



เครื่องจักรเรียนรู้เอ็กซ์ตรีมเชิงวิวัฒนาการโดยใช้พื้นฐานของขั้นตอนการค้นหาค่าที่เหมาะสมแบบสเต็ปไซส์แรนดอมและขั้นตอนวิธีแบบหิ่งห้อย

Evolutionary Extreme Learning Machine Based on Optimized Step-Size Random Search Firefly Algorithm

ภคิราษ มุสิกะวัน (Pakarat Musigawan)*, สิริภัทร เชี่ยวชาญวัฒนา (Sirapat Chiewchanwattana)*
 ค่ำรณ สุหนัฒ (Khamron Sunat)*

บทคัดย่อ

Extreme Learning Machine (ELM) เป็นขั้นตอนวิธีที่มีความเร็ว มีโครงสร้างการทำงานแบบ Single-hidden layer feedforward neural networks (SLFNs) แต่อย่างไรก็ตาม ELM ยังคงใช้หลักการสุ่มเพื่อทำการกำหนดค่าน้ำหนักในชั้นนำเข้าข้อมูลและค่าเอนเอียงในชั้นซ่อน ทำให้มีโอกาสที่จะนำไปสู่ค่าเหมาะสมเฉพาะที่ (Local optimal) งานวิจัยนี้จึงได้นำเสนอวิธีการนำเอา Firefly Algorithm และ Optimized step-size random search (OSSRS) เข้ามาใช้ในการค้นหาค่าน้ำหนักในชั้นนำเข้าข้อมูลและค่าเอนเอียงในชั้นซ่อนที่เหมาะสมเพื่อนำไปใช้กับ ELM ซึ่งถูกเรียกว่า Optimized step-size random search Firefly Algorithm Extreme Learning Machine (OSSRS FA ELM) โดยทำการเปรียบเทียบประสิทธิภาพกับ ELM แบบเดิมและ ELM ที่ถูกเรียนรู้เพื่อหาค่าน้ำหนักโดยใช้ Firefly Algorithm, Differential Evolution, Group Search Optimization จากผลทดลองแสดงให้เห็นว่า OSSRS FA ELM ให้ความถูกต้องในการจำแนกข้อมูลโดยเฉลี่ยสูงกว่า FA ELM 0.26%, DE ELM 0.72%, GSO ELM 0.67% และ ELM 1.63%

คำสำคัญ: เครื่องจักรเรียนรู้เอ็กซ์ตรีม, ขั้นตอนวิธีหิ่งห้อย, การค้นหาค่าที่เหมาะสมแบบสเต็ปไซส์แรนดอม

Abstract

Extreme learning machine (ELM) is a new learning algorithm much faster than traditional gradient-based learning algorithm, was proposed for single-hidden layer feedforward

neural networks (SLFNs). However, ELM use random determination of the input weight and hidden biases may lead to local optimal. In this paper proposes a hybrid learning algorithms is proposed based on Optimized step-size random search (OSSRS) and Firefly algorithm to select input weight and hidden biases for ELM, called Optimized step-size random search Firefly Algorithm Extreme Learning Machine (OSSRS FA ELM). Then comparison the performance with OSSRS FA ELM, ELM and other a hybrid ELM trained to find input weights and hidden biases by Firefly Algorithm, Differential Evolution, Group Search Optimization. Experimental result show that OSSRS FA ELM is more accuracy than FA ELM 0.26%, DE ELM 0.72%, GSO ELM 0.67% and ELM 1.63%.

Keyword: Extreme learning machine, Firefly algorithm, Optimized step-size random search.

1. บทนำ

วิธีการขั้นตอนโครงข่ายประสาทเทียมเป็นวิธีการที่นิยมกันอย่างแพร่หลายในปัจจุบัน ซึ่งวิธีการขั้นตอนโครงข่ายประสาทเทียมแบบเดิมนั้นมีข้อเสียคือมีความช้า รวมไปถึงวิธีการดังกล่าวมีโอกาสที่จะได้ค่าเหมาะสมเฉพาะที่ (Local optimal) สูง

ในปัจจุบันได้มีการนำเสนอวิธีขั้นตอนที่ใหม่และทำงานได้รวดเร็วกว่าวิธีการแบบเดิม โดยวิธีการดังกล่าวมีการทำงานอยู่บนโครงข่ายแบบ Single-hidden layer feedforward neural

* ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยขอนแก่น



networks (SLFNs) ซึ่งมีชื่อเรียกว่า Extreme Learning Machine (ELM) วิธีดังกล่าวมีความสามารถในการทำงานที่มีความเร็วสูงโดยอาศัยวิธีการกำหนดค่าน้ำหนักและค่าเอนเอียงที่ถูกนำมาใช้สำหรับโหนดชั้นซ่อนจากการสุ่มแทนที่วิธีการวนปรับค่าน้ำหนักที่ใช้ในวิธีการเรียนรู้แบบเดิม และในส่วนของค่าน้ำหนักของชั้นผลลัพธ์ได้มาจากวิธีการคำนวณเมตริกซ์ผกผันแบบมอร์-เพนโรส (Moore-Penrose) ถึงแม้ว่า ELM มีความเร็วในการทำงานสูง แต่ความถูกต้องของตัวแบบ ELM นั้นขึ้นอยู่กับค่าน้ำหนักที่ได้จากการสุ่มซึ่งมีความไม่แน่นอน ทำให้มีโอกาสที่จะได้ค่าเหมาะสมเฉพาะที่สูง และอาจต้องใช้จำนวนโหนดชั้นซ่อนเป็นจำนวนมาก [1], [2], [3], [4]

นับตั้งแต่ขั้นตอนวิธีการเชิงวิวัฒนาการถูกนำมาใช้อย่างแพร่หลายในการหาค่าตอบที่ดีที่สุด (Global optimal) ซึ่งขั้นตอนวิธีการเหล่านี้มีความสามารถในการหลีกเลี่ยงปัญหาค่าเหมาะสมเฉพาะที่ โดยมักนำมาประยุกต์ใช้ร่วมกับโครงข่ายประสาทเทียมเป็นอย่างมากเพื่อที่จะใช้ในการปรับค่าน้ำหนักเพื่อให้ได้มาซึ่งค่าน้ำหนักที่มีประสิทธิภาพที่สุด โดยได้มีงานวิจัยต่างๆ ได้นำเอาขั้นตอนวิธีการเชิงวิวัฒนาการมาปรับใช้ร่วมกับ ELM เพื่อทำการหาค่าน้ำหนักที่ดีที่สุด เช่น ในการนำเอา Differential Evolution (DE) มาปรับใช้ร่วมกับ ELM เพื่อหาค่าน้ำหนักที่ดีที่สุดซึ่งถูกเรียกว่า Evolutionary Extreme Learnin (E-ELM) ถูกนำเสนอโดย Huang และคณะ [3], การนำเอา Particle Swarm Optimization (PSO) มาปรับใช้ร่วมกับ ELM เพื่อใช้สำหรับงานประเภทพยากรณ์โดยใช้ข้อมูลผลผลิตข้าวโพดและปัจจัยที่มีต่อผลผลิตข้าวโพดในประเทศจีน ถูกนำเสนอโดย You Xu และ Yang Shu [8] และในการนำเอา Group Search Optimization (GSO) มาปรับใช้ร่วมกับ ELM ถูกนำเสนอโดย D. N. G. Silva และคณะ [9] ซึ่งในงานวิจัยนี้ได้นำเสนอวิธีการในการหาค่าน้ำหนักที่เหมาะสมสำหรับชั้นซ่อนของ ELM โดยอาศัยข้อดีของ ELM และ Firefly Algorithm พร้อมทั้งนำเสนอวิธีใหม่ในการเพิ่มประสิทธิภาพให้กับ E-ELM โดยการนำเอา Optimized step-size random search (OSSRS) มาปรับใช้ร่วมอีกด้วย โดยในการทดลองได้ใช้ Firefly Algorithm Extreme Learning Machine (FA ELM), Differential Evolution Extreme Learning Machine (DE ELM), Group Search Optimization Extreme Learning Machine (GSO ELM) และ Extreme Learning Machine (ELM) แบบเดิม มาทำการทดสอบเพื่อใช้ในการเปรียบเทียบประสิทธิภาพ

สำหรับส่วนที่เหลือ ของบทความได้แบ่งออกเป็นสี่ส่วนดังนี้ คือ วิจัยที่เกี่ยวข้อง วิธีการดำเนินการวิจัย ผลการดำเนินการวิจัย และสรุปผลการวิจัย

2. วิจัยที่เกี่ยวข้อง

2.1 Extreme Learning Machine

Extreme Learning Machine (ELM) ถูกนำเสนอโดย Huang และคณะ [1], [2] เป็นวิธีขั้นตอนที่มีการทำงานแบบ Single-Hidden Layer Feedforward Networks (SLFNs) ที่ประกอบไปด้วย K โหนดชั้นซ่อน และฟังก์ชันกระตุ้น $g(x)$ โดยนำไปใช้ในการเรียนรู้ข้อมูลจำนวน N ตัว ในรูปแบบ $(x_i, t_i), i = 1, 2, \dots, N$ โดยที่ $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in R^n$ และ $t_i = (t_{i1}, t_{i2}, \dots, t_{im})^T \in R^m$ โดยในส่วนของค่าน้ำหนัก และค่าเอนเอียงที่อยู่ระหว่างชั้นนำเข้าและชั้นซ่อนได้มาจากการสุ่มค่าโดยไม่มีการวนปรับ โดยหลักการการทำงานจะทำการแปลงจากระบบสมการไม่เชิงเส้นเป็นสมการเชิงเส้นดังสมการต่อไปนี้

$$Hb = T \quad (1)$$

เมื่อ $H = \{h_{ij}\} (i = 1, \dots, N \text{ and } j = 1, \dots, K)$ เป็นเมตริกผลลัพธ์ที่ได้มาจากโหนดชั้นซ่อน โดยแต่ละผลลัพธ์ได้มาจากฟังก์ชัน $h_{ij} = g(w_j x_i + b_j)$ ซึ่งจะเป็นผลลัพธ์ของโหนดชั้นซ่อนที่ j ที่เป็นผลลัพธ์ของข้อมูล $x_i, w_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T$ เป็นค่าน้ำหนักของโหนด j และ b_j เป็นค่าเอนเอียงของโหนดชั้นซ่อนที่ $j, b = [b_1, b_2, \dots, b_k]^T$ เป็นค่าน้ำหนักของชั้นผลลัพธ์ $b_j = [b_{j1}, b_{j2}, \dots, b_{jm}]^T (j = 1, \dots, K)$ เป็นเวกเตอร์ของค่าถ่วงน้ำหนักที่อยู่ระหว่างโหนดที่ j ของชั้นซ่อนและชั้นผลลัพธ์ $T = [t_1, t_2, \dots, t_n]^T$ เป็นเมตริกของผลลัพธ์ ในส่วนของการหาค่าน้ำหนักที่ชั้นผลลัพธ์ใช้วิธีการหาค่ากำลังสองน้อยสุดดังต่อไปนี้

$$\hat{b} = H^+ T \quad (2)$$

เมื่อ H^+ แทนเมตริกผกผันแบบมอร์-เพนโรสของเมตริก และเป็นค่าประมาณที่มีค่านอร์มต่ำสุด

2.2 Firefly Algorithm

Firefly algorithm (FA) ถูกนำเสนอโดย Xin-She Yang [5], [6] โดยใช้ในการแก้ปัญหาแบบไม่เชิงเส้น ซึ่งจะใช้หลักการในการเคลื่อนที่ของหิ่งห้อยตัวอื่นไปหาหิ่งห้อยตัวที่มีค่าความน่าสนใจมากกว่าซึ่งวัดจากค่าความหนาแน่นของแสงของหิ่งห้อยตัวนั้น สามารถคำนวณการเคลื่อนที่ของหิ่งห้อยได้จากสมการ



$$x_i = x_i + b_0 e^{-g r_{ij}^2} (x_i - x_j) + a e_i \quad (3)$$

จากสมการเป็นการเคลื่อนที่ของหิ่งห้อย i ไปหาหิ่งห้อย j เมื่อพบว่าหิ่งห้อย j มีค่าความหนาแน่นของแสงที่ดีกว่า โดยมีความน่าสนใจ b ของหิ่งห้อยจะขึ้นอยู่กับค่าระยะทาง r_{ij} ระหว่างหิ่งห้อย ซึ่งค่าระยะทางดังกล่าวสามารถคำนวณได้จากการหาระยะทางคาร์ทีเซียน (Cartesian distance) และสามารถที่จะทำการคำนวณหาค่าความน่าสนใจของหิ่งห้อยได้จากสมการ

$$b = b_0 e^{-g r_{ij}^2} \quad (4)$$

เมื่อ b_0 คือค่าความน่าสนใจเมื่อตอนที่ $r = 0$ และ g คือค่าสัมประสิทธิ์การดูดกลืนแสง

2.3 An optimized step-size random search

เป็นวิธีการในการค้นหาแบบสุ่มสำหรับการหาค่าที่น้อยที่สุด ซึ่งวิธีนี้ในส่วนของ step-size จะถูกกำหนดค่าโดยการหาค่าที่เหมาะสมที่สุดจากสมการกำลังสองสำหรับเป็นค่าของฟังก์ชัน โดยในแต่ละขั้นตอนจะทำการสุ่มเพื่อหาค่าทิศทาง ซึ่งจะใช้วิธีการสุ่มโดยใช้ตัวสร้างเลขสุ่มเทียม (pseudorandom number generator) กับการแจกแจงปกติและส่วนเบี่ยงเบนมาตรฐานที่กำหนด [7]

3. วิธีการดำเนินการวิจัย

ในส่วนนี้เป็นการนำเสนอวิธีประยุกต์การทำงานร่วมกันระหว่าง ELM, Firely Algorithm และ OSSRS ขั้นตอนแรกให้ทำการสร้างประชากรหิ่งห้อยด้วยวิธีการสุ่ม โดยหิ่งห้อยแต่ละตัวจะเป็นตัวแทนคำตอบของค่าน้ำหนัก w_{ij} และค่าเอนเอียง b_j สำหรับชั้นซ่อน

$$q = [w_{11}, w_{12}, \dots, w_{1k}, w_{22}, \dots, w_{2k}, \dots, w_{n1}, w_{n2}, \dots, w_{nk}, b_1, b_2, \dots, b_k]$$

ค่า w_{ij} และ b_j ทั้งหมดที่ได้มาจากการสุ่มที่มีค่าอยู่ช่วงระหว่าง $[-1, 1]$

โดยหิ่งห้อยแต่ละตัวที่ถูกแทนเป็นค่าของน้ำหนัก และค่าเอนเอียงจะถูกนำมาใช้ในการวิเคราะห์เพื่อทำการคำนวณหาค่าน้ำหนักในชั้นผลลัพธ์ของ ELM โดยใช้ Moore-Penrose (MP) แทนที่วิธีการวนปรับค่ารูปแบบเดิม

หลังจากนั้นจะทำการหาค่าความหนาแน่นของแสงของแต่ละประชากร โดยใช้ Cost function (E) เป็น Root mean squared error (RMSE) ในการคำนวณหาค่าความหนาแน่นของแสงให้กับหิ่งห้อยแต่ละตัว

$$E = \sqrt{\frac{\sum_{j=1}^N \left\| \sum_{i=1}^K b_i f(w_i \cdot x_i + b_i) - t_j \right\|^2}{m \times N}} \quad (5)$$

Begin

Objective function $f(x), (x_1, x_2, \dots, x_n)^T$

Generate initial population of fireflies $x_i (i = 1, 2, \dots, n)$

Define light absorption coefficient g

Light intensity I_i at x_i is determined by $f(x_i)$ where I_i is RSME obtained by ELM

While (t < MaxGeneration)

For i=1:n all flyfies

For j=1:i all flyfies

If ($I_i > I_j$), Move firefly x_i towards x_j , End if

Attractiveness varies with distance r via

$exp[-gr^2]$

Calculate of by OSSRS

Evaluate new solution and update light intensity

by $f(x_i)$

where a new light intensity is RSME obtained by ELM

End for

End for

End while, x_{best} to weight and bias for ELM

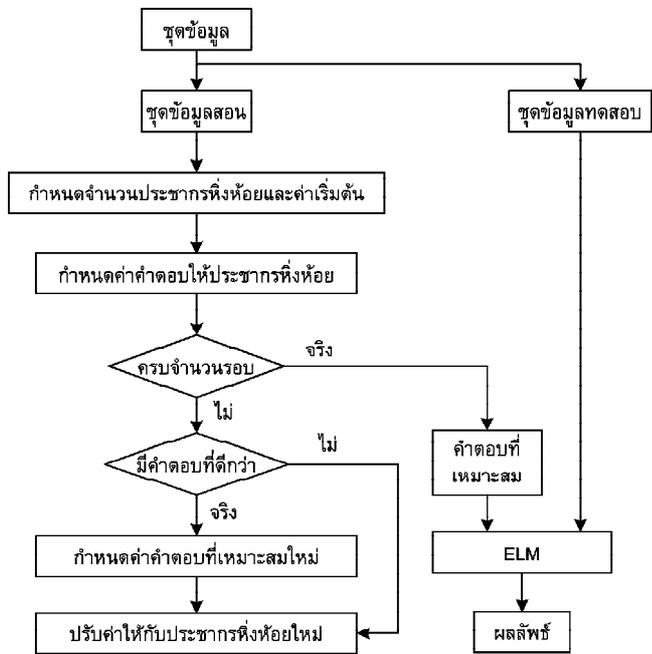
End

ภาพที่ 1 โค้ดเทียมแสดงขั้นตอนของ OSSRS FA ELM

หลังจากที่ทำการคำนวณหาค่าความหนาแน่นของแสงให้กับหิ่งห้อยครบทุกตัวแล้ว จะเป็นการเริ่มต้นการทำงานของ Firefly Algorithm โดยที่จะทำการเปรียบเทียบค่าความหนาแน่นของแสงของหิ่งห้อยแต่ละตัว โดยหิ่งห้อยตัวที่มีความหนาแน่นของแสงแยกกว่าจะต้องบินไปหาหิ่งห้อยตัวที่มีความหนาแน่นของแสงที่ดีกว่า ซึ่งค่าความหนาแน่นของแสงในที่นี้ได้มาจากค่า RMSE ของ ELM ที่ใช้เป็น Fitness Function เมื่อได้หิ่งห้อยที่มีค่าความหนาแน่นแสงที่ดีที่สุดในแต่ละรอบแล้วให้หาหิ่งห้อยที่ดีที่สุดในรอบนั้นมาทำการคำนวณด้วยตัวแบบ



OSSRS เพื่อทำการหาค่าที่ดีที่สุดอีกครั้ง หลังจากที่ได้คำตอบที่ดีที่สุดแล้วก็จะนำเอาประชากรหึ่งห้อยที่เป็นตัวแทนของค่านำหนักในชั้นข้อมูลนำเข้าและค่าเอเนียงในชั้นซ่อนไปเข้าตัวแบบ ELM เพื่อทำการคำนวณให้ได้ผลลัพธ์และทำการประเมินผล



ภาพที่ 2 แผนภาพแสดงขั้นตอนวิธีการทำงานของ OSSRS FA ELM

4. ผลการดำเนินการวิจัย

ในส่วนนี้เป็นการเปรียบเทียบประสิทธิภาพการทำงานของ OSSRS FA ELM, FA ELM, DE ELM, GSO ELM และ ELM แบบเดิม โดยทำการประมวลผลจากโปรแกรม MATLAB R2011b สำหรับข้อมูลที่ใช้ในการวัดประสิทธิภาพของตัวแบบจะใช้ข้อมูลทั้งหมด 11 ชุดข้อมูล ดังตารางที่ 1 โดยสามารถทำการดาวน์โหลดข้อมูลได้จากเว็บ <http://www.fml.tuebingen.mpg.de/Members/raetsch/benchmark> เป็นข้อมูลจาก Friedrich Miescher Laboratory of the Max Planck Society ซึ่งข้อมูลดังกล่าวได้ถูกทำการแบ่งข้อมูลมาแล้วจำนวน 100 ชุด โดยใช้วิธีการ K-Fold Cross Validation เพื่อทำการวัดประสิทธิภาพ

ค่าพารามิเตอร์ของ Firefly Algorithm จะถูกกำหนดไว้ดังนี้ $\alpha=0.65$ $\gamma=0.8$ พารามิเตอร์ Population size และ Iterative ใน Firefly Algorithm , DE และ GSO จะถูกกำหนดค่าดังนี้ Population size ถูกกำหนดค่าเป็น 100 จำนวนรอบของ Iterative ถูกกำหนดเป็น 10 ค่านำหนักและค่าเอเนียงที่ใช้ใน

ELM จะมีค่าระหว่าง $[-1,1]$ ฟังก์ชันกระตุ้นของ ELM ที่เลือกใช้คือ sigmoid function $f(x) = 1/(1 + e^{-x})$ และทำการหาจำนวนโหนดชั้นซ่อนที่ดีที่สุดให้กับ ELM ตั้งแต่ 1 ถึง 1000 โหนด และ 1 ถึง 50 โหนด สำหรับ OSSRS FA ELM, FA ELM, DE ELM และ GSO ELM

ตารางที่ 1 ข้อมูลที่ใช้ในการทดลอง

DATASETS	Attributes	Classes	Rows	Train	Test
banana	2	2	5300	400	4900
breast_cancer	9	2	263	200	77
diabetes	8	2	768	468	300
flare_solar	9	2	144	666	400
german	20	2	1000	700	300
heart	13	2	270	170	100
ringnorm	20	2	7400	400	7000
thyroid	5	2	215	140	75
titanic	3	2	24	150	2051
twonorm	20	2	7400	400	7000
waveform	21	2	5000	400	4600

จากการทดสอบวัดค่าความถูกต้องในแต่ละรอบจะให้ค่าความถูกต้องไม่เท่ากัน สำหรับงานวิจัยนี้ได้ทดสอบวัดค่าความถูกต้อง 100 รอบ แล้วนำค่าความถูกต้องที่ได้มาหาค่าเฉลี่ยที่แสดงในตารางที่ 2 ถึงตารางที่ 5 โดยในส่วนผลลัพธ์ที่ถูกทำเป็นตัวหนาจะเป็นผลลัพธ์ที่แสดงค่าความถูกต้องสูงสุดของแต่ละตาราง และในส่วนของ Dif เป็นการแสดงค่าความแตกต่างของผลลัพธ์ที่ได้จากตัวแบบทุกตัวที่ใช้ในการทดสอบกับ OSSRS FA ELM ซึ่งหาก OSSRS FA ELM ได้ค่าที่ดีกว่าจะได้ค่าเป็น "+" หากไม่จะได้ค่าเป็น "-" และค่าเบี่ยงเบนมาตรฐานที่แสดงในตารางที่ 6 ถึงตารางที่ 9 ซึ่งหาก OSSRS FA ELM ได้ค่าที่ดีกว่าจะมีค่าเป็น "-" หากไม่จะได้เป็น "+"

ตารางที่ 2 ผลการเปรียบเทียบความถูกต้องระหว่าง OSSRS FA ELM และ FA ELM

DATASETS	OSSRS FA ELM	FA ELM	Dif
Banana	89.41	89.42	-0.01
breast_cancer	72.34	71.53	0.81
Diabetes	76.08	76.04	0.04
flare_solar	65.86	65.84	0.02
German	75.16	74.6	0.56
Heart	82.36	81.98	0.38
Ringnorm	89.81	89.42	0.39
Thyroid	93.78	93.32	0.46
Titanic	78.29	78.25	0.04
Twonorm	97.14	97.11	0.03
waveform	86.61	86.46	0.15
Average of Dif			0.26



จากตารางที่ 2 แสดงให้เห็นว่าการนำวิธีการ OSSRS มาใช้ร่วมกับวิธีการ Firefly Algorithm สามารถช่วยในการเพิ่มประสิทธิภาพในการหาค่าน้ำหนักที่เหมาะสมได้ดีกว่าเดิม โดย OSSRS FA ELM มีความถูกต้องมากกว่า FA ELM โดยเฉลี่ย 0.26% และให้ความถูกต้องมากกว่า FA ELM เป็นจำนวน 10 ข้อมูลมีเพียงชุดข้อมูล banana ที่ให้ความถูกต้องน้อยกว่า FA ELM ซึ่งแสดงให้เห็นว่าเมื่อนำวิธีการ OSSRS มาปรับร่วมใช้กับ Firefly Algorithm ทำให้มีโอกาสได้ผลลัพธ์ที่ดียิ่งกว่าเดิม

ตารางที่ 3 ผลการเปรียบเทียบความถูกต้องระหว่าง OSSRS FA ELM และ DE ELM

DATASETS	OSSRS FA ELM	DE ELM	Dif
Banana	89.41	89.53	-0.12
breast_cancer	72.34	70.47	1.87
Diabetes	76.08	74.19	1.89
flare_solar	65.86	65.01	0.85
German	75.16	73.43	1.73
Heart	82.36	80.64	1.72
Ringnorm	89.81	90.12	-0.31
Thyroid	93.78	93.84	-0.06
Titanic	78.29	78.44	-0.15
Twonorm	97.14	96.75	0.39
waveform	86.61	86.52	0.09
Average of Dif			0.72

จากตารางที่ 3 แสดงให้เห็นว่าวิธีการ OSSRS FA ELM ให้ความถูกต้องมากกว่า DE ELM โดยเฉลี่ย 0.72% โดยให้ความถูกต้องมากกว่า DE ELM อยู่ 7 ข้อมูล คือ breast_cancer, diabetes, flare_solar, german, heart, twonorm และ waveform

ตารางที่ 4 ผลการเปรียบเทียบความถูกต้องระหว่าง OSSRS FA ELM และ GSO ELM

DATASETS	OSSRS FA ELM	GSO ELM	Dif
Banana	89.41	89.28	0.13
breast_cancer	72.34	71.68	0.66
Diabetes	76.08	75.6	0.48
flare_solar	65.86	65.74	0.12
German	75.16	75.02	0.14
Heart	82.36	81.9	0.46
Ringnorm	89.81	87.62	2.19
Thyroid	93.78	92.43	1.35
Titanic	78.29	78.07	0.22
Twonorm	97.14	96.9	0.24
waveform	86.61	85.2	1.41
Average of Dif			0.67

จากตารางที่ 4 แสดงให้เห็นว่าวิธีการ OSSRS FA ELM ให้ความถูกต้องมากกว่า GSO ELM โดยเฉลี่ย 0.67% โดยให้ความถูกต้องมากกว่า GSO ELM ทุกชุดข้อมูล

ตารางที่ 5 ผลการเปรียบเทียบความถูกต้องระหว่าง OSSRS FA ELM และ ELM

DATASETS	OSSRS FA ELM	ELM	Dif
Banana	89.41	88.98	0.43
breast_cancer	72.34	72.26	0.08
Diabetes	76.08	75.64	0.44
flare_solar	65.86	65.59	0.27
German	75.16	74.79	0.37
Heart	82.36	81.78	0.58
Ringnorm	89.81	78.17	11.64
Thyroid	93.78	92.88	0.9
Titanic	78.29	77.69	0.6
Twonorm	97.14	96.34	0.8
waveform	86.61	84.83	1.78
Average of Dif			1.63

จากตารางที่ 5 แสดงให้เห็นว่าวิธีการ OSSRS FA ELM ให้ความถูกต้องมากกว่า ELM โดยเฉลี่ย 1.63% โดยให้ความถูกต้องมากกว่า ELM ทุกชุดข้อมูลที่ใช้ในการทดสอบเพื่อวัดประสิทธิภาพ เนื่องจากหลักการทำงานของ ELM ใช้วิธีการสุ่มเพื่อทำการกำหนดค่าน้ำหนักในชั้นข้อมูลนำเข้าและค่าเอเนอจี้ในชั้นซ่อน ทำให้ผลลัพธ์ที่ได้มาเป็นผลลัพธ์ที่ไม่มีความถูกต้องมากที่ควร

ตารางที่ 6 ผลการเปรียบเทียบค่าความเบี่ยงเบนมาตรฐานระหว่าง OSSRS FA ELM และ FA ELM

DATASETS	OSSRS FA ELM	FA ELM	Dif
Banana	0.64	0.6	0.04
breast_cancer	6.66	6.75	-0.09
Diabetes	2.76	2.81	-0.05
flare_solar	2.74	2.51	0.23
German	3.42	3.46	-0.04
Heart	5.46	5.12	0.34
Ringnorm	0.75	0.88	-0.13
Thyroid	3.67	4.09	-0.42
Titanic	1.13	1.22	-0.09
Twonorm	0.26	0.31	-0.05
waveform	0.9	0.89	0.01
Average of Dif			-0.02

ตารางที่ 7 ผลการเปรียบเทียบค่าความเบี่ยงเบนมาตรฐานระหว่าง OSSRS FA ELM และ DE ELM

DATASETS	OSSRS FA ELM	DE ELM	Dif
Banana	0.64	0.62	0.02
breast_cancer	6.66	6.48	0.18
Diabetes	2.76	3.19	-0.43
flare_solar	2.74	3.28	-0.54
German	3.42	3.7	-0.28
Heart	5.46	5.54	-0.08
Ringnorm	0.75	0.84	-0.09
Thyroid	3.67	4.01	-0.34
Titanic	1.13	1	0.13
Twonorm	0.26	0.31	-0.05
waveform	0.9	0.97	-0.07
Average of Dif			-0.14



นอกจากนี้การนำเอาวิธีเชิงวิวัฒนาการเข้ามาปรับร่วมกับ ELM ยังสามารถช่วยในการลดจำนวนของโหนดชั้นซ่อนได้อีกด้วยซึ่งแสดงเอาไว้ในตารางที่ 10 แต่อาจต้องใช้เวลาในการฝึกสอนเพิ่มขึ้นมาอีกโดยเวลาที่ใช้การฝึกสอนเพื่อหาค่าน้ำหนักที่เหมาะสมถูกแสดงในตารางที่ 11

ตารางที่ 8 ผลการเปรียบเทียบค่าความเบี่ยงเบนมาตรฐานระหว่าง OSSRS FA ELM และ GSO ELM

DATASETS	OSSRS FA ELM	GSO ELM	Dif
Banana	0.64	0.62	0.02
breast_cancer	6.66	6.71	-0.05
Diabetis	2.76	2.81	-0.05
flare_solar	2.74	2.88	-0.14
German	3.42	3.09	0.33
Heart	5.46	5.17	0.29
Ringnorm	0.75	1.21	-0.46
Thyroid	3.67	4.53	-0.86
Titanic	1.13	1.37	-0.24
Twonorm	0.26	0.39	-0.13
waveform	0.9	1	-0.1
Average of Dif			-0.13

ตารางที่ 9 ผลการเปรียบเทียบค่าความเบี่ยงเบนมาตรฐานระหว่าง OSSRS FA ELM และ ELM

DATASETS	OSSRS FA ELM	ELM	Dif
Banana	0.64	0.64	0
breast_cancer	6.66	4.84	1.82
Diabetis	2.76	1.78	0.98
flare_solar	2.74	1.91	0.83
German	3.42	2.29	1.13
Heart	5.46	3.61	1.85
Ringnorm	0.75	1.41	-0.66
Thyroid	3.67	3.1	0.57
Titanic	1.13	1.12	0.01
Twonorm	0.26	0.4	-0.14
waveform	0.9	0.78	0.12
Average of Dif			0.6

ตารางที่ 10 จำนวนโหนดชั้นซ่อน

DATA	OSSRS FA ELM	FA ELM	DE ELM	GSO ELM	ELM
banana	35	35	35	35	40
breast Cancer	10	10	10	10	20
diabetis	20	20	20	20	20
flare Solar	15	15	15	15	20
german	30	30	30	30	40
heart	20	20	20	20	25
ringnorm	100	100	100	100	110
thyroid	30	30	30	30	35
titanic	10	10	10	10	290
twonorm	50	50	50	50	50
waveform	35	35	35	35	40

5. สรุปการวิจัย

ในงานวิจัยนี้ได้ทำเสนอวิธีการ E-ELM แบบใหม่โดยอาศัยวิธีการปรับใช้ร่วมระหว่าง OSSRS, Firefly Algorithm และ

ตารางที่ 11 เวลาที่ใช้ในการเรียนรู้

DATA	OSSRS FA ELM	FA ELM	DE ELM	GSO ELM	ELM
banana	53.08	51.65	56.93	58.41	0.0098
breast	0.83	0.79	0.56	0.68	0.0027
diabetis	9.38	8.87	7.94	8.91	0.008
flare solar	9.6	9.25	8.19	9.39	0.0114
german	16.7	15.25	12.87	18.79	0.0154
heart	6.3	5.88	4.48	6.01	0.0042
ringnorm	143.3	136.3	156.8	173.15	0.036
thyroid	6.52	6.21	4.87	6.12	0.005
titanic	19.34	19.67	19.14	24.49	0.0267
twonorm	96.5	91.04	99.78	108.63	0.012
waveform	57.85	56.08	55.04	63.39	0.0067

ELM ซึ่งถูกเรียกว่า OSSRS Firefly Algorithm Extreme Learning Machine ซึ่งใช้วิธีการหาค่านอร์มต่ำสุดโดยใช้ Moore-Penrose Inverse สำหรับการหาค่าน้ำหนักสำหรับชั้นโหนดผลลัพธ์ และใช้ Firefly Algorithm รวมกับ OSSRS ในการหาค่าน้ำหนักและค่าเอนเอียงที่เหมาะสมสำหรับโหนดชั้นซ่อน ซึ่งวิธี ELM เดิมใช้หลักการสุ่มในการหาค่าน้ำหนักและค่าเอนเอียงสำหรับโหนดชั้นซ่อนทำให้ผลลัพธ์ที่ได้มีความไม่แน่นอน มีโอกาสที่จะได้ค่าเหมาะสมเฉพาะที่สูง รวมไปถึงจำเป็นต้องใช้จำนวนโหนดชั้นซ่อนเป็นจำนวนมาก

โดยผลการทดลองแสดงให้เห็นว่าวิธีการนำเอา OSSRS Firefly Algorithm มาใช้ร่วมกับ ELM ทำให้มีความถูกต้องโดยเฉลี่ยมากกว่าทุกวิธีการที่ใช้ในการทดสอบ และในส่วนของตารางเปรียบเทียบค่าเบี่ยงเบนมาตรฐานได้แสดงให้เห็นว่า OSSRS มีค่าเบี่ยงเบนมาตรฐานดีกว่าวิธีการ E-ELM ที่ใช้ในการทดสอบทุกตัว จากผลการวิจัยสรุปได้ว่า การใช้ขั้นตอนวิธีการ OSSRS Firefly เพื่อหาค่าน้ำหนักและค่าเอนเอียงสำหรับชั้นซ่อนให้กับ ELM ให้ความถูกต้องในการจำแนกข้อมูลโดยเฉลี่ยสูงกว่า FA ELM, DE ELM, GSO ELM และ ELM และให้ค่าเบี่ยงเบนมาตรฐานโดยเฉลี่ยสูงกว่า กว่า FA ELM, DE ELM, GSO ELM

6. เอกสารอ้างอิง

- [1] G.-B. Huang, D. H. Wang, and Y. Lan, "Extreme learning machines a survey," *International Journal of Machine Learning and Cybernetics*, Vol. 2, no. 2, pp. 107-122, 2011.
- [2] G.-B. Huang, Q.-Y. Zhu and C.-K. Siew, "Extream Learning Machine Theory and applications," *Neurocomputing*, Vol. 70, pp. 489-501, 2006.



- [3] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Evolutionary Extreme Learning Machine," *Pattern Recognition*, Vol. 38, pp. 1759-1763, 2005.
- [4] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," *Neural Networks. 2004 IEEE International Joint Conference on Neural Networks*, Budapest Hungary, pp. 985-990, 2004.
- [5] X.-S. Yang, *Engineering Optimization: An Introduction with Metaheuristic Applications*, Wiley & Sons, New Jersey, 2010.
- [6] X.-S. Yang. *Nature-inspired metaheuristic algorithms* Luniver Press, 2008.
- [7] B.V. Sheela, "An Optimized Step-Size Random Search (OSSRS)," *Computer Methods in Applied Mechanics and Engineering*, pp. 99-106, 1979.
- [8] You Xu and Yang Shu, "Evolutionary Extreme Learning Machine Based on Particle Swarm Optimization," *Advances in Neural Networks – ISNN 2006, in: Lecture Notes in Computer Science*, Vol. 3971, pp. 644-652, 2006.
- [9] D. N. G. Silva, L. D. S. Pacifico and T. B. Ludermire, "An Evolutionary Extreme Learning Machine Based on Group Search Optimization," *IEEE Congress on Evolutionary Computation*, pp. 574-580, 2011.
- [10] J. Kennedy, and R. Eberhart, "Particle Swarm Optimization," *Proceedings of IEEE International Conference on Neural Networks*, Vol. 4, pp. 1942-1948, 1995.
- [11] R. Storn, and K. Price, "Differential Evolution – A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces," *Journal of Global Optimization* 11: 341-359, 1997.
- [12] S. He, Member, Q. H. Wu, Senior Member, and J. R. Saunders, "Group Search Optimizer: An Optimization Algorithm Inspired by Animal Searching Behavior," *IEEE Trans. on Evol. Comp.*, Vol. 13, No. 5, 2009.
-