

การเปรียบเทียบประสิทธิภาพการจำแนกประเภทผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน

อกนิษฐ์ ทองจิตร^{1*} พูลพงศ์ สุขสว่าง² และ จตุภัทร เมฆพ่าย³

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบการจำแนกประเภทผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน โดยใช้ตัวแบบการจำแนกประเภทข้อมูล 2 วิธี คือ โครงข่ายประสาทเทียมแบบป้อนย้อนกลับ (Back Propagation Neural Networks: BPNN) กับ โครงข่ายประสาทเทียมร่วมกับการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Back Propagation Neural Networks with Particle Swarm Optimization: BPNN-PSO) ชุดข้อมูลที่นำมาทดลองเป็นตัวอย่งผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวานอายุตั้งแต่ 35 ปีขึ้นไป ในพื้นที่เขตรับผิดชอบของสำนักงานสาธารณสุขจังหวัดนครพนม ปี พ.ศ. 2561 จำนวน 7,000 ระเบียบ วิเคราะห์ข้อมูลบนพื้นฐานวิธี 10-Fold Cross Validation ซึ่งปัจจัยที่ส่งผลต่อการมีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน จำนวน 10 ตัวแปร ได้แก่ อายุ เพศ ประวัติการสูบบุหรี่ ประวัติการดื่มเครื่องดื่มแอลกอฮอล์ ประวัติเบาหวานในญาติสายตรง ประวัติความดันโลหิตสูงในญาติสายตรง ดัชนีมวลกาย เส้นรอบเอว ความดันโลหิตช่วงหัวใจบีบตัว และความดันโลหิตช่วงหัวใจคลายตัว ผลการวิจัยปรากฏว่า ค่าความถูกต้องของตัวแบบจำแนกผู้ป่วยมีภาวะเสี่ยงต่อการเป็นโรคเบาหวานด้วยวิธี BPNN-PSO ให้ค่าความถูกต้องสูงกว่าวิธี BPNN ที่ค่าความถูกต้อง 90.57% และให้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error: MSE) ต่ำกว่าวิธี BPNN ที่ค่า MSE เท่ากับ 0.09

คำสำคัญ: โครงข่ายประสาทเทียม, การหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค, โรคเบาหวาน

¹ นักวิชาการศึกษา สำนักงานศึกษาธิการภาค 13

² ผู้ช่วยศาสตราจารย์ วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา มหาวิทยาลัยบูรพา

³ ผู้ช่วยศาสตราจารย์ ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยบูรพา

* ผู้นิพนธ์ประสานงาน โทร. +669 0959 3645 อีเมล: akanit2524@gmail.com



The Comparison of Classification Efficiency of Patients Who are Risk Diabetes

Akanit Thongjit^{1*} Poonpong Suksawang² and Jatupat Mekpanyup³

Abstract

This research aimed to compare efficiency model for classify patients who are risk diabetes. There are two data classification method used, Back Propagation Neural Networks (BPNN) and Back Propagation Neural Networks with Particle Swarm Optimization (BPNN-PSO). The data sets were provided by subjects who are risk to develop diabetes and are more than 35 years old, living in the area under the responsibility of Nakhon Phanom Provincial Health Office in year 2018. The total number of records was 7,000 cases. The data was analyzed by using technique on 10-Fold Cross Validation. Factors that affect the risk of diabetes included 10 variables: age, sex, smoke, alcohol, diabetes medical in family (DMFAMILY), hypertension in family (HTFAMILY), body mass index (BMI), waist, systolic blood pressure (SBP) and diastolic blood pressure (DBP). The results have shown that the BPNN-PSO model provided the accuracy in classification the diabetes higher than that of the BPNN model at 90.57% and the Mean Square Error lower than the BPNN models at MSE=0.09.

Keywords: Artificial Neural Networks, Particle Swarm Optimization, Diabetes

¹ Educator, Regional Education Office No.13

² Assistant Professor, College of Research Methodology and Cognitive Science, University of Burapha

³ Assistant Professor, Department of Mathematics, Faculty of Science, University of Burapha

* Corresponding Author, Tel. +669 0959 3645 e-mail: akanit2524@gmail.com

1. บทนำ

จากรายงานของสำนักงานนโยบายและยุทธศาสตร์ สำนักงานปลัดกระทรวงสาธารณสุข พบว่า สถานการณ์โรคเบาหวานในประเทศไทยมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง โดยอัตราเสียชีวิตจากโรคเบาหวานต่อประชากรแสนคนของประเทศไทยตั้งแต่ปี พ.ศ. 2556-2558 เท่ากับ 14.93 17.53 และ 17.83 ตามลำดับ [1] จากรายงานดังกล่าวแสดงให้เห็นว่า โรคเบาหวานเป็นหนึ่งในกลุ่มโรคที่เป็นปัญหาสำคัญด้านสาธารณสุข ซึ่งมีปัจจัยนำไปสู่โรคที่มีปัจจัยเสี่ยงร่วม ดังนั้น หากมีวิธีการที่สามารถจำแนกผู้ป่วยหรือผู้ที่มีความเสี่ยงต่อการเป็นโรคเบาหวานได้ จะทำให้ทราบถึงสภาวะการดำเนินโรคซึ่งจะนำไปสู่การป้องกันและการได้รับการรักษาที่เหมาะสม

จากการศึกษางานวิจัยที่ผ่านมาโครงข่ายประสาทเทียม (Artificial Neural Networks) เป็นวิธีการที่นิยมนำมาใช้ในการแก้ปัญหาต่าง ๆ อย่างแพร่หลาย เนื่องจากความสามารถในการเรียนรู้ อาทิเช่น ปัญหาด้านธุรกิจ ด้านวิทยาศาสตร์ หรือทางด้านการแพทย์ เป็นต้น ซึ่งการวินิจฉัยโรคหรือจำแนกข้อมูลทางการแพทย์ ส่วนใหญ่แล้วนิยมใช้โครงข่ายประสาทเทียม เนื่องจากมีความสามารถในการจำแนกข้อมูล ดังเช่นงานวิจัยของ Botaca et al. [2] ได้ศึกษาทำนายการป่วยเป็นมะเร็งต่อมลูกหมาก โดยใช้โครงข่ายประสาทเทียมแบบเพอร์เซปตรอนหลายชั้น (Multi-Layer Perceptron Neural Networks: MLPNN) RBF-MLP และ Recurrent NN (RNN) เปรียบเทียบกับการถดถอยแบบโลจิสติก ผลการศึกษาพบว่า ประสิทธิภาพความแม่นยำในการทำนายโดยใช้โครงข่ายประสาทเทียมดีกว่าการถดถอยแบบโลจิสติก ซึ่งสอดคล้องกับ Sumathi และ Santhakumaran [3] ได้ศึกษาโครงข่ายประสาทเทียมแบบเพอร์เซปตรอนหลายชั้น (MLPNN) สำหรับทำนายการเป็นโรคความดันโลหิตสูง ผลการศึกษาพบว่า MLPNN สามารถทำนายการเป็นโรคความดันโลหิตสูงได้อย่างมีประสิทธิภาพ จากข้อมูลข้างต้น พบว่าเทคนิคโครงข่ายประสาทเทียมมีความเหมาะสมกับการนำมาทำนายโรคได้อย่างแม่นยำ แต่อย่างไรก็ตาม โครงข่ายประสาทเทียมแบบแบบป้อนย้อนกลับยังมีข้อเสีย คือ มีการเรียนรู้ที่ช้าเนื่องจากการปรับค่าน้ำหนัก (Weight) และค่าความเอนเอียง (Bias) จากสาเหตุดังกล่าวได้มี


นักวิจัยเสนอแนวทางแก้ปัญหาโดยประยุกต์การหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization: PSO) ในการปรับค่าน้ำหนักที่เหมาะสมที่สุดให้กับโครงข่ายประสาทเทียมการปรับค่าน้ำหนักแบบเดิม ส่งผลให้ค่าผลลัพธ์ที่ได้จากแต่ละข่ายงานมีการลู่เข้าหาค่าคำตอบที่เหมาะสม และเพิ่มประสิทธิภาพความถูกต้องของการจำแนกประเภทข้อมูลด้วยโครงข่ายประสาทเทียมได้ [4]

ดังนั้นการวิจัยในครั้งนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบจำแนกประเภทผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน โดยใช้ตัวแบบการจำแนกประเภทข้อมูล 2 วิธี คือ โครงข่ายประสาทเทียมแบบป้อนย้อนกลับ (BPNN) กับ โครงข่ายประสาทเทียมร่วมกับการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (BPNN-PSO)

2. วรรณกรรมที่เกี่ยวข้อง

2.1 โครงข่ายประสาทเทียม

มีพื้นฐานมาจากการจำลองการทำงานของสมองมนุษย์ด้วยโปรแกรมคอมพิวเตอร์ จุดมุ่งหมายของโครงข่ายประสาทเทียมคือ ต้องการให้คอมพิวเตอร์มีความชาญฉลาดในการเรียนรู้เหมือนมนุษย์ ซึ่งสามารถฝึกฝนได้และสามารถนำความรู้ไปประยุกต์กับปัญหาการจำแนกข้อมูลได้ การเรียนรู้ของโครงข่ายประสาทเทียมทำได้ โดยการส่งข้อมูลเข้ามายังส่วนที่เรียกว่าเพอร์เซปตรอน (Perceptron) ซึ่งทำหน้าที่รับข้อมูลการเรียนรู้ของโครงข่ายประสาทเทียมจะผ่านการประมวลผล 2 ขั้นตอน คือ ขั้นตอนการหาผลรวมและขั้นตอนการแปลงด้วยฟังก์ชันกระตุ้น ดังรูปที่ 1 โดยโครงข่ายประสาทเทียมจะมีการป้อนข้อมูลเข้าและการกำหนดค่าน้ำหนักซึ่งแบ่งชั้น (Layer) การทำงานออกเป็น 3 ชั้น ดังนี้



รูปที่ 1 แบบจำลองการทำงานของโครงข่ายประสาทเทียม

2.1.1 ชั้นนำเข้า (Input Layer) ทำหน้าที่นำเข้าข้อมูลเข้าสู่โครงข่ายประสาทเทียม โดยข้อมูลนี้จะนำไปประมวลผลในแต่ละโหนด (Node) ของชั้นถัดไป

2.1.2 ชั้นซ่อน (Hidden Layer) ทำหน้าที่รับข้อมูลจากชั้นนำเข้าโดยการกำหนดค่าน้ำหนักของข้อมูลจากชั้นนำเข้า ก่อนรับข้อมูลเข้าสู่ชั้นซ่อน ชั้นซ่อนจะทำหน้าที่เพิ่มประสิทธิภาพในการจัดกลุ่มข้อมูลก่อนจะส่งต่อข้อมูลไปยังชั้นต่อไป

2.1.3 ชั้นส่งออก (Output Layer) ทำหน้าที่ส่งออกข้อมูลโดยผ่านการประมวลผลจากฟังก์ชันผลรวม (Summation Function: S) เป็นผลรวมของข้อมูลป้อนเข้าที่ถ่วงด้วยค่าน้ำหนัก (W) กับค่าความเอนเอียง (b) และฟังก์ชันการแปลง (Transfer Function) จนได้ผลลัพธ์ ดังสมการที่ (1)

$$S = \sum_{i=1}^n W_i X_i + b \quad (1)$$

ฟังก์ชันกระตุ้น (Activation Function) เป็นส่วนที่ทำหน้าที่แปลงผลรวมของข้อมูลป้อนเข้าให้เป็นผลลัพธ์ในชั้นส่งออก ซึ่งสามารถแบ่งได้ 2 ประเภท คือ ฟังก์ชันกระตุ้นแบบเชิงเส้น และฟังก์ชันกระตุ้นแบบไม่ใช่เชิงเส้น ลักษณะทั่วไปของโครงข่ายประสาทเทียม คือ โหนดจำลองมาจากรอยประสานประสาท (Synapse) ระหว่างใยประสาทนำเข้า (Dendrite) ของเซลล์ประสาทตัวหนึ่ง และแกนประสาทนำออก (Axon) ของเซลล์ประสาทอีกตัวหนึ่ง โดยมีฟังก์ชันการแปลงเป็นตัวกำหนดสัญญาณส่งออก โครงข่ายประสาทเทียมสามารถแบ่งได้ 3 แบบ ได้แก่

1) โครงข่ายประสาทแบบป้อนไปข้างหน้าชั้นเดียว (Single-Layer Feed Forward Neural Networks) ประกอบด้วยชั้นสัญญาณประสาทขาเข้าและชั้นสัญญาณประสาทขาออกเท่านั้น

2) โครงข่ายประสาทแบบป้อนไปข้างหน้าหลายชั้น (Multi-Layer Feed Forward Neural Networks) มีลักษณะเช่นเดียวกับโครงข่ายประสาทแบบป้อนไปข้างหน้าชั้นเดียว แต่จะมีชั้นซ่อนเพิ่มขึ้นโดยอยู่ระหว่างชั้นข้อมูลนำเข้าและชั้นส่งออก

3) โครงข่ายประสาทแบบป้อนย้อนกลับ (Back Propagation Neural Networks: BPNN) มีลักษณะเช่นเดียวกับโครงข่ายประสาทแบบป้อนไปข้างหน้า ซึ่งมี

ชั้นซ่อนอย่างน้อย 1 ชั้น และมีการวนซ้ำแบบป้อนย้อนกลับอย่างน้อยหนึ่งครั้ง

หากแบ่งโครงข่ายประสาทเทียมตามประเภทการเรียนรู้สามารถแบ่งได้ 2 ประเภท ได้แก่ การเรียนรู้แบบมีผู้สอน (Supervised Learning) และการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ปัจจุบันมีการพัฒนาโครงข่ายประสาทเทียมอย่างต่อเนื่องซึ่งมีบทบาทอย่างมากในด้านการจำแนกรูปแบบการทำนาย การหาความเหมาะสมและการจัดกลุ่มซึ่งมีงานวิจัยจำนวนมากที่นำเสนอวิธีการจัดประเภทข้อมูลโดยใช้โครงข่ายประสาทเทียม แต่ผลงานวิจัยมีสถาปัตยกรรมของโครงข่ายประสาทเทียมที่แตกต่างกัน ขั้นตอนการเรียนรู้ที่แตกต่างกัน สำหรับการวิจัยนี้ใช้โครงข่ายประสาทเทียมแบบป้อนย้อนกลับโดยมีขั้นตอนการดำเนินการ ดังนี้

- 1) กำหนดจำนวนโหนดชั้นนำเข้า ชั้นซ่อนและชั้นส่งออก อัตราการเรียนรู้ จำนวนรอบ ค่าความคลาดเคลื่อนที่ยอมรับได้และสุ่มค่าน้ำหนักให้โครงข่ายประสาท
- 2) คำนวณค่าผลลัพธ์ของโครงข่าย และปรับค่าน้ำหนักในกรณีที่ใช้เพอร์เซ็ปตรอนจำแนกข้อมูลผิดพลาด
- 3) ทำซ้ำชุดข้อมูลการเรียนรู้ (Learning Data Set) จนกระทั่งเพอร์เซ็ปตรอนจำแนกข้อมูลได้ผลลัพธ์ตามค่าเป้าหมายที่กำหนดไว้

เนื่องจาก BPNN ใช้เทคนิคการหาค่าเหมาะสมด้วยวิธี Gradient Descent เพื่อปรับค่าน้ำหนักของโครงข่ายจากความคลาดเคลื่อน (Error) ที่ได้จากการเรียนรู้ แต่การเรียนรู้ดังกล่าวทำให้ขั้นตอนการย้อนกลับมักประสบปัญหาการหาค่าที่เหมาะสม (Local Optima) ทำให้โครงข่ายประสาทเทียมไม่สามารถจำแนกประเภทข้อมูลได้อย่างมีประสิทธิภาพ [4]

2.2 การหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค

เป็นวิธีหาค่าตอบที่เหมาะสมจากการสังเกตการเคลื่อนไหวของสัตว์สังคม เช่น ผึ้งนก ผึ้งปลา เป็นต้น ซึ่งสัตว์สังคมเหล่านี้มีการส่งสัญญาณสื่อสารกันเพื่อให้ฝูงทราบตำแหน่งของอาหาร และสามารถเคลื่อนที่ไปยังแหล่งอาหาร (Sharing Information) นั้นได้อย่างถูกต้อง โดยจะเรียกสัตว์แต่ละตัวที่อยู่ในฝูงว่า อนุภาค (Particle) การเคลื่อนที่ประกอบด้วยตำแหน่ง (Position) และความเร็วในการเคลื่อนที่ (Velocity) ซึ่ง Jaroenrat [5] ได้กำหนดขั้นตอนการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคประกอบด้วย 7 ขั้นตอน ดังนี้

ขั้นตอนที่ 1 กำหนดอนุภาคเริ่มต้นและค่าความเร็วในการเคลื่อนที่ของแต่ละอนุภาคโดยการสุ่ม

ขั้นตอนที่ 2 คำนวณค่าความเหมาะสม (Fitness Value) ของแต่ละอนุภาคด้วยสมการฟังก์ชันเป้าหมาย (Fitness Function)

ขั้นตอนที่ 3 เก็บค่าความเหมาะสมที่ดีที่สุดซึ่งเป็นค่าความเหมาะสมที่สุดในรอบการทำงานปัจจุบัน (Pbest)

ขั้นตอนที่ 4 เก็บค่าน้ำหนักที่ให้ผลลัพธ์ดีที่สุด (Gbest) พิจารณาจากการวนรอบตั้งแต่รอบแรกถึงปัจจุบันซึ่งแตกต่างจาก Pbest ที่พิจารณาการเก็บค่าที่ดีที่สุดเฉพาะรอบปัจจุบัน

ขั้นตอนที่ 5 ปรับค่าความเร็วในการเคลื่อนที่ของแต่ละอนุภาค ดังสมการที่ (2)

$$V'_D = \{w \times V_D\} + \{n_1 \times \text{random}_1()\} \times [Pbest_D - X_D] + \{n_2 \times \text{random}_2()\} \times [Gbest_D - X_D] \quad (2)$$

เมื่อ V'_D แทน ค่าความเร็วที่คำนวณได้จากอนุภาครุ่นปัจจุบัน

V_D แทน ค่าความเร็วที่คำนวณได้จากอนุภาครุ่นก่อน

W แทน ค่าการถ่วงน้ำหนัก

n_1, n_2 แทน ค่าคงที่อัตราการเร่งในการค้นหา

ขั้นตอนที่ 6 ปรับค่าน้ำหนักของแต่ละอนุภาคโดยใช้ผลลัพธ์จากการคำนวณในสมการ (2) เพื่อปรับปรุงความเร็วที่คำนวณได้จากอนุภาครุ่นปัจจุบัน โดยเพิ่มข้อมูล ดังสมการที่ (3)

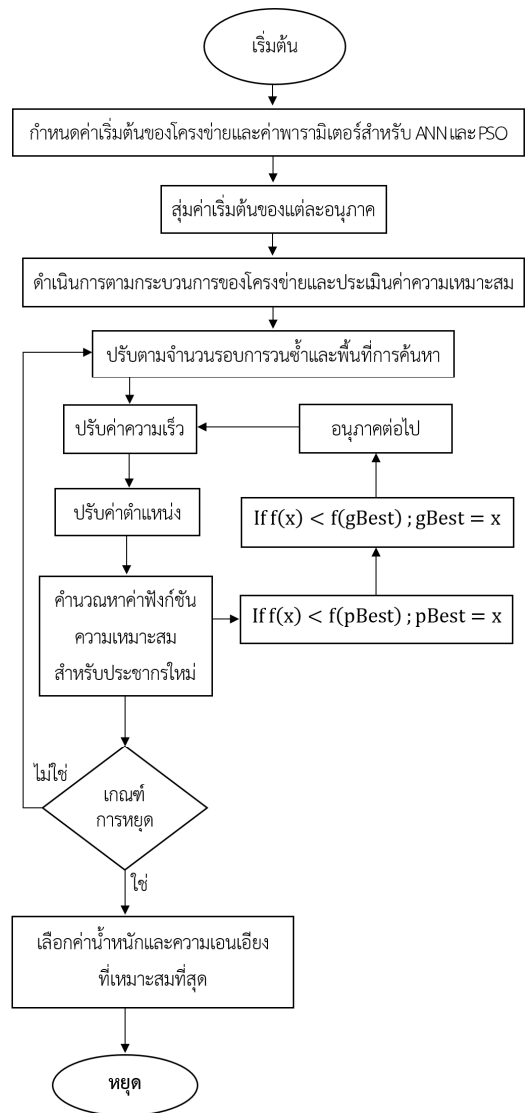
$$X'_D = V'_D + X_D \quad (3)$$

เมื่อ X'_D แทน ตำแหน่งที่คำนวณได้จากอนุภาครุ่นปัจจุบัน

X_D แทน ตำแหน่งที่คำนวณได้จากอนุภาครุ่นก่อน

ขั้นตอนที่ 7 ตรวจสอบเงื่อนไข 2 ลักษณะ ได้แก่ เงื่อนไขที่ 1 ผลลัพธ์ที่ได้มีค่าที่สูงหรือดีกว่าคำตอบที่ต้องการ และเงื่อนไขที่ 2 จำนวนรอบการทำงานถึงค่าที่กำหนดไว้หากพบว่าการทำงานมีทั้ง 2 เงื่อนไขให้หยุดการทำงาน แต่ถ้าไม่ครบทั้ง 2 เงื่อนไขให้กลับไปทำซ้ำตั้งแต่ขั้นตอนที่ 2

ซึ่งในการวิจัยครั้งนี้ได้นำวิธี PSO มาประยุกต์การหาค่าน้ำหนักที่เหมาะสมให้กับแต่ละโครงข่ายประสาทเทียมการวนปรับค่าแบบเดิมในขั้นตอนการปรับค่าน้ำหนักของตัวแบบ BPNN เพื่อให้โครงข่ายงานระบบประสาทมีการรู้เข้าหาคำตอบที่เหมาะสมสำหรับจำแนกผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวานโดยขั้นตอนวิธีการทำงานของโครงข่ายประสาทเทียมร่วมกับการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (BPNN-PSO) ดังรูปที่ 2



รูปที่ 2 ขั้นตอนวิธีโครงข่ายประสาทเทียมร่วมกับวิธีการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค [6]

3. วิธีดำเนินการวิจัย

บทความวิจัยนี้นำเสนอวิธีการจำแนกผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวานโดยเปรียบเทียบประสิทธิภาพการจำแนกผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวานโดยใช้วิธี BPNN และวิธี BPNN-PSO

3.1 การเตรียมข้อมูล

ข้อมูลที่ใช้ในการวิจัยได้จากฐานข้อมูลของสำนักงานสาธารณสุขจังหวัดนครพนม ปี พ.ศ. 2561 ซึ่งเป็นข้อมูลผู้ป่วยที่มาคัดกรองกลุ่มเสี่ยงการเป็นโรคเบาหวานที่มีอายุตั้งแต่ 35 ปี ขึ้นไป ในเขตพื้นที่รับผิดชอบของสำนักงานสาธารณสุขจังหวัดนครพนม โดยเลือกกลุ่มตัวอย่างแบบเจาะจงช่วงเดือนสิงหาคมถึงตุลาคม 2561 จำนวนทั้งหมด 7,000 ระเบียบ คัดเลือกจากระเบียนข้อมูลด้วยปัจจัยที่ส่งผลต่อการเป็นโรคเบาหวาน จำนวน 10 ตัวแปร ได้แก่ อายุ (AGE) เพศ (GENDER) ประวัติการสูบบุหรี่ (SMOKE) ประวัติการดื่มเครื่องดื่มแอลกอฮอล์ (ALCOHOL) ประวัติเบาหวานในญาติสายตรง (DMFAMILY) ประวัติความดันโลหิตสูงในญาติสายตรง (HTFAMILY) ดัชนีมวลกาย (BMI) เส้นรอบเอว (WAIST) ความดันโลหิตช่วงหัวใจบีบตัว (SBP) และความดันโลหิตช่วงหัวใจคลายตัว (DBP) [7], [8], [9] รายละเอียดข้อมูลสำหรับใช้ในการสร้างตัวแบบ ดังตารางที่ 1

ตารางที่ 1 รายละเอียดข้อมูล

ตัวแปร	รายละเอียด	รหัสข้อมูลป้อนเข้า
1. AGE	อายุผู้ป่วย	ตัวเลขอายุ
2. SEX	เพศของผู้ป่วย	1=ชาย 2=หญิง
3. SMOKE	ประวัติการสูบบุหรี่	1 = ไม่สูบ 2 = สูบนานๆครั้ง 3 = สูบเป็นครั้งคราว 4 = สูบเป็นประจำ 9 = ไม่ทราบ
4. ALCOHOL	ประวัติการดื่มเครื่องดื่มแอลกอฮอล์	1 = ไม่ดื่ม 2 = ดื่มนาน ๆ ครั้ง 3 = ดื่มเป็นครั้งคราว 4 = ดื่มเป็นประจำ 9 = ไม่ทราบ
5. DMFAMILY	ประวัติเบาหวานในญาติสายตรง	1 = มี 2 = ไม่มี 9 = ไม่ทราบ
6. HTFAMILY	ประวัติความดันโลหิตสูงในญาติสายตรง	1 = มี 2 = ไม่มี 9 = ไม่ทราบ

ตารางที่ 1 คุณลักษณะเบื้องต้นของปัจจัยที่ส่งผลต่อกลุ่มมีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน (ต่อ)

ตัวแปร	รายละเอียด	รหัสข้อมูลป้อนเข้า
7. BMI	ดัชนีมวลกาย	ตัวเลขดัชนีมวลกาย
8. WAIST	เส้นรอบเอว	ค่าตัวเลขเส้นรอบเอว
9. SBP	ความดันโลหิตขณะหัวใจบีบตัว	ค่าตัวเลขความดันโลหิตขณะหัวใจบีบตัว
10. DBP	ความดันโลหิตขณะหัวใจคลายตัว	ค่าความดันโลหิตขณะหัวใจคลายตัว

3.2 การสร้างตัวแบบจำแนกผู้ป่วยที่มีความเสี่ยงต่อการเป็นโรคเบาหวาน

ตัวแบบที่ใช้จำแนกผู้ป่วยมีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน มีทั้งหมด 2 ตัวแบบ ได้แก่ ตัวแบบ BPNN-PSO และ ตัวแบบ BPNN โดยใช้ฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent Function) และ Purelin ในการหาค่าผลลัพธ์ของแต่ละโหนด ใช้ฟังก์ชันค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error Function) เป็นฟังก์ชันคอส (Cost Function) สำหรับกระบวนการมินิไมเซชัน (Minimization) กำหนดค่า MSE เท่ากับ 10^{-12} จำนวนรอบสูงสุดในการปรับค่าน้ำหนักเท่ากับ 500 รอบ อัตราการเรียนรู้เท่ากับ 0.95 โมเมนตัม (Momentum) เท่ากับ 0.05 และเลือกใช้การหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคเป็นฟังก์ชันในการปรับค่าน้ำหนักและค่าความเอนเอียง แทนการวนโดยกำหนดค่าพารามิเตอร์สำหรับการเรียนรู้ PSO ดังนี้ ค่าคงที่อัตราการเร่งในการค้นหา n_1 และ n_2 เท่ากับ 2 ค่าน้ำหนักเริ่มต้น (W) เท่ากับ 1 และ จำนวนอนุภาคเท่ากับ 10

3.3 การตรวจสอบประสิทธิภาพการจำแนก

ในงานวิจัยนี้ใช้การแบ่งข้อมูลเพื่อนำมาตรวจสอบประสิทธิภาพของตัวแบบด้วยวิธี K-Fold Cross Validation โดยแบ่งข้อมูลเป็นชุดการฝึกเรียนรู้ (Learning Data Set) และชุดตรวจสอบ (Validation Data Set) 10 ส่วนเท่า ๆ กัน โดยใช้ 8 ส่วนเป็นชุดการเรียนรู้และอีก 2 ส่วนเป็นชุดการตรวจสอบ ซึ่งจะทำสลับกันจนครบทั้งหมด 10 รอบ โดยจะตรวจสอบประสิทธิภาพการจำแนกประเภทข้อมูลด้วยค่าความถูกต้องและค่าคลาดเคลื่อนกำลังสองเฉลี่ย ดังสมการที่ (4) และ (5)

$$\text{Accuracy} = \left(\frac{a + d}{a + b + c + d} \right) \times 100 \quad (4)$$

- โดย a คือ จำนวนผู้ป่วยที่เป็นโรคเบาหวานและได้รับการทำนายว่าเป็นโรคเบาหวาน
b คือ จำนวนผู้ป่วยที่เป็นโรคเบาหวานและได้รับการทำนายว่าไม่เป็นโรคเบาหวาน
c คือ จำนวนผู้ป่วยที่ไม่เป็นโรคเบาหวานและได้รับการทำนายว่าเป็นโรคเบาหวาน
d คือ จำนวนผู้ป่วยที่ไม่เป็นโรคเบาหวานและได้รับการทำนายว่าไม่เป็นโรคเบาหวาน


$$\text{MSE} = \sum \frac{(Y - Y')^2}{N} \quad (5)$$

- โดย Y คือ ค่าที่เกิดขึ้นจริง
Y' คือ ค่าที่เกิดจากการทำนาย

4. ผลการวิจัย

4.1 ผลการสร้างตัวแบบจำแนกผู้ป่วยที่มีความเสี่ยงต่อการเป็นโรคเบาหวาน

จากการออกแบบตัวแบบจำแนกประเภทข้อมูล และใช้โปรแกรม MATLAB วิเคราะห์โดยใช้วิธีโครงข่ายประสาทเทียมแบบป้อนย้อนกลับ (BPNN) และโครงข่ายประสาทเทียมร่วมกับการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (BPNN-PSO) เพื่อเปรียบเทียบประสิทธิภาพการจำแนกประเภทผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน ซึ่งมีการเชื่อมโยงไปข้างหน้าอย่างทั่วถึงโดยที่เป็นโครงสร้างข่ายงานระบบประสาทเทียมแบบป้อนย้อนกลับ มีฟังก์ชันกระตุ้นเชื่อมต่อการทำงานที่โหนดของชั้นนำเข้า ชั้นซ่อน และชั้นส่งออกเป็นฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent) และ Purelin ใช้ฟังก์ชันเป้าหมายด้วยค่าความคลาดเคลื่อนกำลังสองเฉลี่ย สำหรับตัวแบบการจำแนกประเภทข้อมูลโดยใช้โครงข่ายประสาทเทียม ดังรูปที่ 3



รูปที่ 3 ตัวแบบการจำแนกผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวานโดยใช้วิธี BPNN-PSO

การเรียนรู้ของโครงข่ายประสาทเทียมในการจำแนกประเภทผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวานสามารถอธิบายได้ ดังนี้

ส่วนที่ 1 ชั้นนำเข้า มีจำนวนโหนดทั้งหมด 10 โหนด ซึ่งจะมีค่าเท่ากับจำนวนตัวแปรปัจจัยที่ส่งผลการเป็นโรคเบาหวาน จำนวน 10 ตัวแปร ได้แก่

AGE	แทน	อายุ
GENDER	แทน	เพศ
SMOKE	แทน	ประวัติการสูบบุหรี่
ALCOHOL	แทน	ประวัติการดื่มเครื่องดื่มแอลกอฮอล์
DMFAMILY	แทน	ประวัติเบาหวานในญาติสายตรง
HTFAMILY	แทน	ประวัติความดันโลหิตสูงในญาติสายตรง
BMI	แทน	ดัชนีมวลกาย
WAIST	แทน	เส้นรอบเอว
SBP	แทน	ความดันโลหิตช่วงหัวใจบีบตัว
DBP	แทน	ความดันโลหิตช่วงหัวใจคลายตัว

ส่วนที่ 2 ชั้นซ่อน มีจำนวนโหนดทั้งหมด 24 โหนดที่ได้จากการทดลองหาจำนวนโหนดที่เหมาะสม โดยหาค่าเฉลี่ยความถูกต้องของจำนวนโหนด จากจำนวนโหนดเริ่มต้นที่ 10 โหนด เพิ่มขึ้นทีละโหนดจนถึง 100 โหนด จากการทดลองพบว่า จำนวนโหนดในชั้นซ่อนที่เริ่มให้ค่าความถูกต้องมากกว่าค่าเฉลี่ยของ BPNN ที่จำนวนโหนดที่ 12 โหนด และ BPNN-PSO ที่จำนวนโหนดที่ 24

โหนด ซึ่งแต่ละโหนดจะมีค่าน้ำหนักและค่าความเอนเอียงที่นำมาใช้ในการหาค่าผลลัพธ์ของชั้นส่งออกด้วยฟังก์ชันกระตุ้น

ส่วนที่ 3 ชั้นส่งออก มีจำนวนโหนดทั้งหมด 2 โหนด ซึ่งแสดงค่าผลลัพธ์ของเป้าหมายคือ ผลการวินิจฉัยผู้ป่วยมีผลลัพธ์จำนวนสองค่า ได้แก่

Y_1 แทน เป็นโรคเบาหวาน

Y_2 แทน ไม่เป็นโรคเบาหวาน

4.2 ผลการตรวจสอบประสิทธิภาพการจำแนก

ผู้ป่วยที่มีความเสี่ยงต่อการเป็นโรคเบาหวาน

จากการทดสอบประสิทธิภาพด้วยวิธี 10-fold cross-validation เพื่อเปรียบเทียบประสิทธิภาพการจำแนกประเภทผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน โดยใช้โครงข่ายประสาทเทียมแบบป้อนย้อนกลับ (BPNN) และโครงข่ายประสาทเทียมร่วมกับการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (BPNN-PSO) สามารถสรุปได้ว่า ตัวแบบโครงข่ายประสาทเทียมร่วมกับการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (BPNN-PSO) มีประสิทธิภาพในการจำแนกประเภทข้อมูลดีกว่าตัวแบบโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยมีค่าความถูกต้องในการจำแนกผู้ป่วยโรคเบาหวานสูงสุดเท่ากับ 90.57% และค่าความคลาดเคลื่อนกำลังสองเฉลี่ยเท่ากับ 0.09 แสดงดังตารางที่ 2

ตารางที่ 2 ประสิทธิภาพของตัวแบบ BPNN-PSO และตัวแบบ BPNN ในการจำแนกผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน

ฟังก์ชันกระตุ้น		Accuracy		MSE	
ชั้นซ่อน	ชั้นส่งออก	BPNN PSO	BPNN	BPNN PSO	BPNN
Hyperbolic Tangent	Purelin	90.57	88.50	0.09	0.10
Purelin	Hyperbolic Tangent	90.14	88.17	0.09	0.11

5. สรุปผลและอภิปรายผลการวิจัย

จากการเปรียบเทียบประสิทธิภาพการจำแนกผู้ป่วยที่มีภาวะเสี่ยงต่อการเป็นโรคเบาหวาน ดังตารางที่ 2 แสดงให้เห็นว่า ตัวแบบการจำแนกประเภทข้อมูลโดยใช้วิธี BPNN-PSO ด้วยฟังก์ชันกระตุ้น Hyperbolic Tangent ในชั้นซ่อน และ Purelin ในชั้นส่งออก มีค่าความถูกต้อง

สูงสุด เท่ากับ 90.57% และมีค่าความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุด เท่ากับ 0.09 และจากผลลัพธ์ที่ได้จากการจำแนกประเภทข้อมูลนี้ แสดงให้เห็นว่าการปรับค่าน้ำหนักและการเลือกฟังก์ชันกระตุ้นมีส่วนสำคัญในการเพิ่มประสิทธิภาพของตัวแบบการจำแนกประเภทข้อมูลด้วยโครงข่ายประสาทเทียมได้

6. ข้อเสนอแนะ

จากผลการวิจัยจะเห็นได้ว่าตัวแบบการจำแนกประเภทข้อมูลด้วยวิธีโครงข่ายประสาทเทียมที่นำการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคมาประยุกต์ ช่วยเพิ่มประสิทธิภาพค่าความถูกต้องในการวิเคราะห์จำแนกประเภทข้อมูล และช่วยลดค่าความคลาดเคลื่อนกำลังสองเฉลี่ย แสดงให้เห็นว่าตัวแบบนี้เหมาะกับการนำไปใช้งาน วิเคราะห์ข้อมูลทางด้านสุขภาพเบื้องต้นของผู้ป่วยแต่ละประเภทกลุ่มเสี่ยงได้

7. กิตติกรรมประกาศ

ขอขอบพระคุณนายแพทย์สำนักงานสาธารณสุขจังหวัดนครพนมที่อนุเคราะห์ข้อมูล และขอขอบคุณบุคลากรของสำนักงานสาธารณสุขจังหวัดนครพนมที่ให้ความสะดวกในการเข้าศึกษาข้อมูล

8. เอกสารอ้างอิง

- [1] Ministry of Public Health, "Department of Mental Health," [Online]. Available: <https://www.dmh.go.th/news-dmh/view.asp?id=25634>. [Accessed 25 August 2018].
- [2] C. Botoca, R. Barden, M. Botoca and F. Alexa, "Prostate Cancer Prognosis Evaluation Assisted by Neural Networks," *WSEAS Transactions on Computers*, vol. 2, no. 9, pp. 164 - 173, 2010.
- [3] B. Sumathi and A. Santhakumaran, "A Pre-Diagnosis of Hypertension Using Artificial Neural Network," *Journal of Computer Science and Technology*, vol. 11, no. 2, pp. 42 - 48, 2011.

- [4] N. Mohammadi and S. J. Mirabedini, "Comparison of Particle Swarm Optimization and Backpropagation Algorithms for Training Feedforward Neural Network," *Journal of Mathematics and Computer Science*, vol. 12, no. 1, pp. 113 - 123, 2014.
- [5] K. Jaroenrat, "Particle Swarm Optimization for Open Shortest Path First Network's Traffic Engineering," *Information Technology Journal*, vol. 11, no. 1, pp. 43 - 52, 2015.
- [6] M. Geethanjali, S. Mary Raja Slochanal, and R. Bhavani, "PSO trained ANN-based differential protection scheme for power transformers," *Neurocomputing*, vol. 71, no. 4 - 6, pp. 904 - 918, 2008.
- [7] N. Nai-aruna and R. Moungrmai, "Comparison of Classifiers for the Risk of Diabetes Prediction," *Procedia Computer Science*, vol. 69, no. 1, pp. 132 - 142, 2015.
- [8] D. R. Edla and R. Cheruku, "Diabetes- Finder: A Bat Optimized Classification System for Type-2 Diabetes," *Procedia Computer Science*, vol. 115, no. 1, pp. 235 - 242, 2017.
- [9] O. Karan, C. Bayraktar, H. Gümüşkaya and B. Karlık, "Diagnosing diabetes using neural networks on small mobile devices," *Expert Systems with Applications*, vol. 39, no. 1, pp. 54 - 60, 2012.