

# โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับร่วมกับอัตรา การเรียนรู้แบบปรับตัวเองสำหรับการจำแนกประเภท ข้อมูลที่ไม่สมดุลกัน

## BACKPROPAGATION NEURAL NETWORK WITH ADAPTIVE LEARNING RATE FOR CLASSIFICATION OF IMBALANCED DATA

Received: 7 May, 2021

Revised: 11 June, 2021

Accepted: 14 June, 2021

รุจิรา จุลภักดิ์\*

Rujira Jullapak\*

อาริต ธรรมโน\*\*

Arit Thammano\*\*

---

\*สาขาวิชาระบบสารสนเทศ คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคล  
ตะวันออก

\*Faculty of Business Administration and Information Technology, Rajamangala University of  
Technology Tawan-ok

\*Email: Rujira\_\_ju@rmutto.ac.th

\*\*คณะเทคโนโลยีสารสนเทศ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

\*\*Faculty of Information Technology, King Mongkut's Institute of Technology Ladkrabang

\*\*Email: arit@it.kmitl.ac.th

## บทคัดย่อ

ปัจจุบันมีงานวิจัยจำนวนมากที่ใช้การจำแนกประเภทข้อมูลด้วยวิธีการโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ เนื่องจากมีความสามารถที่จะเรียนรู้ข้อมูลที่ซับซ้อนได้เป็นอย่างดี แต่ปัญหาที่พบสำหรับวิธีการนี้คือ หากชุดข้อมูลที่นำมาใช้ในการเรียนรู้มีความไม่สมดุลกันของข้อมูล (Imbalanced data) โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับจะเรียนรู้คลาสที่มีปริมาณข้อมูลมาก มากกว่าคลาสที่มีปริมาณข้อมูลน้อย ส่งผลให้การจำแนกประเภทนั้นเอนเอียงไปยังคลาสที่มีปริมาณข้อมูลมากกว่า ผลของการจำแนกประเภทโดยรวมจึงไม่ถูกต้อง งานวิจัยนี้มีวัตถุประสงค์เพื่อแก้ปัญหาค่าความไม่สมดุลกันของปริมาณข้อมูลในแต่ละคลาส โดยได้นำเสนอวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับร่วมกับอัลตราการเรียนรู้แบบปรับตัวเอง (Backpropagation Neural Network with Adaptive Learning: BPNN-ALR) ซึ่งเป็นการปรับปรุงวิธีการเรียนรู้จากโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ในการทดสอบประสิทธิภาพของวิธีการที่นำเสนอ นั้น ผู้วิจัยได้ทดสอบกับชุดข้อมูลทางการแพทย์ที่มีความไม่สมดุลกันของข้อมูลจำนวน 2 ชุด ผลการทดสอบพบว่า สำหรับชุดข้อมูล Breast Tissue ความแม่นยำของวิธีการโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมถูกต้องร้อยละ 47.62 ส่วนวิธี BPNN-ALR ถูกต้องร้อยละ 77.14 สำหรับชุดข้อมูล Vertebral Column วิธีการโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมถูกต้องร้อยละ 48.39 ส่วนวิธี BPNN-ALR ถูกต้องร้อยละ 60.97 จากผลการทดลองที่ได้ทดสอบไปในเบื้องต้นพบว่าอัลกอริทึมที่พัฒนาขึ้นมา มีความแม่นยำในการจำแนกประเภทมากกว่าวิธีการของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิม

**คำสำคัญ:** การจำแนกประเภทข้อมูล โครงข่ายประสาทเทียม อัลตราการเรียนรู้แบบปรับตัวเอง อัลกอริทึมการเรียนรู้แบบแพร่ย้อนกลับ ข้อมูลที่ไม่สมดุลกัน

## Abstract

Currently there are several research studies solving classification with Backpropagation Neural Network (BPNN) due to its high capability to learn complex data. However, the drawback of this method is that if the learning data sets contain imbalanced data, the BPNN will learn more from the class that has more data than the class that has few data; as a result, it will always predict the class that has more data. Thus, the overall classification accuracy is low. This research aims to solve the imbalanced data problem by presenting the Backpropagation Neural Network with Adaptive Learning Rate (BPNN-ALR) which is improved over the

traditional BPNN. To test the efficiency of the proposed method, the researchers used two imbalanced medical data sets. The results showed that the accuracy of the traditional BPNN on Breast Tissue data set is 47.62%, while that of BPNN-ALR is 77.14%. On Vertebral Column data set, the accuracy of the traditional BPNN is 48.39%, while that of BPNN-ALR is 60.97%. In summary, the preliminary test results showed that the proposed algorithm is more accurate than the traditional BPNN.

**Keywords:** Classification, Neural Network, Adaptive Learning Rate, Backpropagation Learning Algorithm, Imbalanced Data

## บทนำ

อัลกอริทึมที่ใช้ในการจำแนกประเภทจะมีลักษณะการเรียนรู้แบบมีผู้สอน (Supervised learning) ในระหว่างการเรียนรู้ อัลกอริทึมจะทำการสร้างเกณฑ์เพื่อใช้ในการแบ่งข้อมูลออกเป็นกลุ่มๆ โดยมีเอาต์พุตเป้าหมายเป็นตัวกำหนดให้ว่าข้อมูลไหนควรจะอยู่ในกลุ่มใด ตัวอย่างของอัลกอริทึมที่นิยมใช้ในการจำแนกประเภทข้อมูล ได้แก่ Logistic Regression, Discriminant Analysis, อัลกอริทึมการจำแนกประเภทแบบเคมีน และโครงข่ายประสาทเทียม

Feng, Xu, Mannor, and Ya. (2014) นำเสนออัลกอริทึม Robust Logistic Regression (RoLR) เพื่อใช้ในการจำแนกประเภทแบบไบนารี โดยอัลกอริทึม RoLR ใช้ขั้นตอนของโปรแกรมเชิงเส้นในการประมาณค่าพารามิเตอร์ ผลการทดลองแสดงว่า RoLR สามารถจำแนกประเภทได้ดีกว่า Logistic Regression ในทุกข้อมูลที่ทำการทดสอบ

Jia, Deng, Xin, Liu, and Pedrycz (2019) นำเสนออัลกอริทึมในการจำแนกประเภทที่อาศัยการทำงานร่วมกันของ Linear Discriminant Analysis (LDA) และ Axiomatic Fuzzy Sets (AFS) ผลการวิจัยสรุปว่าอัลกอริทึมที่นำเสนอนอกจากจะมีความแม่นยำในการจำแนกประเภทสูงกว่า Logistic Regression, C4.5, Support Vector Machine, และ K-Nearest Neighbors แล้ว อัลกอริทึมที่นำเสนอยังมีความง่ายในการที่ผู้ใช้งานจะเข้าใจในตัวจำแนก (Interpretability) อีกด้วย

อาริกา ธรรมโน, มุทิตา หวังคิด, และอาริต ธรรมโน. (2563) ทำการพยากรณ์โรคมะเร็งเต้านมด้วยอัลกอริทึมการจำแนกประเภทแบบเคมีนร่วมกับค่าถ่วงน้ำหนักแบบปรับตัวเอง โดยอัลกอริทึมที่ใช้นี้พัฒนามาจากอัลกอริทึมการแบ่งกลุ่มแบบเคมีนให้มีความสามารถในการจำแนกประเภท และปรับเปลี่ยนค่าถ่วงน้ำหนักของคุณลักษณะเด่นในสมการหาระยะห่างระหว่างข้อมูลกับจุดศูนย์กลางของแต่ละประเภทให้เหมาะสมได้ด้วยตัวเองในระหว่างการเรียนรู้ชุดข้อมูล ผลการทดสอบพบว่าอัลกอริทึมการจำแนกประเภทแบบเคมีนร่วมกับค่าถ่วงน้ำหนักแบบปรับตัวเองมีความถูกต้องในการพยากรณ์ที่สูงขึ้น

Dreiseitl and Ohno-Machado (2002) ได้ทำการเปรียบเทียบประสิทธิภาพในจำแนกประเภทระหว่างวิธี Logistic Regression กับโครงข่ายประสาทเทียม และ Blackard and Dean (1999) ทำการเปรียบเทียบประสิทธิภาพในจำแนกประเภทระหว่างวิธี Discriminant Analysis กับโครงข่ายประสาทเทียม โดยทั้ง 2 งานวิจัยสรุปว่าโครงข่ายประสาทเทียมมีความแม่นยำในการจำแนกประเภทสูงกว่าทั้ง Logistic Regression และ Discriminant Analysis

โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back propagation Neural Network: BPNN) เป็นวิธีการซึ่งได้รับความนิยมเป็นอย่างมากในปัจจุบันในการจำแนกประเภทข้อมูล เนื่องจากมีความสามารถในการหาความสัมพันธ์ที่ซับซ้อนได้ดี สามารถแก้ปัญหาในลักษณะที่เป็นเชิงเส้น (Linear) และไม่เป็นเชิงเส้น (Nonlinear) ได้ จากการศึกษางานวิจัยที่เกี่ยวข้องพบว่ามีการนำเอาโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับมาใช้ในการจำแนกประเภทอยู่เป็นจำนวนมาก เช่น การคัดกรองผู้ที่มีความเสี่ยงต่อภาวะซึมเศร้า การพยากรณ์โรคมะเร็งเต้านม การจำแนกประเภทขยะ การจำแนกชนิดป่า เป็นต้น ทั้งนี้วิธีการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับจะสามารถทำนายผลได้อย่างมีประสิทธิภาพก็ต่อเมื่อ ชุดข้อมูลที่ใช้ในการสอนโครงข่ายประสาทเทียมมีปริมาณข้อมูลในแต่ละคลาสใกล้เคียงกัน แต่ในความเป็นจริงแล้วนั้น ข้อมูลของคลาสต่าง ๆ ในชุดข้อมูลจะปะปนกัน เราไม่สามารถกำหนดจำนวนของข้อมูลในแต่ละคลาสให้มีขนาดใกล้เคียงกันได้ ทำให้ข้อมูลของคลาสที่มีจำนวนน้อยจะถูกทำนายไปเป็นกลุ่มของคลาสที่มีปริมาณข้อมูลมาก ซึ่งทำให้ผลของการทำนายนั้นผิดพลาด

จากการศึกษาวิจัยที่เกี่ยวข้องกับการจำแนกประเภทข้อมูลที่ไม่สมดุลกันพบว่า ปัญหาข้อมูลไม่สมดุลกันยังคงเป็นปัญหาที่สำคัญและยังได้รับความสนใจในปัจจุบันเป็นอย่างมาก โดยงานวิจัยส่วนใหญ่จะเน้นไปที่การแก้ไขปัญหาในขั้นตอนของการเตรียมชุดข้อมูลก่อนนำไปเรียนรู้ ตัวอย่างเช่น

นพมาศ อัครจันทโชติ และดิเรก พินิตสุภากมล (2562) ได้ศึกษาวิธีการแก้ปัญหาข้อมูลไม่สมดุลกัน โดยทำการทดลองเปรียบเทียบประสิทธิภาพระหว่างวิธีสุ่มเพิ่ม (Random Oversampling: ROS) และวิธีสังเคราะห์ข้อมูลเพิ่ม (Synthetic Minority Oversampling Technique: SMOTE) ซึ่งทั้งสองวิธีใช้การสุ่มตัวอย่างซ้ำเป็นพื้นฐานเหมือนกัน จากผลการวิจัยพบว่าวิธี SMOTE มีประสิทธิภาพที่ดีกว่าไม่ว่าจะใช้ร่วมกับเทคนิคในการจำแนกประเภทแบบการถดถอยโลจิสติกส์หรือต้นไม้ตัดสินใจก็ตาม ในส่วนของวิธี ROS ซึ่งมีประสิทธิภาพในการจำแนกประเภทที่ต่ำกว่านั้น ผู้วิจัยได้อธิบายว่าการเพิ่มข้อมูลของวิธี ROS นั้นเป็นการนำข้อมูลเดิมเข้ามาเพิ่มซ้ำเข้าไปเพื่อเพิ่มจำนวนข้อมูลของคลาสที่มีปริมาณข้อมูลน้อย จึงไม่ได้ทำให้ได้สารสนเทศของข้อมูลเพิ่มขึ้น และยังก่อให้เกิดปัญหา Overfitting อีกด้วย

วิชญ์วิสิฐ เกษรสิทธิ์, จิราวัลย์ จิตรถเวช, และวิชิต หล่อจ๊ะระซุนท์กุล. (2563) ได้เปรียบเทียบวิธีการแก้ปัญหาค่าความไม่สมดุลกันของข้อมูลสำหรับการจำแนกประเภทของการกลับมารักษาซ้ำในโรงพยาบาลของผู้ป่วยโรคเบาหวาน จำนวน 4 วิธี คือวิธีสุ่มเพิ่ม วิธี

สุ่มลด วิธีผสมผสาน และวิธีสังเคราะห์ข้อมูลเพิ่ม (SMOTE) โดยในงานวิจัยนี้เทคนิคที่ใช้ในการจำแนกประเภท คือ เทคนิคการถดถอยลอจิสติกและต้นไม้การตัดสินใจ จากการเปรียบเทียบประสิทธิภาพพบว่าวิธีการแก้ปัญหาความไม่สมดุลด้วยวิธีสังเคราะห์ข้อมูลเพิ่มเมื่อนำมาใช้ร่วมกับเทคนิคการจำแนกประเภทด้วยต้นไม้การตัดสินใจมีความสามารถจำแนกประเภทของการกลับมารักษารักษาในโรงพยาบาลของผู้ป่วยโรคเบาหวานได้ดีที่สุด

Zhang, Huang, Wu, and Li (2020) นำเสนอเทคนิคที่เรียกว่า SGM เพื่อใช้ในการจัดการกับปัญหาข้อมูลไม่สมดุลกัน โดย SGM เป็นเทคนิคที่เกิดจากการผสมผสานกันของ SMOTE และ Gaussian Mixture Model (GMM) โดย SMOTE ทำการสังเคราะห์ข้อมูลเพิ่มให้กับคลาสที่มีปริมาณข้อมูลน้อย และ GMM ทำการจัดกลุ่มข้อมูลในคลาสที่มีปริมาณข้อมูลมากเพื่อเป็นการลดปริมาณข้อมูลลง คณะผู้วิจัยได้นำเอา SGM ไปใช้งานร่วมกับ Convolutional Neural Network (CNN) เพื่อใช้เป็นระบบในการตรวจจับการบุกรุกบนเครือข่ายคอมพิวเตอร์ โดยเรียกระบบนี้ว่า SGM-CNN การทดสอบประสิทธิภาพของ SGM-CNN ทำกับข้อมูล 2 ชุดคือ UNSW-NB15 และ CICIDS2017 ผลการทดลองสรุปได้ว่า SGM-CNN มีอัตราตรวจจับ 99.74% และ 96.54% สำหรับข้อมูล UNSW-NB15 และมีอัตราการตรวจจับที่ 99.85% สำหรับข้อมูล CICIDS2017

ถึงแม้ว่างานวิจัยส่วนใหญ่จะเน้นไปที่การแก้ไขปัญหาในขั้นตอนของการเตรียมชุดข้อมูลก่อนนำไปเรียนรู้ แต่ก็จะมีข้อเสียเกี่ยวกับการที่ต้องเสียเวลาในการเตรียมชุดข้อมูลและอาจทำให้เกิดความลำบากต่อผู้ใช้งานทั่วไปที่ไม่มีความรู้ด้านคอมพิวเตอร์ ด้วยเหตุดังกล่าวผู้วิจัยจึงคิดค้นวิธีการเพื่อแก้ไขปัญหาความไม่สมดุลกันของข้อมูล โดยทำการปรับปรุงอัลกอริทึมการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับให้มีความสามารถในการเรียนรู้ข้อมูลของแต่ละคลาสด้วยอัตราการเรียนรู้ที่แตกต่างกัน นอกจากนั้นแล้วอัตราการเรียนรู้ของแต่ละคลาสยังสามารถที่จะปรับตัวเองให้เหมาะสมกับประสิทธิภาพในการจำแนกข้อมูลในแต่ละช่วงเวลาของการเรียนรู้ นอกจากอัลกอริทึมที่นำเสนอจะช่วยให้ผู้ใช้งานทั่วไปสามารถใช้งานได้สะดวกมากยิ่งขึ้นแล้ว อัลกอริทึมที่นำเสนอยังมีประสิทธิภาพในการจำแนกประเภทข้อมูลที่ไม่สมดุลกันดีกว่าโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมอีกด้วย

## ทฤษฎีที่เกี่ยวข้อง

### 1.1 การเรียนรู้ของเครื่องจักร (Machine learning)

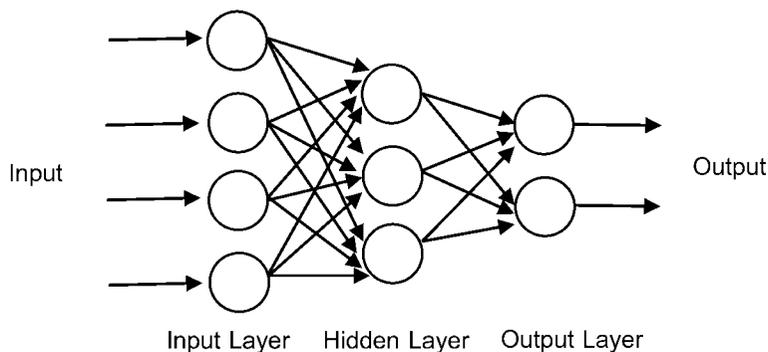
การเรียนรู้ของเครื่องจักรเป็นศาสตร์หนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence: AI) ที่ศึกษาและพัฒนาอัลกอริทึมเพื่อทำให้เครื่องคอมพิวเตอร์สามารถที่จะเรียนรู้และสร้างแบบจำลองทางคณิตศาสตร์ขึ้นมาจากชุดข้อมูลตัวอย่าง ซึ่งเมื่อมีแบบจำลองแล้วเครื่องจะสามารถพยากรณ์หรือตัดสินใจได้อย่างแม่นยำ โดยวิธีการในการเรียนรู้แบ่งได้เป็น 2 ลักษณะคือ 1) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการเรียนรู้ที่เครื่องจะทำการค้นหารูปแบบหรือสารสนเทศจากข้อมูลที่ป้อนเข้าไปให้ด้วยตัวเอง โดยที่เราไม่จำเป็นต้องระบุผลลัพธ์เป้าหมายของข้อมูลเหล่านั้นให้กับเครื่อง 2) การเรียนรู้แบบมีผู้สอน

(Supervised Learning) เป็นลักษณะของการเรียนรู้ที่จะต้องมีการป้อนข้อมูลอินพุตและผลลัพธ์เป้าหมายเข้าสู่เครื่องคอมพิวเตอร์ เพื่อให้เครื่องใช้ในการสร้างแบบจำลองความสัมพันธ์ระหว่างข้อมูลอินพุตและผลลัพธ์เป้าหมายที่เกี่ยวข้อง ดังนั้นการเรียนรู้แบบมีผู้สอนจะมีการแบ่งชุดข้อมูลออกเป็น 2 ชุดคือ ชุดข้อมูลเรียนรู้ (Training set) เพื่อใช้ในการสร้างแบบจำลอง และชุดข้อมูลทดสอบ (Testing set) เพื่อใช้ในการทดสอบประสิทธิภาพของแบบจำลองที่สร้างขึ้นมา

การจำแนกประเภท (Classification) เป็นส่วนหนึ่งของการเรียนรู้แบบมีผู้สอนซึ่งเครื่องจะทำการสร้างแบบจำลองความสัมพันธ์ของคุณลักษณะของข้อมูลและคลาสเป้าหมายของข้อมูลจากชุดข้อมูลเรียนรู้ที่ได้รับ เมื่อสร้างแบบจำลองเรียบร้อยแล้วเครื่องจะสามารถทำนายคลาสของข้อมูลที่ไม่เคยเห็นมาก่อนได้อย่างถูกต้อง ตัวอย่างของอัลกอริทึมในการจำแนกประเภทที่นิยมใช้ในปัจจุบันได้แก่ โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Neural Network) นาอิวเบย์ (Naive Bayes) การวิเคราะห์การถดถอยโลจิสติกส์ (Logistic Regression Analysis) การเรียนรู้เชิงลึก (Deep Learning) ต้นไม้ตัดสินใจ (Decision Tree) แรนดอมฟอเรส (Random Forest) เคเนียเรสเนเบอร์ (K-Nearest Neighbor) เอ็กซ์ทรีมกราดิเอนท์บูตติ้ง (Extreme Gradient Boosting)

## 1.2 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Neural Network)

สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบหลายชั้นจะมีลักษณะโดยทั่วไปดังนี้คือ มีชั้นอินพุต (Input Layer) จำนวนหนึ่งชั้น ชั้นเอาต์พุต (Output Layer) จำนวนหนึ่งชั้น และมีชั้นซ่อน (Hidden Layer) อย่างน้อยหนึ่งชั้น ดังแสดงในภาพที่ 1



ภาพที่ 1 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบหลายชั้น

อัลกอริทึมที่นิยมใช้มากที่สุดในการเรียนรู้ของโครงข่ายประสาทเทียมแบบหลายชั้นคือ อัลกอริทึมการเรียนรู้แบบแพร่ย้อนกลับ (Backpropagation Learning Algorithm) ซึ่งโดยทั่วไปแล้วเรามักจะเรียกโครงข่ายประสาทเทียมแบบหลายชั้นที่มีการใช้อัลกอริทึมการเรียนรู้

แบบแพร่ย้อนกลับว่าโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation Neural Network) ขั้นตอนการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับเป็นดังนี้

- ขั้นตอนที่ 1 กำหนดอัตราการเรียนรู้ (Learning rate) ให้มีค่าอยู่ระหว่าง 0 ถึง 1
- ขั้นตอนที่ 2 กำหนดจำนวนโหนดในชั้นอินพุต ชั้นซ่อน และชั้นเอาต์พุต รวมทั้งจำนวนรอบที่จะทำการเรียนรู้ โดยจำนวนโหนดในชั้นอินพุตจะแทนด้วยตัวแปร  $n$  จำนวนโหนดในชั้นซ่อนจะแทนด้วยตัวแปร  $m$  และจำนวนโหนดในชั้นเอาต์พุตจะแทนด้วยตัวแปร  $p$
- ขั้นตอนที่ 3 สุ่มค่าน้ำหนักเริ่มต้นให้กับเส้นเชื่อมทุกเส้นที่เชื่อมระหว่างโหนดในชั้นที่อยู่ติดกัน โดยค่าน้ำหนักของเส้นเชื่อมที่เชื่อมระหว่างโหนดในชั้นอินพุตกับโหนดในชั้นซ่อนจะแทนด้วย  $W_{ji}$  และค่าน้ำหนักของเส้นเชื่อมที่เชื่อมระหว่างโหนดในชั้นซ่อนกับโหนดในชั้นเอาต์พุตจะแทนด้วย  $W_{kj}$
- ขั้นตอนที่ 4 คำนวณหาค่าเอาต์พุตของโหนดในชั้นซ่อนแต่ละโหนด ( $H_j$ ) โดยใช้สมการที่ (1) และ (2)

$$net_j = \sum_{i=1}^n W_{ji} X_i \quad (1)$$

$$H_j = \frac{1}{1 + e^{-net_j}} \quad (2)$$

เมื่อ  $X_i$  คือ ค่าจากโหนดที่  $i$  ในชั้นอินพุต

$W_{ji}$  คือ ค่าน้ำหนักของเส้นเชื่อมที่เชื่อมระหว่างโหนด  $i$  ในชั้นอินพุตกับโหนด  $j$  ในชั้นซ่อน

ขั้นตอนที่ 5 คำนวณหาค่าเอาต์พุตของโหนดในชั้นเอาต์พุตแต่ละโหนด ( $O_k$ ) โดยใช้สมการที่ (3) และ (4)

$$net_k = \sum_{j=1}^m W_{kj} H_j \quad (3)$$

$$O_k = \frac{1}{1 + e^{-net_k}} \quad (4)$$

เมื่อ  $W_{kj}$  คือ ค่าน้ำหนักของเส้นเชื่อมที่เชื่อมระหว่างโหนด  $j$  ในชั้นซ่อนกับโหนด  $k$  ในชั้นเอาต์พุต

ขั้นตอนที่ 6 ทำการเปรียบเทียบค่าเอาต์พุตที่ได้จากโครงข่าย ( $O_k$ ) กับค่าเอาต์พุตเป้าหมาย ( $y_k$ ) เพื่อคำนวณหาความผิดพลาดโดยใช้สมการที่ (5)

$$E = \frac{1}{2} \sum_{k=1}^p (y_k - O_k)^2 \quad (5)$$

ขั้นตอนที่ 7 ใช้ค่าความผิดพลาดที่ได้ในขั้นตอนที่ 6 เพื่อทำการปรับค่าน้ำหนักของเส้นเชื่อมทุกเส้นที่เชื่อมโหนดในชั้นซ่อนกับโหนดในชั้นเอาต์พุต ( $W_{kj}$ ) โดยใช้สมการที่ (6) และ (7) ส่วนการปรับค่าน้ำหนักของเส้นเชื่อมที่เชื่อมโหนดในชั้นอินพุตกับโหนดในชั้นซ่อน ( $W_{ji}$ ) จะใช้สมการที่ (8) และ (9)

$$\frac{\partial E}{\partial W_{kj}} = \left( \frac{\partial E}{\partial O_k} \right) \left( \frac{\partial O_k}{\partial net_k} \right) \left( \frac{\partial net_k}{\partial W_{kj}} \right) = -(y_k - O_k) O_k (1 - O_k) H_j \quad (6)$$

$$W_{kj}^{new} = W_{kj}^{old} - \eta \frac{\partial E}{\partial W_{kj}} \quad (7)$$

$$\frac{\partial E}{\partial W_{ji}} = \left( \frac{\partial E}{\partial O_k} \right) \left( \frac{\partial O_k}{\partial net_k} \right) \left( \frac{\partial net_k}{\partial H_j} \right) \left( \frac{\partial H_j}{\partial net_j} \right) \left( \frac{\partial net_j}{\partial W_{ji}} \right) = - \sum_{k=1}^p (y_k - O_k) O_k (1 - O_k) W_{kj} H_j (1 - H_j) X_i \quad (8)$$

$$W_{ji}^{new} = W_{ji}^{old} - \eta \frac{\partial E}{\partial W_{ji}} \quad (9)$$

ขั้นตอนที่ 8 ทำซ้ำขั้นตอนที่ 4 ถึง 7 จนครบตามจำนวนรอบที่ต้องการ

### 1.3 ข้อมูลที่ไม่สมดุลกัน (Imbalanced Data)

ข้อมูลที่ไม่สมดุลกัน หมายถึง กรณีที่ปริมาณข้อมูลของแต่ละคลาสในชุดข้อมูลมีความแตกต่างกันมาก เมื่อนำไปให้เครื่องจักรเรียนรู้ เครื่องจักรจะจดจำสิ่งที่ได้เรียนรู้ในปริมาณที่มากได้มากกว่า ทำให้เกิดการเรียนรู้ที่ไม่สมดุล ส่งผลกระทบให้การจำแนกคลาสที่มีปริมาณข้อมูลน้อยมีความแม่นยำในการจำแนกน้อย นั่นคือเมื่อนำข้อมูลที่ไม่เคยเห็นมาก่อนมาทดสอบผลการจำแนกข้อมูลจะเอนเอียงไปทางคลาสที่มีข้อมูลปริมาณมาก ทำให้ประสิทธิภาพในการจำแนกโดยรวมนั้นลดลง

### 1.4 วิธีการแก้ปัญหาข้อมูลที่ไม่สมดุลกัน

1) **วิธีสุ่มลด (Random Undersampling)** เป็นเทคนิคในการลดจำนวนข้อมูลของคลาสที่มีปริมาณข้อมูลมากให้มีจำนวนใกล้เคียงหรือเท่ากับคลาสที่มีปริมาณข้อมูลน้อย โดยจะทำการสุ่มเลือกข้อมูลจากคลาสที่มีปริมาณข้อมูลมากขึ้นมาจำนวนใกล้เคียงหรือเท่ากับคลาสที่มีปริมาณข้อมูลน้อย แต่วิธีการนี้มีข้อเสียคือในการลดข้อมูลของคลาสที่มีปริมาณข้อมูลมากอาจทำให้ข้อมูลที่สำคัญสูญหายจากชุดข้อมูลการเรียนรู้ได้

2) **วิธีสุ่มเพิ่ม (Random Oversampling)** เป็นการสุ่มข้อมูลจากคลาสที่มีปริมาณข้อมูลน้อยเพื่อทำให้มีจำนวนเพิ่มมากขึ้นใกล้เคียงหรือเท่ากับจำนวนของคลาสที่มีปริมาณข้อมูลมาก

### 3) วิธีสังเคราะห์ข้อมูลเพิ่ม (Synthetic Minority Oversampling

**Technique: SMOTE)** เป็นเทคนิคการสุ่ม เพิ่ม โดยใช้ข้อมูลเดิมแล้วทำการสังเคราะห์ข้อมูลขึ้นมาใหม่จากข้อมูลเดิมที่มีอยู่ เริ่มต้นจากการสุ่มค่าข้อมูลที่อยู่ในกลุ่มที่มีปริมาณข้อมูลน้อยขึ้นมา 1 ค่า หลังจากนั้นพิจารณาค่าข้อมูลใกล้เคียงอีกจำนวน  $K$  ค่า ( $K$ -nearest neighbor) แล้วคำนวณหาระยะทาง (Euclidean distance) ระหว่างค่าที่สุ่มกับค่าข้อมูลใกล้เคียงแต่ละค่า เพื่อหาค่าระยะทางที่น้อยที่สุดระหว่างค่าที่สุ่มกับค่าข้อมูลใกล้เคียง จากนั้นจึงสร้างข้อมูลเทียมขึ้นมาให้อยู่ระหว่างค่าข้อมูลที่สุ่มกับค่าข้อมูลใกล้เคียงตัวที่ให้ค่าระยะทางที่น้อยที่สุด

#### วิธีการวิจัย

จากการศึกษางานวิจัยที่เกี่ยวข้องพบว่า งานวิจัยโดยส่วนใหญ่เน้นการแก้ปัญหาความไม่สมดุลกันของข้อมูลก่อนที่จะนำข้อมูลไปใช้ในการเรียนรู้ (Training) ซึ่งอาจทำให้เสียเวลาและเพิ่มความซับซ้อนให้กับผู้ใช้งานมากยิ่งขึ้น ดังนั้นในงานวิจัยนี้ผู้วิจัยจึงนำเสนอวิธีการแก้ปัญหาความไม่สมดุลกันของข้อมูล โดยแก้ไขในส่วนของขั้นตอนการเรียนรู้ให้อัลกอริทึมมีความสามารถในการปรับอัตราการการเรียนรู้ให้เหมาะสมกับประสิทธิภาพในการจำแนกข้อมูลในแต่ละช่วงเวลาของการเรียนรู้ได้ด้วยตัวเอง ผู้วิจัยได้เรียกอัลกอริทึมที่ปรับปรุงใหม่นี้ว่า โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับร่วมกับอัตราการเรียนรู้แบบปรับตัวเอง (Backpropagation Neural Network with Adaptive Learning Rate: BPNN-ALR) โดยจะทำการทดสอบอัลกอริทึมที่ปรับปรุงใหม่นี้เปรียบเทียบกับวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมการทำงานของ BPNN-ALR นั้นเป็นการพัฒนาแก้ไขวิธีการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Backpropagation Neural Network) ให้มีประสิทธิภาพสูงขึ้น BPNN-ALR มีการสร้างตัวแปรเพิ่มขึ้นมา 1 ตัวแปรคือ  $z_c(t)$  โดยที่  $z_c(t)$  เป็นตัวแปรที่ใช้ในการปรับค่าอัตราการเรียนรู้ของแต่ละคลาส  $c$  ให้เหมาะสมกับค่าความแม่นยำในการทำนายข้อมูลของคลาสนั้นในช่วงเวลา  $t$  กล่าวคือถ้าความแม่นยำในการทำนายข้อมูลของคลาส  $c$  มีค่าต่ำ โครงข่ายจะทำการเพิ่มค่าของตัวแปร  $z_c(t)$  ขึ้น เพื่อให้ข้อมูลของคลาส  $c$  ถูกเรียนรู้ด้วยอัตราที่สูงขึ้นในรอบการเรียนรู้ถัดไป

ขั้นตอนในการทำงานของ BPNN-ALR จะคล้ายคลึงกับขั้นตอนการทำงานของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับที่ได้อธิบายไว้ในหัวข้อ 2.2 เป็นส่วนใหญ่ แต่จะมีความแตกต่างในส่วนของขั้นตอนที่ 1 ขั้นตอนที่ 6 และขั้นตอนที่ 7 ดังนี้

ขั้นตอนที่ 1 กำหนดอัตราการเรียนรู้ ( $\eta$ ) ให้มีค่าอยู่ระหว่าง 0 ถึง 1 และกำหนดค่าเริ่มต้นให้กับ  $z_c(t)$  ดังนี้

$$z_c(0) = \frac{N_{\max}}{N_c} \quad (10)$$

เมื่อ  $N_{\max}$  คือ จำนวนข้อมูลในคลาสนที่มีข้อมูลมากที่สุด  
 $N_c$  คือ จำนวนข้อมูลในคลาส  $c$

ขั้นตอนที่ 6 ทำการเปรียบเทียบค่าเอาต์พุตที่ได้จากโครงข่าย ( $O_k$ ) กับค่าเอาต์พุตเป้าหมาย ( $y_k$ ) เพื่อคำนวณหาความผิดพลาดโดยใช้สมการที่ (5) และตรวจสอบผลการทำนายข้อมูลในแต่ละคลาสว่ามีความถูกต้องจำนวนเท่าใด ( $r_c$ ) หลังจากนั้นปรับค่าของ  $z_c(t)$  โดยใช้สมการที่ (11)

$$z_c(t+1) = \begin{cases} z_c(t) + \varepsilon, & \text{if } \frac{r_c}{N_c} < 0.5 \\ z_c(t), & \text{otherwise} \end{cases} \quad (11)$$

เมื่อ คือ สเต็ปในการปรับเพิ่มค่าอัตราการเรียนรู้ โดยกำหนดให้เป็นค่าน้อยๆ ระหว่าง 0 ถึง 0.1

ขั้นตอนที่ 7 ใช้ค่าความผิดพลาดที่ได้ในขั้นตอนที่ 6 เพื่อทำการปรับค่าน้ำหนักของเส้นเชื่อมทุกเส้นที่เชื่อมระหว่างโหนดในชั้นซ่อนกับโหนดในชั้นเอาต์พุต ( $W_{kj}$ ) โดยใช้สมการที่ (6) และ (12) ส่วนการปรับค่าน้ำหนักของเส้นเชื่อมที่เชื่อมระหว่างโหนดในอินพุตกับโหนดในชั้นซ่อน ( $W_{ji}$ ) จะใช้สมการที่ (8) และ (13)

$$W_{kj}^{new} = W_{kj}^{old} - \eta(z_c(t+1)) \frac{\partial E}{\partial W_{kj}} \quad (12)$$

$$W_{ji}^{new} = W_{ji}^{old} - \eta(z_c(t+1)) \frac{\partial E}{\partial W_{ji}} \quad (13)$$

### ผลการทดสอบและอภิปรายผล

งานวิจัยนี้ทำการทดสอบประสิทธิภาพของอัลกอริทึมที่นำเสนอโดยใช้ข้อมูลทางการแพทย์ในการทดสอบ 2 ชุด โดยข้อมูลทั้ง 2 ชุดนี้เป็นข้อมูลที่มีความไม่สมดุลกันค่อนข้างสูง คือ ชุดข้อมูล Breast Tissue (Jossinet, 1996; Silva, Marques de St., & Jossinet, 2000) และชุดข้อมูล Vertebral Column (Berthonnaud, Dimnet, Roussouly, & Labelle, 2005; Rocha Neto & Barreto, 2009; Rocha Neto, Sousa, Barreto, & Cardoso, 2011) ซึ่งเป็นชุดข้อมูลมาตรฐานที่เปิดเป็นสาธารณะ โดยเก็บอยู่ใน UCI Machine Learning Repository (Dua & Graff, 2019) รายละเอียดของชุดข้อมูลทั้งสองจะได้กล่าวถึงในย่อหน้าถัดไป

ชุดข้อมูล Breast Tissue เป็นชุดข้อมูลที่ได้จากการวัดค่าความต้านทานไฟฟ้าของตัวอย่างเนื้อเยื่อที่ถูกตัดออกจากเต้านมของกลุ่มตัวอย่างจำนวน 106 ราย โดยบุคลากรของ INEB-Instituto de Engenharia Biomedica และได้เปิดเผยเป็นสาธารณะในปี ค.ศ. 2010 โดยข้อมูล 106 ข้อมูลที่รวบรวมมาแบ่งออกเป็น 4 กลุ่มคือ กลุ่มที่ 1 เนื้อเยื่อชนิด Carcinoma (Car) จำนวน 21 ข้อมูล กลุ่มที่ 2 เนื้อเยื่อชนิด Fibroadenoma (Fad), ชนิด Mastopathy (Mas), และชนิด Glandular (Gla) จำนวน 48 ข้อมูล กลุ่มที่ 3 เนื้อเยื่อชนิด Connective (Con) จำนวน 15 ข้อมูล และกลุ่มที่ 4 เนื้อเยื่อชนิด Adipose (Adi) จำนวน 22 ข้อมูล รายละเอียดของชุดข้อมูล Breast Tissue จะแสดงไว้ดังตารางที่ 1 และ 2

**ตารางที่ 1** ปริมาณข้อมูลในแต่ละคลาสของชุดข้อมูล Breast Tissue

คลาส	จำนวนข้อมูล	อัตราส่วน
1 (Car)	21	19.81%
2 (Fad, Mas, Gla)	48	45.28%
3 (Con)	15	14.15%
4 (Adi)	22	20.75%
<b>รวม</b>	<b>106</b>	<b>100.00%</b>

**ตารางที่ 2** ตัวอย่างของชุดข้อมูล Breast Tissue

IO	PA500	HFS	DA	AREA	A/DA	MAX IP	DR	P	Class
524.71	0.187448	0.032114	228.8002	6843.598	29.9108	60.20488	220.7372	556.8283	1
330	0.226893	0.26529	121.1542	3163.239	26.1092	69.71736	99.08496	400.2258	1
...	...	...	...	...	...	...	...	...	...
211	0.053931	0.094248	30.75344	151.9846	4.942034	14.26837	27.24312	217.1307	2
196.8567	0.020071	0.090757	28.59313	82.05889	2.869882	7.968783	27.66152	200.7493	2
1724.09	0.052709	0.020944	404.1262	3053.967	7.556963	71.42759	399.1942	1489.387	3
1385.6655	0.0923288	0.089361	202.48	8785.029	43.38713	143.0922	143.2578	1524.609	3
...	...	...	...	...	...	...	...	...	...
2100	0.061959	0.045379	390.4825	16640.72	42.6158	125.9004	380.6447	2073.029	4
1800	0.034208	0.042586	301.0604	4406.154	14.63545	67.62533	293.3669	1742.376	4

ชุดข้อมูล Vertebral Column ได้เก็บรวบรวมจากกลุ่มตัวอย่าง 310 คน แบ่งเป็น กลุ่มคนปกติ (NO) 100 คน คนที่ป่วยโรคหมอนรองกระดูกทับเส้นประสาท (DH) จำนวน 60 คน และคนที่ป่วยเป็นโรคกระดูกสันหลังเคลื่อน (SL) 150 คน ดังรายละเอียดในตารางที่ 3 และ 4

**ตารางที่ 3** ปริมาณข้อมูลในแต่ละคลาสของชุดข้อมูล Vertebral Column

คลาส	จำนวนเรคคอร์ด	อัตราส่วน
1 (NO)	100	32.26%
2 (DH)	60	19.35%
3 (SL)	150	48.39%
<b>รวม</b>	<b>310</b>	<b>100.00%</b>

**ตารางที่ 4** ตัวอย่างของชุดข้อมูล Vertebral Column

Pelvic incidence	Pelvic tilt	Lumbar lordosis angle	Sacral slope	Pelvic radius	Grade of spondylolisthesis	Class
38.51	16.96	35.11	21.54	127.63	7.99	1
54.92	18.97	51.6	35.95	125.85	2	1
...	...	...	...	...	...	...
63.03	22.55	39.61	40.48	98.67	-0.25	2
39.06	10.06	25.02	29	114.41	4.56	2
...	...	...	...	...	...	...
74.38	32.05	78.77	42.32	143.56	56.13	3
89.68	32.7	83.13	56.98	129.96	92.03	3

ในการทดลองเพื่อทดสอบประสิทธิภาพของอัลกอริทึมในการจำแนกประเภท ผู้วิจัยได้แบ่งชุดข้อมูลออกเป็น 2 กลุ่ม คือ กลุ่มที่ใช้ในการเรียนรู้และกลุ่มที่ใช้ในการทดสอบ เพื่อให้การทดสอบมีความน่าเชื่อถือผู้วิจัยจึงเลือกใช้วิธี K-fold Cross Validation (Geisser, 1975) ในการแบ่งชุดข้อมูล โดยเริ่มจากการแบ่งชุดข้อมูลออกเป็น K ส่วน ข้อมูลในแต่ละส่วนจะผลัดกันไปเป็นข้อมูลทดสอบ ในขณะที่อีก 4 ส่วนที่เหลือถูกใช้เป็นข้อมูลสำหรับการเรียนรู้ ดังนั้นการทดสอบจะต้องทำทั้งหมด K ครั้ง โดยแต่ละครั้งจะมีข้อมูลที่ใช้ในการเรียนรู้และข้อมูลที่ใช้ทดสอบแตกต่างกันออกไป สำหรับชุดข้อมูล Breast Tissue จะกำหนดค่า K = 5 และสำหรับชุดข้อมูล Vertebral Column จะกำหนดค่า K = 10 ตัวอย่างของกรณี 5-fold Cross Validation ได้ถูกแสดงไว้ในภาพที่ 2

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

 ข้อมูลเรียนรู้
  ข้อมูลทดสอบ

ภาพที่ 2 ตัวอย่างวิธี 5-fold cross validation

ตารางที่ 5 และ 6 เป็นตารางเปรียบเทียบค่าความถูกต้อง ค่าความถูกต้องเฉลี่ย และค่าส่วนเบี่ยงเบนมาตรฐานในการจำแนกประเภทของชุดข้อมูล Breast Tissue และชุดข้อมูล Vertebral Column โดยใช้อัลกอริทึม BPNN-ALR และโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ จากผลการทดลองในทั้งสองตารางพบว่าอัลกอริทึม BPNN-ALR มีค่าความถูกต้องเฉลี่ยสูงกว่าอัลกอริทึมโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิม 29.52% สำหรับชุดข้อมูล Breast Tissue และอัลกอริทึม BPNN-ALR มีค่าความถูกต้องเฉลี่ยสูงกว่าอัลกอริทึมโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิม 12.58% สำหรับชุดข้อมูล Vertebral Column โดยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมพยากรณ์ชุดข้อมูลทดสอบว่าเป็นข้อมูลในคลาสที่มีข้อมูลปริมาณมากทั้งหมด จึงทำให้ความถูกต้องของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมมีค่าต่ำ

ตารางที่ 5 ความถูกต้องในจำแนกประเภทชุดข้อมูล Breast Tissue ของอัลกอริทึม BPNN-ALR และ BPNN

	ความถูกต้อง (%)	
	BPNN	BPNN-ALR
ครั้งที่ 1	47.62%	71.43%
ครั้งที่ 2	47.62%	80.95%
ครั้งที่ 3	47.62%	80.95%
ครั้งที่ 4	47.62%	76.19%
ครั้งที่ 5	47.62%	76.19%
<b>Mean</b>	<b>47.62%</b>	<b>77.14%</b>
<b>S.D.</b>	<b>0%</b>	<b>3.98%</b>

**ตารางที่ 6** ความถูกต้องในจำแนกประเภทชุดข้อมูล Vertebral Column ของอัลกอริทึม BPNN-ALR และ BPNN

	ความถูกต้อง (%)	
	BPNN	BPNN-ALR
ครั้งที่ 1	48.39%	54.84%
ครั้งที่ 2	48.39%	58.06%
ครั้งที่ 3	48.39%	58.06%
ครั้งที่ 4	48.39%	61.29%
ครั้งที่ 5	48.39%	61.29%
ครั้งที่ 6	48.39%	61.29%
ครั้งที่ 7	48.39%	67.74%
ครั้งที่ 8	48.39%	61.29%
ครั้งที่ 9	48.39%	64.52%
ครั้งที่ 10	48.39%	61.29%
<b>Mean</b>	<b>48.39%</b>	<b>60.97%</b>
<b>S.D.</b>	<b>0%</b>	<b>3.55%</b>

**สรุปผลการวิจัยและข้อเสนอแนะ**

งานวิจัยนี้เป็นการปรับปรุงวิธีการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับให้มีความแม่นยำมากยิ่งขึ้นในกรณีที่ถูกใช้จำแนกประเภทชุดข้อมูลที่ไม่สมดุลกัน โดยปัญหาของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมที่มักจะเรียนรู้ข้อมูลในคลาสที่มีปริมาณข้อมูลมากกว่าคลาสที่มีปริมาณข้อมูลน้อยได้ถูกแก้ไข อัลกอริทึมที่ปรับปรุงขึ้นมาใหม่มีความสามารถในการเรียนรู้ข้อมูลของแต่ละคลาสด้วยอัตราการเรียนรู้ที่แตกต่างกัน นอกจากนั้นอัตราการเรียนรู้ของแต่ละคลาสยังสามารถที่จะปรับตัวเองให้เหมาะสมกับประสิทธิภาพในการจำแนกข้อมูลในแต่ละช่วงเวลาของการเรียนรู้อีกด้วย ผู้วิจัยได้ทำการทดลองเปรียบเทียบประสิทธิภาพอัลกอริทึมที่นำเสนอกับอัลกอริทึมโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิมในการจำแนกประเภทข้อมูลทางการแพทย์ที่มีความไม่สมดุลกันของข้อมูล 2 ชุดพบว่าอัลกอริทึมที่นำเสนอสามารถจำแนกประเภทข้อมูลในชุดข้อมูลที่ 1 และ 2 ได้ดีกว่าโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับแบบดั้งเดิม 29.52% และ 12.58% ตามลำดับ

จากผลการทดลองในเบื้องต้นกับข้อมูลทางการแพทย์ทั้ง 2 ชุดของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับร่วมกับอัตราการการเรียนรู้แบบปรับตัวเองที่ได้ผลอยู่ในระดับน่าพึงพอใจ และจากลักษณะของข้อมูลทางการแพทย์ที่มักจะมีอัตราความไม่สมดุลกันของข้อมูลสูง ผู้วิจัยจะได้ทำการทดสอบโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับร่วมกับอัตราการการเรียนรู้แบบปรับตัวเองเพิ่มเติมกับชุดข้อมูลที่มีอัตราความไม่สมดุลกันของข้อมูลสูงมากขึ้นกว่านี้ เพื่อที่จะเป็นแนวทางในการนำโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับร่วมกับอัตราการการเรียนรู้แบบปรับตัวเองไปพัฒนาเป็นระบบในการวินิจฉัยโรคเบื้องต้นให้กับประชาชนทั่วไป ทำให้ผู้ป่วยทราบตัวตนเองเป็นโรคได้อย่างทันท่วงที จะได้ไปพบแพทย์เพื่อรับการรักษาอย่างถูกต้องตามหลักวิชาการตั้งแต่ในระยะเริ่มต้น ซึ่งจะนำไปสู่การลดลงของอัตราการตายของผู้ป่วยได้

## บรรณานุกรม

- นพมาศ อัครจันทโชติ, และดิเรก พนิตสุภากมล. (2562). การเปรียบเทียบวิธีการแก้ปัญหา ข้อมูลไม่สมดุลสำหรับการจำแนกกลุ่มรายได้ของผู้ประกอบการร้านยาประเภท ข.ย. 1. In *The 9th STOU National Research Conference*. สืบค้นจาก [http://sci-database.hcu.ac.th/science/file/rsID292\\_\\_F1\\_\\_20200122213859.pdf](http://sci-database.hcu.ac.th/science/file/rsID292__F1__20200122213859.pdf).
- วิษณุวิสิฐ เกษรสิทธิ์, จิราวัลย์ จิตรถเวช, และวิชิต หล่อจ๊ะระชุนท์กุล. (2563). การลดจำนวนกลุ่มในการจำแนกแบบหลายกลุ่มเป็นสองกลุ่มสำหรับการจำแนกการกลับมารักษาซ้ำในโรงพยาบาลของผู้ป่วยโรคเบาหวาน. *Thai Science and Technology Journal*, 28(1), 41-51.
- อาริกา ธรรมโน, มุกิตา หวังคิด, และอาริต ธรรมโน. (2563). การพยากรณ์โรคมะเร็งเต้านมด้วยอัลกอริทึมการจำแนกประเภทแบบเคมีนร่วมกับค่าถ่วงน้ำหนักแบบปรับตัวเอง. *Journal of Information Science and Technology*, 10(2), 1-9.
- Berthonnaud, E., Dimnet, J., Roussouly, P., & Labelle, H. (2005). Analysis of the sagittal balance of the spine and pelvis using shape and orientation parameters. *Journal of Spinal Disorders & Techniques*, 18(1), 40-47.
- Blackard, J. A., & Dean, D. J. (1999). Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. *Computers and Electronics in Agriculture*, 24, 131-151.
- Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: a methodology review. *Journal of Biomedical Informatics*, 35, 352-359.
- Dua, D., & Graff, C. (2019). *UCI machine learning repository*. Retrieved from <https://archive.ics.uci.edu/ml/index.php>.
- Feng, J., Xu, H., Mannor, S., & Yan, S. (2014). Robust logistic regression and classification. *Proceedings of the 27th International Conference on Neural Information Processing Systems (NIPS 2014)*, Montreal, Quebec, Canada.
- Geisser, S. (1975). The predictive sample reuse method with applications. *Journal of the American Statistical Association*, 70(350), 320-328.
- Jia, W., Deng, Y., Xin, C., Liu, X., & Pedrycz, W. (2019). A classification algorithm with linear discriminant analysis and axiomatic fuzzy sets. *Mathematical Foundations of Computing*, 2(1), 73-81.

- Jossinet, J. (1996). Variability of impedivity in normal and pathological breast tissue. *Medical & Biological Engineering & Computing*, 34, 346-350.
- Rocha Neto, A. R., & Barreto, G. A. (2009). On the application of ensembles of classifiers to the diagnosis of pathologies of the vertebral column: A comparative analysis. *IEEE Latin America Transactions*, 7(4), 487-496.
- Rocha Neto, A. R., Sousa, R., Barreto, G. A., & Cardoso, J. S. (2011). Diagnostic of pathology on the vertebral column with embedded reject option. In *Proceedings of the 5th Iberian Conference on Pattern Recognition and Image Analysis (IbPRIA'2011)*, Gran Canaria, Spain, 588-595.
- Silva, J. E., Marques de S, J. P., & Jossinet, J. (2000). Classification of breast tissue by electrical impedance spectroscopy. *Medical & Biological Engineering & Computing*, 38, 26-30.
- Zhang, H., Huang, L., Wu, C. Q., & Li, Z. (2020). An effective convolutional neural network based on SMOTE and gaussian mixture model for intrusion detection in imbalanced dataset. *Computer Networks*, 177.