นผู้วิจัยได้ออกแบบขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคเพื่อนำเอาค่าน้ำหนักของโหนดผลลัพธ์จากการทดลองที่ใช้จำนวนโหนดชั้นซ่อนจำนวน 50 โหนด ไปทำการหาค่าน้ำหนักที่เหมาะสมให้กับแบบจำลองซึ่งปกติแล้วตำแหน่งเริ่มต้นและความเร็วของแต่ละอนุภาคจะเกิดจากการสุ่ม แต่ในงานวิจัยนี้ได้กำหนดตำแหน่งเริ่มต้นด้วยค่าน้ำหนักของชั้นผลลัพธ์ที่ได้จาก ELM และสุ่มค่าที่อยู่ระหว่าง -999.9999 ถึง 999.9999 โดยให้จำนวนรอบในการทำซ้ำจำนวน 100 รอบ กำหนดจำนวนอนุภาคคือ 3000 อนุภาค และมีการกำหนดค่าอื่นๆดังตารางที่ 1

ตารางที่ 1 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

ผลการวิจัยและอภิปรายผลการวิจัย

การวิจัยนี้ได้แบ่งการทดลองเป็น 2 แบบคือ การทดลองของแบบจำลอง ELM และการทดลองของแบบจำลอง PSO-ELM โดยการทดลองของแบบจำลอง ELM นั้นจะมีผลการทดลองดังตารางที่ 2

ตารางที่ 2 แสดงผลการทดลองของแบบจำลอง ELM

การทดลอง	จำนวนโหนดชั้นซ่อน	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 ที่การทดสอบคือ 5.136 ซึ่งไม่ได้ต่างจากการทดลองที่มีโหนดชั้นซ่อน 125 โหนดมากนัก และจำนวนโหนดชั้นซ่อนที่ไม่มากเกินไปทำให้สามารถวิเคราะห์ผลได้ง่าย จึงได้เลือกแบบจำลอง ELM ที่กำหนดโหนดชั้นซ่อน 50 โหนดไปใช้ในแบบจำลอง PSO-ELM ต่อไป

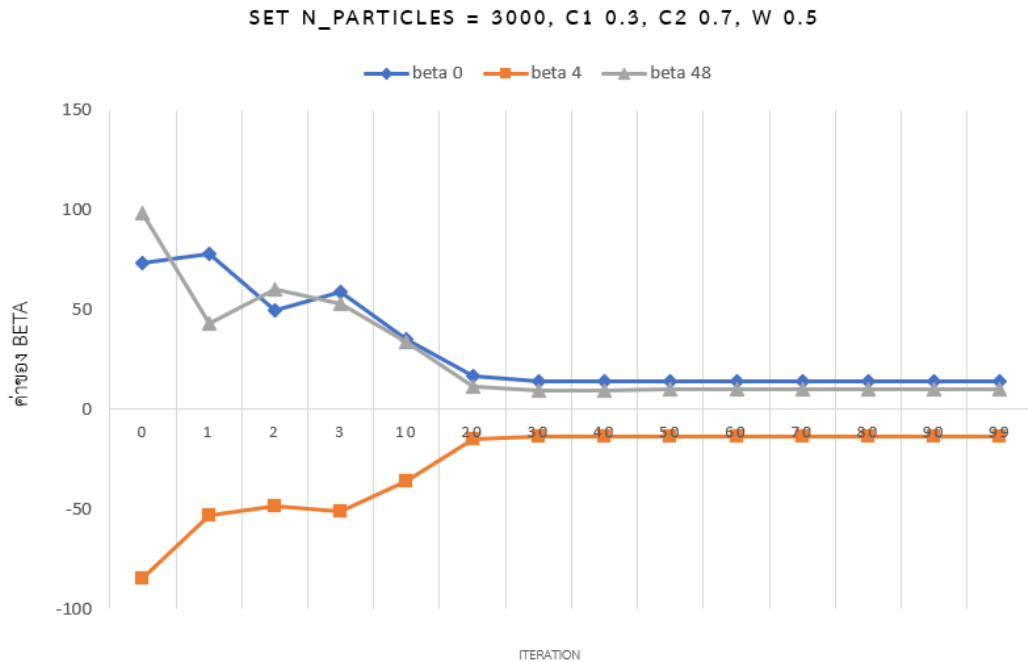
จากนั้นจึงได้นำการทดลองของแบบจำลอง ELM ที่กำหนดจำนวนชั้นซ่อน 50 โหนดนั้นมาหาค่าน้ำหนักของโหนดเข้าที่พุดโดยใช้ PSO โดยได้กำหนดรอบในการวนซ้ำ 100 รอบ และจำนวนอนุภาค 3000 อนุภาค ซึ่งผลการทดลองของ PSO-ELM จะได้ผลดังตารางที่ 3

ตารางที่ 3 แสดงผลการทดลองของ PSO-ELM ที่มีจำนวนโหนดชั้นซ่อน 50 โหนด

การทดลอง	ค่า parameter ที่กำหนด			ผลลัพธ์				
	w	c1	c2	train		test		เวลา h:mm:ss
				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 0.5, C1 คือ 0.3 และ c2 คือ 0.7 โดยได้ค่า RMSE ที่ชุดข้อมูลทดสอบ (Test data) คือ 5.912 ซึ่งน้อยที่สุดเมื่อเทียบกับการทดลองอื่นๆ และสามารถได้ค่า RMSE ใกล้เคียงกับแบบจำลอง ELM ที่กำหนดโหนดชั้นซ่อนจำนวน 50 โหนด แต่จะใช้เวลานานกว่า

โดยการหาค่าน้ำหนักของเอาพุตโหนดที่ดีที่สุดของแบบจำลอง PSO-ELM นั้น ในแต่ละอนุภาคจะค่อยๆเปลี่ยนแปลงไปตามอนุภาคที่ดีที่สุดในแต่ละรอบซึ่งสุดท้ายแล้วก็ได้อ่านน้ำหนักของเอาพุตโหนดที่ทำให้ได้ค่า RMSE ที่น้อยที่สุด ดังภาพที่ 2



ภาพที่ 2 แสดงค่าน้ำหนักของเอาพุตโหนดในแต่ละรอบ

จากภาพที่ 2 จะเห็นได้ว่าค่าน้ำหนักของเอาพุตโหนดในแต่ละรอบจะค่อยๆเปลี่ยนแปลงไปเรื่อยๆ และเริ่มที่มีการเปลี่ยนแปลงที่น้อยลง ซึ่งทำให้เห็นว่าค่าน้ำหนักของเอาพุตโหนดที่ได้ออกมานั้นเป็นค่าที่ดีที่สุดของการทดลอง

สรุปผลการวิจัย

จากการทดลองของแบบจำลอง ELM และแบบจำลอง PSO-ELM นั้นได้ข้อสรุปคือ แบบจำลอง ELM นั้นมีความรวดเร็วในการเรียนรู้และมีประสิทธิภาพอย่างมากเมื่อมีจำนวนโหนดชั้นซ่อนที่เพิ่มมากขึ้น ซึ่งถ้าสามารถหาค่าน้ำหนักของโหนดรับเข้าและค่าเบี่ยงเบนได้เหมาะสมกับจำนวนโหนดและชุดข้อมูลฝึกสอนก็จะทำให้ได้ค่าน้ำหนักของโหนดผลลัพธ์ที่สามารถคำนวณค่าดัชนีคุณภาพน้ำได้แม่นยำมากขึ้น ในส่วนของแบบจำลอง PSO-ELM นั้นผลลัพธ์ของค่าความคลาดเคลื่อนที่ได้นั้นก็มีความใกล้เคียงกับแบบจำลอง ELM แต่ค่อนข้างที่จะต้องใช้เวลาในการประมวลผลที่นานกว่า เมื่อพิจารณาจากค่าน้ำหนักของโหนดผลลัพธ์ที่ออกมาเมื่อนำมาเทียบกับของ ELM แล้วนั้นก็มีความใกล้เคียงกัน

โดยจากการทดลองทั้ง 2 แบบจำลองนี้สามารถบอกได้ว่าการคำนวณค่าน้ำหนักของโหนดผลลัพธ์ของแบบจำลอง ELM ที่ใช้เมตริกฟังก์ชันแบบมอร์-เพนโรสในการคำนวณนั้นสามารถหาค่าน้ำหนักของโหนดผลลัพธ์จากชุดข้อมูล จำนวนโหนด ค่าน้ำหนัก

ของโหนดรับเข้า และค่าเบี่ยงเบนที่จะทำให้การทำนายค่าดัชนีคุณภาพน้ำมีความแม่นยำได้ดีที่สุดแล้ว เนื่องจากการทดลองของแบบจำลอง PSO-ELM นั้นเมื่อมีการเพิ่มค่าให้กับค่าน้ำหนักของโหนดชั้นซ่อนเพื่อที่จะนำมาเป็นจุดเริ่มต้นของอนุภาค เมื่อ PSO ประมวลผลเสร็จสิ้น ค่าน้ำหนักของโหนดชั้นซ่อนที่ได้ออกมาจะใกล้เคียงกับค่าที่ได้จากแบบจำลอง ELM เพราะจากบทความต่างๆที่ได้นำมาอ้างอิงนั้นกล่าวว่า PSO นั้นจะสามารถหาค่าที่ดีที่สุดหรือใกล้เคียงได้เสมอถ้ากำหนดจำนวนรอบการทำซ้ำกับจำนวนอนุภาคเหมาะสมกับปัญหา

ดังนั้นการใช้ PSO-ELM ในการปรับที่ค่าน้ำหนักของโหนดผลลัพธ์นั้นสามารถทำได้แต่จะไม่สามารถเพิ่มความแม่นยำได้มากนักเมื่อเทียบกับเวลาที่ใช้ในการประมวลผลที่เพิ่มมากขึ้น โดยถ้าต้องการใช้ PSO-ELM เพื่อที่จะเพิ่มความแม่นยำนั้น ควรนำไปใช้ในการหาค่าที่เหมาะสมของจำนวนโหนดชั้นซ่อน ค่าน้ำหนักของชั้นรับเข้า หรือค่าเบี่ยงเบน ซึ่งจะช่วยให้แบบจำลองมีความแม่นยำที่ตีมากขึ้น

กิตติกรรมประกาศ

การจัดทำวิจัยได้รับการสนับสนุนจากบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ในการนำเสนอผลงานวิจัย ผู้วิจัยจึงขอขอบคุณมา ณ ที่นี้

เอกสารอ้างอิง

- [1] 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>
- [2] 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>
- [3] Hagiabi, 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>
- [4] 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>

[5] Popyack, J. L. (2016). Gusz Eiben and Jim Smith (Eds): Introduction to evolutionary computing. Genetic Programming and Evolvable Machines, 17(2), 197-199. RetriveForm<https://doi.org/10.1007/s10710-016-9267-7>

[6] 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>

[7] มุสิกะวัน, ภ., เชี่ยวชาญวัฒนา, ส., & สุนันติ, ค. (2016). เครื่องจักรเรียนรู้เอ็กซ์ตรีมเชิงวิวัฒนาการโดยใช้พื้นฐานของขั้นตอนการค้นหาค่าที่เหมาะสมแบบสแต็บไซส์แรนดอมและขั้นตอนวิธีแบบหึ่งห้อย. Information Technology Journal.

RetriveFormhttps://ph01.tci-thaijo.org/index.php/IT_Journal/article/view/54182