



การเปรียบเทียบประสิทธิภาพเทคนิคนิวรอนเน็ตเวิร์ค ซัพพอร์ตเวกเตอร์แมชชีน และนิวโรฟัซซี กับการแปลงฟูเรียร์แบบเร็ว เพื่อวิเคราะห์และแยกแยะสัญญาณรูปคลื่นไฟฟ้า

Efficiency Comparison of Neural Networks, Support Vector Machine and Neuro-Fuzzy with Fast Fourier Transform for Waveform Analysis and Classification

อดิสรณ์ กำลังเพชร^{1*} และประจวบ อินระวงศ์¹

Received: June, 2017; Accepted: October, 2017

บทคัดย่อ

งานวิจัยนี้ได้นำเสนอการเปรียบเทียบประสิทธิภาพของตัวแบบทั้งสามวิธี คือ ตัวแบบที่ใช้เทคนิคจากโครงข่ายประสาทเทียม (ANN) ตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (SMOreg) และตัวแบบนิวโรฟัซซีโดยใช้เทคนิคแบบ ANFIS ในรูปแบบของการจดจำเพื่อใช้ในการวิเคราะห์และแยกแยะข้อมูลสัญญาณรูปคลื่นไฟฟ้าระหว่างชุดข้อมูลสัญญาณดีกับชุดข้อมูลสัญญาณเสีย โดยหลักการในการสร้างตัวแบบที่นำเสนอทั้งสามตัวแบบจะใช้ข้อมูลที่ผ่านการแปลงฟูเรียร์แบบเร็ว เพื่อใช้หาตัวแปรข้อมูลสำหรับกระบวนการเรียนรู้หรือฝึกหัดและทดสอบ จากการทดลองทั้งสามตัวแบบมี ANN, SMOreg และ ANFIS โดยผลลัพธ์จากการฝึกหัดค่า MSE คือ $1.45E-08$, $5.60E-08$, $3.32E-09$ ค่า MAE คือ $8.28E-05$, $4.31E-05$, $3.20E-05$ และค่า MAPE คือ 2.99636, 0.69080, 0.83541 ตามลำดับ และผลลัพธ์จากการทดสอบค่า MSE คือ $8.30E-09$, $2.66E-07$, $3.21E-09$ ค่า MAE คือ $8.61E-05$, $3.32E-04$, $3.38E-05$ และค่าร้อยละที่ได้จากค่า MAPE คือ 2.5807, 10.9384, 0.8061 ตามลำดับ เมื่อนำทั้งสามตัวแบบมาเปรียบเทียบผลลัพธ์ที่ได้จากการทดสอบ พบว่าตัวแบบนิวโรฟัซซีโดยใช้เทคนิคแบบ ANFIS มีประสิทธิภาพที่ดีที่สุด โดยมีค่า

¹ Faculty of Engineering and Architecture, Rajamangala University of Technology Isan, Nakhon Ratchasima

* Corresponding Author E - mail Address: einstein.ict@gmail.com

ความผิดพลาดโดยรวมน้อยที่สุดกว่าตัวแบบอื่น และค่าของ EI เท่ากับ 99.999993 % สูงที่สุด และผลจากการทดสอบทุกชุดข้อมูลสัญญาณสามารถแยกแยะระหว่างชุดข้อมูลสัญญาณดีกับชุดข้อมูลสัญญาณเสียได้อย่างถูกต้อง

คำสำคัญ : โครงข่ายประสาทเทียม; นิวโรฟัซซี; ซัพพอร์ตเวกเตอร์แมชชีน; การแปลงฟูเรียร์แบบเร็ว; สัญญาณรูปคลื่นไฟฟ้า

Abstract

This research presents a comparison of the efficiency of three models, namely, the model using Artificial Neural Networks technique (ANN), Support Vector Machine models (SMOreg) and Neuro-Fuzzy using ANFIS technique models in form of pattern recognition for waveform analysis and classification between good signals and bad signals data set. In principle, the three models are proposed. It used Fast Fourier Transform data for learning and testing process for finding the best model. The three experiments were ANN, SMOreg and ANFIS. Results from the MSE training were 1.45E-08, 5.60E-08, 3.32E-09, the MAE were 8.28E-05, 4.31E-05, 3.20E-05, the MAPE were 2.99636, 0.69080, 0.83541, respectively, and the MSE test results were 8.30E-09, 2.66E-07, 3.21E-09, the MAE were 8.61E-05, 3.32E-04, 3.38E-05, and the percentage obtained from MAPE were 2.5807, 10.9384 and 0.8061, respectively. It was found that the ANFIS technique was the best. With the smallest overall error value than the other models, which provides the highest percentage of Efficiency Index (EI) in the testing process were 99.999993 %. The experimental result of testing showed that all data sets can distinguish between good and bad data sets correctly.

Keywords: Artificial Neural Networks; Neuro-Fuzzy; Support Vector Machine; Fast Fourier Transform; Waveform Analysis;

บทนำ

ปัจจุบันเทคโนโลยีในด้านต่าง ๆ ได้มีการพัฒนาอย่างรวดเร็ว รวมทั้งได้มีการพัฒนาผลิตภัณฑ์ อุปกรณ์ทางด้านไฟฟ้าและอิเล็กทรอนิกส์ทั้งในด้านการวิจัยและงานด้านภาคอุตสาหกรรม โดยอุปกรณ์ทางด้านไฟฟ้าและอิเล็กทรอนิกส์ที่ใช้ในงานด้านภาคอุตสาหกรรม เช่น อุปกรณ์ที่ใช้ในส่วนประกอบต่าง ๆ ของเครื่องจักรกล อุปกรณ์สำหรับทดสอบชิ้นงาน อุปกรณ์สำหรับประกอบชิ้นงาน อุปกรณ์ที่ใช้ควบคุมการหยิบจับชิ้นงาน เป็นต้น ในชิ้นส่วนของอุปกรณ์ต่าง ๆ จะมีแผงวงจรที่ทำหน้าที่ในการสั่งงานเครื่อง ซึ่งจากการสั่งงานนั้นโดยส่วนใหญ่แล้วจะติดต่อสื่อสารกันด้วยรูปแบบสัญญาณไฟฟ้า และเนื่องจากการติดต่อสื่อสารสั่งงานด้วยรูปแบบสัญญาณไฟฟ้า ปัญหาที่ตามมาก็คือ เมื่อสัญญาณเกิดการสื่อสารผิดพลาด หรือสัญญาณมีปัญหา

อันเนื่องจากชุดของแผงวงจรเอง หรือสัญญาณที่ทำงานผิดพลาดอันเนื่องมาจากสัญญาณรบกวน (Noise) ซึ่งจะทำให้การส่งงานนั้นเกิดการทำงานที่ผิดพลาดได้ จึงมีความจำเป็นที่จะต้องมียุทธวิธีหรือตัวแบบสำหรับตรวจสอบอุปกรณ์ที่ส่งงานด้วยรูปแบบสัญญาณไฟฟ้าให้คงสภาพการทำงานที่ดีปกติเสมอ

การวิเคราะห์สัญญาณรูปคลื่นไฟฟ้ามีหลากหลายวิธี ไม่ว่าจะเป็นการวิเคราะห์สัญญาณรูปคลื่นไฟฟ้าด้วยวิธีการวิเคราะห์แบบฟูเรียร์ (Fourier Analysis) วิธีการจำลองทางเวลา (Time Domain Simulation) หรือการจำลองทางความถี่ (Frequency Domain Simulation) เป็นต้น [1] โดยงานวิจัยนี้มุ่งเน้นการนำเสนอตัวแบบสำหรับวิเคราะห์และแยกแยะข้อมูลสัญญาณรูปคลื่นไฟฟ้าที่ดีและที่มีปัญหาหรือเสียด้วยวิธีที่นำเสนอทั้ง 3 วิธี แล้วนำแต่ละวิธีมาทำการเปรียบเทียบประสิทธิภาพว่าวิธีไหนที่ดีที่สุด โดยมีการวิเคราะห์ผลลัพธ์ที่ได้จากค่าความคลาดเคลื่อนที่เกิดขึ้น ซึ่งข้อมูลที่ใช้เป็นข้อมูลของสัญญาณรูปคลื่นไฟฟ้าของชิ้นงานที่ใช้ชิพประมวลผลสัญญาณดิจิทัลหรือชิปเซตดีเอสพี (Digital Signal Processor: DSP) ของเครื่องจักรกล โดยเริ่มต้นจากการนำข้อมูลสัญญาณรูปคลื่นไฟฟ้าที่ได้มาทำการหาค่าตัวแปรด้วยวิธีการแปลงฟูเรียร์แบบเร็ว (Fast Fourier Transform: FFT) สำหรับใช้เป็นข้อมูลเรียนรู้และทดสอบร่วมกับวิธีที่นำเสนอทั้ง 3 วิธี คือ 1) วิธีการของเทคนิคโครงข่ายประสาทเทียมหรือนิวรอนเน็ตเวิร์ค (Artificial Neural Network: ANN) ด้วยวิธีการเรียนรู้แบบมีผู้สอน (Supervised Learning) [1] - [4] และ 2) วิธีการของเทคนิคโครงข่ายประสาทเทียมแบบฟัซซีหรือนิวโรฟัซซี (Neuro-Fuzzy) ด้วยวิธีการแบบปรับตัวได้ (Adaptive Network-Based Fuzzy Inference System: ANFIS) [5] และ 3) วิธีการของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย (Support Vector Machine for Regression) โดยเลือกใช้เทคนิคแบบเอสเอ็มโอสำหรับการถดถอย (Sequence Minimal Optimization for Regression: SMOreg)

จากงานวิจัยเพื่อเป็นแนวทางในการประยุกต์ใช้ในการวิเคราะห์และแยกแยะสัญญาณรูปคลื่นไฟฟ้าที่ดีและเสีย เพื่อให้เห็นความแตกต่างในการวิเคราะห์ระหว่างสัญญาณดีกับสัญญาณเสีย โดยมีวัตถุประสงค์ 1) เพื่อสร้างตัวแบบโดยใช้เทคนิคทั้งสามวิธี สำหรับการวิเคราะห์และแยกแยะสัญญาณรูปคลื่นไฟฟ้า 2) เพื่อวิเคราะห์และแยกแยะความแตกต่างระหว่างสัญญาณรูปคลื่นไฟฟ้าสัญญาณดีกับสัญญาณรูปคลื่นไฟฟ้าสัญญาณเสีย 3) เพื่อเปรียบเทียบผลลัพธ์ของประสิทธิภาพระหว่างทั้งสามวิธีที่นำเสนอว่าวิธีไหนดีที่สุด และ 4) เพื่อเป็นแนวทางวิธีคิดในการประยุกต์ใช้วิธีที่นำเสนอร่วมกับวิธีการแปลงฟูเรียร์แบบเร็วในการวิเคราะห์และแยกแยะสัญญาณรูปคลื่นไฟฟ้า

ประโยชน์ที่คาดว่าจะได้รับ ผู้สนใจในการวิเคราะห์สัญญาณไฟฟ้าสามารถนำขั้นตอนวิธีที่ได้จากการศึกษาไปประยุกต์ใช้และเป็นแนวทางในการสร้างตัวแบบ เพื่อช่วยในการวิเคราะห์และแยกแยะระหว่างข้อมูลสัญญาณดีและข้อมูลสัญญาณเสียของสัญญาณรูปคลื่นไฟฟ้าในรูปแบบต่าง ๆ ได้

ทฤษฎีที่เกี่ยวข้อง

1. ชิพประมวลผลสัญญาณดิจิทัล (Digital Signal Processor: DSP)

ชิพ DSP เป็นชิพประมวลผลสัญญาณ คือ ไมโครโปรเซสเซอร์ที่ถูกออกแบบมาสำหรับงานประมวลผลสัญญาณแบบเวลาจริงโดยเฉพาะ โดยไมโครโปรเซสเซอร์ประเภทนี้ จะมีสถาปัตยกรรมที่เอื้ออำนวยต่อการคำนวณ การโอนถ่ายข้อมูลที่มีประสิทธิภาพ และความเร็วสูง เช่น การมีคำสั่งพิเศษ

ในการคูณ การบวกสะสม หรือการอ้างข้อมูลแบบ Circular Buffer เป็นต้น บางชนิดยังสามารถทำการประมวลผลหลาย ๆ ส่วนได้พร้อมกันในตัวเดียว (Multi-Processing) อีกด้วย ซึ่งชิพ DSP นี้มีทั้งประเภทที่เป็นการประมวลผลข้อมูลแบบจำนวนเต็ม (Fixed-Point) และประเภทที่ประมวลผลข้อมูลแบบเลขของตรรกฐาน (Floating-Point) ส่วนการใช้งานทำได้โดยเขียนเป็นโปรแกรมภาษาแอสเซมบลีหรือภาษาซีแล้วใช้คอมไพเลอร์แปลงเป็นภาษาแอสเซมบลีอีกที [6]


2. การแปลงฟูเรียร์แบบเร็ว (Fast Fourier Transform: FFT)

การวิเคราะห์ฟูเรียร์เป็นกระบวนการเปลี่ยนรูปคลื่นสัญญาณทางเวลาไปเป็นส่วนประกอบกันทางความถี่หรือสเปกตรัมของสัญญาณนั้น ๆ โดยสัญญาณที่มีลักษณะเป็นรายคาบ จะสามารถวิเคราะห์โดยใช้อนุกรมฟูเรียร์ และสัญญาณที่มีลักษณะไม่เป็นรายคาบจะใช้การแปลงด้วยฟูเรียร์ทรานส์ฟอร์ม [1], [7] และจากปัญหาของ Discrete Fourier Transform (DFT) คือ การคำนวณตามนิยามของ DFT นั้นแปรตาม N^2 ดังนั้นถ้าไม่มีวิธีการคำนวณ DFT ให้เร็วพอที่จะคำนวณ DFT ที่ N มีค่าสูง ๆ ได้ภายในเวลาอันสมควรแล้ว DFT ก็ไม่มีประโยชน์ วิธีการที่คำนวณ DFT ให้เร็ว ซึ่งวิธีนี้ก็คือใช้อัลกอริทึมชื่อ FFT ในการคำนวณจากสมการที่ (1) [1] เราสามารถลดจำนวนการคูณกันของสมการเมตริกได้ด้วยการแปลงทางฟูเรียร์แบบเร็ว โดยการจัดกลุ่มของเมตริก W^{kn} ใหม่ ซึ่งทำให้การคูณกันของสมการลดลงเหลือเพียง $N \log_2 N$ ครั้ง [1]


$$[X(f_k)] = \frac{1}{N} [W^{kn}] [x(t_n)] \quad (1)$$

3. โครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

โครงข่ายประสาทเทียมเป็นโมเดลทางคณิตศาสตร์หรือโมเดลทางคอมพิวเตอร์ โดยจุดมุ่งหมายของโครงข่ายประสาทเทียมคือ ต้องการให้คอมพิวเตอร์มีความชาญฉลาดในการเรียนรู้เสมือนที่มนุษย์มีการเรียนรู้ สามารถฝึกหัดได้ และสามารถนำความรู้และทักษะไปประยุกต์ใช้ได้ดี [8] สำหรับการประมวลผลสารสนเทศด้วยการคำนวณแบบคอนเนกชันนิสต์ (Connectionist) ที่มีการรวมกลุ่มแบบขนานของหน่วยประมวลผลย่อย โดยทั่วไปโครงข่ายประสาทเทียมประกอบด้วย โหนดชั้นตัวแปรนำเข้า (Input Node) โหนดในชั้นซ่อน (Hidden Node) และโหนดชั้นตัวแปรผลลัพธ์ (Output Node) ซึ่งโหนดทั้งหมดเหล่านี้จะมีการเชื่อมต่อกันในรูปแบบเพอร์เซปตรอนหลายชั้น (Multi-Layer Perceptron: MLP) มีการส่งข้อมูลจากชั้นสู่ชั้นจนถึง Output Node และมีกระบวนการฝึกหัดเป็นแบบมีผู้สอน โดยส่งค่าย้อนกลับหรือเรียกว่า การเรียนรู้แบบแพร่กลับ (Back Propagation) [9] - [12] ในโครงข่ายประสาทเทียมหลายชั้นแบบป้อนไปข้างหน้า เริ่มจากการป้อนข้อมูลเข้าจากชั้นข้อมูลนำเข้า (Input Layer) และมีการเชื่อมต่อกับส่วนของโหนดในชั้นซ่อน (Hidden Layer) ซึ่งอาจมีมากกว่าหนึ่งชั้น เพื่อทำการปรับระบบตามพฤติกรรมของข้อมูล และสามารถอธิบายข้อมูลที่มีความซับซ้อนได้เพิ่มมากขึ้น [5], [13] ดังรูปที่ 1 ซึ่งวิธีการของโครงข่ายประสาทเทียมสามารถนำไปประยุกต์ใช้เพื่อแก้ปัญหางานในระดับง่ายไปจนถึงงานระดับยากซับซ้อนขึ้นอยู่กับงานที่นำไปประยุกต์ใช้



รูปที่ 1 โครงสร้างโครงข่ายประสาทเทียม



รูปที่ 2 โครงสร้างของ ANFIS

4. นิวโรฟัซซี (Neuro-Fuzzy: NF)

ปัจจุบันเทคนิคเชิงอัจฉริยะได้มีบทบาทในหลายด้าน โดยแต่ละตัวจะมีคุณสมบัติในการคำนวณและแก้ปัญหาได้เฉพาะบางอย่างไม่สามารถแก้ได้ทั้งหมด เช่น นิวรัลเน็ตเวิร์คมีคุณสมบัติในการเรียนรู้ แต่ไม่สามารถใช้สำหรับการอธิบายถึงการได้มาซึ่งสิ่งที่ตัดสินใจ ในขณะที่ระบบฟัซซีสามารถให้เหตุผลด้วยข้อมูลที่คลุมเครือและมีคุณสมบัติของการใช้งานด้านการอธิบายการตัดสินใจที่สามารถตีความให้อยู่ในรูป If-Then ซึ่งสอดคล้องกับตรรกะความคิดของมนุษย์ โดยช่วยสร้างกฎฟัซซีจากการเรียนรู้จากกลุ่มข้อมูลอินพุตและเอาต์พุต ช่วยในการตัดสินใจที่คลุมเครือ แต่ระบบฟัซซีเองก็ไม่สามารถในการเรียนรู้กฎโดยอัตโนมัติจากข้อมูล ข้อจำกัดต่าง ๆ เหล่านี้ ทำให้มีนักวิจัยให้ความสนใจคิดค้นวิธีการผสมระบบหลายระบบเข้าด้วยกัน เมื่อนำสองศาสตร์นี้รวมกันกลายเป็นระบบประสานแบบอัจฉริยะ (Hybrid Intelligent System: HIS) ขึ้นมาเป็นจำนวนมาก เช่น ระบบฟัซซีผสมเข้ากับโครงข่ายประสาทเทียม จึงได้ชื่อใหม่เป็นระบบนิวโรฟัซซี ทั้งนี้เพื่อแก้ปัญหาจากข้อด้อยของแต่ละวิธี ระบบผสมนิวโรฟัซซีที่มีชื่อเสียงเป็นที่รู้จักกันมาก ได้แก่ ANFIS เป็นระบบอนุมานฟัซซีบนฐานโครงข่ายที่ปรับตัวได้ด้วยวิธีการเรียนรู้แบบโครงข่ายประสาทเทียม จากรูปที่ 2 โครงสร้างของ ANFIS ประกอบด้วย 2 อินพุตคือ x และ y แต่ละอินพุตแบ่งเป็น 2 ฟัซซีเซต และ 1 เอาต์พุต [14] - [15]

5. ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย (Support Vector Machine for Regression)

ซัพพอร์ตเวกเตอร์แมชชีน หรือ SVM เป็นอัลกอริทึมที่ใช้ในการจำแนกกลุ่มข้อมูลด้วยวิธีการหาแนวการตัดสินใจ (Decision Hyperplane) หรือไฮเปอร์เพลนที่เหมาะสมสำหรับการแบ่งข้อมูล 2 ส่วนจากกัน SVM ยังถูกนำมาประยุกต์ใช้ในการสร้างสมการในประมาณการค่าฟังก์ชันเชิงเส้น $F(x)$ แทนแนวการตัดสินใจ ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย หรือ SVR จะเป็นการนำข้อมูลปัจจุบันและข้อมูลในอดีตจำนวนหนึ่งมาทำการเรียนรู้ (Training) เพื่อให้ทราบถึงรูปแบบสำหรับคาดการณ์ผลซึ่งเกิดขึ้นในอนาคต ซึ่งซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอยเป็นอีกเทคนิคหนึ่งที่สามารถนำมาพยากรณ์ได้ งานวิจัยนี้ผู้วิจัยเลือกใช้วิธีสร้างสมการในประมาณการค่าฟังก์ชันเชิงเส้นด้วยวิธี Sequential Minimal Optimization for SVM Regression (SMOreg) [16]

วิธีการเอสเอ็มโอสำหรับการถดถอย (Sequence Minimal Optimization for Regression: SMOreg) เป็นอัลกอริทึมสำหรับการแก้สมการการเขียนโปรแกรมกำลังสอง (Quadratic Programming: QP) เป็นปัญหาที่เกิดขึ้นในระหว่างกระบวนการฝึกหัดของ Sequence Minimal Optimization (SMO) [16]

วิธีดำเนินการวิจัย

ขั้นตอนของการดำเนินการวิจัยโดยรวมสามารถแบ่งได้เป็น 3 ขั้นตอนหลัก ๆ ดังนี้

1. การเริ่มต้นวิจัย


การเริ่มต้นการวิจัย เป็นขั้นตอนแรกของงานวิจัยโดยกำหนดวัตถุประสงค์ของงานวิจัยและประโยชน์ที่คาดว่าจะได้รับการวิจัย จากนั้นเริ่มทำการศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง วางแผนขั้นตอนการดำเนินการวิจัย และเก็บรวบรวมข้อมูลสัญญาณไฟฟ้าที่ต้องการนำมาใช้ในงานวิจัยดังตารางที่ 1

ตารางที่ 1 ขั้นตอนวิธีดำเนินการวิจัย

ขั้นตอนวิธีดำเนินการวิจัย		
การเริ่มต้นการวิจัย	การจัดเตรียมข้อมูล	การสร้างตัวแบบและการทดสอบ
1) ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง	1) ขั้นตอนการแปลงฟูเรียร์แบบเร็วสำหรับหาค่าตัวแปรข้อมูลเพื่อใช้สำหรับทดลอง	1) กำหนดโครงสร้างของแต่ละวิธีที่นำเสนอและกำหนดค่าต่าง ๆ
2) วางแผนขั้นตอนวิธีดำเนินการวิจัย	2) จัดการข้อมูลให้อยู่ในรูปแบบที่ใช้สำหรับทดลอง	2) ทำการฝึกหัดข้อมูลและเตรียมตัวแบบที่ได้สำหรับทดสอบข้อมูล
3) เก็บรวบรวมข้อมูลสัญญาณรูปคลื่นไฟฟ้าที่ใช้สำหรับทดลอง	3) เตรียมชุดข้อมูลสำหรับเรียนรู้กับทดสอบ	3) ทดสอบกับทุกชุดข้อมูลด้วยตัวแบบที่ได้

จากการตรวจวัดชิ้นงานของสัญญาณรูปคลื่นไฟฟ้าด้วยเครื่องออสซิลโลสโคปจำนวนหลายชิ้น ๆ ละ 1 สัญญาณ และเลือกนำมาใช้ทดลองจำนวนหนึ่ง เป็นกลุ่มชุดสัญญาณดีจำนวน 21 สัญญาณ และกลุ่มชุดสัญญาณเสียจำนวน 7 สัญญาณ แต่ละสัญญาณมีจำนวนข้อมูล 3,360 เรคคอร์ด และ

สิ่งที่แตกต่างกันระหว่างสัญญาณดีกับสัญญาณเสีย คือค่าของ Phase, ค่าสูงต่ำของ Amplitude และค่าอ้างอิงที่จุดเริ่มต้นของสัญญาณ จากรูปที่ 3 สัญญาณดีก่อนที่จะผ่านขั้นตอนของ FFT ค่าของ Amplitude โดยค่าต่ำสุดจะอยู่ที่ 0 โวลต์ กับ 5 โวลต์ (Good Signal) ส่วนสัญญาณเสียค่าจะแตกต่าง (Bad Signal 3) หรือค่าของ Phase จะกลับค่า (Bad Signal 1, Bad Signal 2) เมื่อเทียบกับสัญญาณดี




รูปที่ 3 รูปแบบข้อมูลสัญญาณระหว่างดีและเสีย


2. การจัดเตรียมข้อมูล

การจัดเตรียมข้อมูลสัญญาณ เป็นขั้นตอนกระบวนการเตรียมข้อมูลสำหรับนำไปใช้ในกระบวนการเรียนรู้หรือฝึกหัดและทดสอบของตัวแบบที่นำเสนอ มีขั้นตอนดังนี้

2.1 ชุดข้อมูลสำหรับการแปลงฟูเรียร์แบบเร็ว เป็นข้อมูลสัญญาณรูปคลื่นไฟฟ้าที่ได้จากการตรวจวัดด้วยเครื่องออสซิลโลสโคปของชิ้นงาน แล้วนำข้อมูลสัญญาณในแต่ละสัญญาณที่ได้มาทำการแปลงข้อมูลสัญญาณด้วยฟังก์ชัน FFT ค่าที่ได้จะเป็นเลขเชิงซ้อน จากนั้นทำการหาค่าแอมพลิจูดและเลือกช่วงของแอมพลิจูดที่เหมาะสมกับการทดลอง ซึ่งช่วงที่ได้จะอยู่ระหว่างค่า 100 - 2,000 ทำให้ได้ตัวแปรแอมพลิจูด (Amplitude: Amp) ที่มีจำนวนข้อมูล 58 เรคคอร์ดต่อหนึ่งสัญญาณ จากนั้นใช้ชุดข้อมูลเดียวกันกับที่ใช้หาค่าในตัวแปรแอมพลิจูดมาทำการหาค่าเฟสและค่าสเปกตรัมกำลัง ทำให้ได้ตัวแปรเฟส (Phase: Ph) และตัวแปรสเปกตรัมกำลัง (PSD) ที่มีจำนวนข้อมูลสัญญาณละ 58 เรคคอร์ด ส่วนชุดข้อมูลในตัวแปรความถี่ (Frequency: Freq) ได้จากการนำค่าความถี่ที่ตรงกับตำแหน่งในแต่ละค่าของตัวแปรแอมพลิจูด ซึ่งตัวแปรทุกตัวที่ได้ถูกนำมาใช้เพื่อเป็นชุดข้อมูลสำหรับทดลองกับวิธีที่นำเสนอ ดังรูปที่ 4 และรูปที่ 5



รูปที่ 4 ค่าแอมพลิจูดของข้อมูลใน 1 สัญญาณ



รูปที่ 5 ชุดข้อมูลสัญญาณสำหรับทดลองใน 1 สัญญาณ

$$Y = \text{fft}(\text{data}, n); \quad (2)$$

$$\text{Freq} = (0 : n-1) * (fs / n); \quad (3)$$

$$\text{Amp} = \text{abs}(Y); \quad (4)$$

$$\text{PSD} = Y * \text{conj}(Y) / n; \quad (5)$$

$$\text{Ph} = a \tan 2(y1, x1) * 180 / \pi; \quad (6)$$

เมื่อ

data คือ ข้อมูลสัญญาณ
 n คือ จำนวนข้อมูลของ data
 Y คือ ข้อมูลที่ได้จากการแปลงด้วย FFT

f_s คือ ช่วงค่าความถี่ของ $data$
 $Freq$ คือ ค่าความถี่ในแต่ละเรคคอร์ด
 Amp คือ ค่าแอมพลิจูดของ Y
 PSD คือ ค่าสเปกตรัมกำลังของ Y
 Ph คือ ค่าเฟสของ Y

Signal	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10	G11	G12	G13	G14	B1-B7
Training Set	58x8=464 records														
	*	*	*	*	*	*	*	*	*	*	*	*	*	*	7*
Testing Set	*	*	*	*	*	*	*	*	*	*	*	*	*	*	7*


 Training Set = 464 records (Input = Freq, Amp, Ph, Target = PSD)
 Testing Set = 58 records , * = 1 Signal , 7* = Signal Bad 7 signals

รูปที่ 6 ชุดข้อมูลสัญญาณสำหรับฝึกหัดและทดสอบ


จากรูปที่ 6 แสดงการแบ่งชุดข้อมูลสัญญาณสำหรับฝึกหัดและทดสอบ โดยชุดข้อมูลสำหรับฝึกหัดทั้งหมดเท่ากับ 464 เรคคอร์ด คือ ใช้ชุดข้อมูลสัญญาณตั้งแต่ G1 ถึง G8 และชุดข้อมูลสำหรับทดสอบ ซึ่งจะทดสอบทุกข้อมูลสัญญาณ ๗ ละ 58 เรคคอร์ด คือ ข้อมูลสัญญาณตั้งแต่ G1 ถึง G14 และ B1 ถึง B7 (G1 หมายถึง ข้อมูลสัญญาณคิสัญญาณที่ 1, B1 หมายถึง ข้อมูลสัญญาณที่มีปัญหาหรือเสียสัญญาณที่ 1)

2.2 ชุดข้อมูลสำหรับฝึกหัดและชุดข้อมูลสำหรับทดสอบ ประกอบด้วย

1) ชุดข้อมูลสำหรับฝึกหัด (Training Set) คือ ชุดข้อมูลนำเข้า (Input Set) ประกอบด้วย จำนวน 3 ตัวแปร คือ Freq, Amp, Ph ซึ่งในแต่ละตัวแปรจะเลือกใช้ข้อมูลสัญญาณคิทั้งหมด 8 สัญญาณรวมกัน จะได้เท่ากับ 464 เรคคอร์ด และชุดข้อมูลค่าเป้าหมาย (Target Set) มีจำนวน 1 ตัวแปร คือ PSD โดยเลือกใช้ชุดข้อมูลของสัญญาณคิ 1 สัญญาณ แล้วทำข้อมูลค่าเป้าหมายที่มีจำนวนเรคคอร์ดเท่ากับชุดข้อมูลนำเข้า ด้วยวิธีนำมาต่อเรียงกัน 8 ครั้ง เป็นดังรูปที่ 7 และ 8



รูปที่ 7 ลักษณะโครงสร้างที่ใช้สำหรับฝึกหัด



รูปที่ 8 ชุดข้อมูลค่าเป้าหมายของ PSD สำหรับฝึกหัด

2) ชุดข้อมูลสำหรับทดสอบ (Testing Set) คือ เป็นชุดข้อมูลนำเข้าในแต่ละสัญญาณ ๆ ละ 58 เรคคอร์ด ประกอบด้วยจำนวน 3 ตัวแปร คือ Freq, Amp และ Ph ดังรูปที่ 5 และ 6

2.3 การหาค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient)

เนื่องจากข้อมูลนำเข้าต้องมีความสัมพันธ์กับข้อมูลผลลัพธ์ซึ่งเป็นสเปกตรัมกำลังของข้อมูลสัญญาณ โดยความสัมพันธ์ของข้อมูลนี้ได้จากการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ ซึ่งมีค่าอยู่ระหว่าง -1 ถึง 1 โดยถ้ามีค่าเข้าใกล้ 1 แสดงว่าข้อมูลมีความสัมพันธ์กันมากในทิศทางเดียวกัน ถ้าค่าเข้าใกล้ -1 แสดงว่าข้อมูลมีความสัมพันธ์กันมากในทิศทางแปรผกผัน และถ้ามีค่าเข้าใกล้ 0 แสดงว่าข้อมูลมีความสัมพันธ์กันน้อย

สำหรับงานวิจัยนี้ใช้การวิเคราะห์หาค่าสัมประสิทธิ์สหสัมพันธ์แบบ 2 ตัวแปร ซึ่งสามารถหาค่าของ r ได้ ดังสมการที่ (7) [13] เมื่อนำข้อมูลนำเข้าทั้ง 3 ตัวแปร คือ Freq, Amp, Ph มาหาค่าสัมประสิทธิ์สหสัมพันธ์ ซึ่งค่าที่ได้เท่ากับ -0.3556, 0.9686 และ -0.2916 ตามลำดับ

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (7)$$

เมื่อ

- r คือ ค่าสัมประสิทธิ์สหสัมพันธ์
- n คือ จำนวนข้อมูล
- x คือ ค่าข้อมูลนำเข้า
- y คือ ค่าข้อมูลเป้าหมาย

2.4 การแปลงข้อมูล (Data Transformation)

เป็นขั้นตอนการปรับขอบเขตของข้อมูลให้อยู่ในช่วงที่เหมาะสมกับฟังก์ชันที่เลือกใช้ เพื่อนำไปใช้งานในการฝึกหัดให้เกิดกระบวนการเรียนรู้ โดยแปลงค่าข้อมูลสัญญาณด้วยวิธีการนอร์มัลไลซ์ (Normalization) และการแปลงค่าข้อมูลในลักษณะเชิงเส้น (Min-Max Normalization) โดยงานวิจัยนี้

จะแปลงข้อมูลให้อยู่ระหว่างค่า 0 - 1 ก่อนนำชุดข้อมูลไปใช้สำหรับฝึกหัดและทดสอบ ดังรูปที่ 5 และ ดังสมการที่ (8) [5], [13]

$$V_{new} = \frac{V - \min}{\max - \min} (\max_{new} - \min_{new}) + \min_{new} \quad (8)$$

เมื่อ

V_{new}	คือ	ค่าหลังจากการแปลงค่า
V	คือ	ค่าก่อนการแปลงค่า
$\max$	คือ	ค่าสูงสุดของข้อมูลก่อนแปลงค่า
$\min$	คือ	ค่าต่ำสุดของข้อมูลก่อนแปลงค่า
$\max_{new}$	คือ	ค่าสูงสุดของข้อมูลหลังแปลงค่า
$\min_{new}$	คือ	ค่าต่ำสุดของข้อมูลหลังแปลงค่า

3. การสร้างตัวแบบและการทดสอบ

การสร้างตัวแบบและการทดสอบ เป็นขั้นตอนกระบวนการสร้างตัวแบบโดยกำหนดค่าต่าง ๆ ในตัวแบบที่น่าเสนอ เพื่อหาตัวแบบที่ดีที่สุดในแต่ละวิธี และนำตัวแบบที่ได้ไปทดสอบกับข้อมูลสำหรับทดสอบ มีขั้นตอนดังนี้

3.1 ตัวแบบที่ได้จากการฝึกหัดโดยใช้เทคนิคโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น (ANN) โดยใช้ระบบการเรียนรู้แบบแพร่ค่าย้อนกลับ เนื่องจากเป็นโครงข่ายที่สามารถเรียนรู้ได้โดยการปรับค่าน้ำหนัก เพื่อลดค่าความคลาดเคลื่อนระหว่างค่าข้อมูลผลลัพธ์กับค่าเป้าหมาย [5], [13] และประกอบด้วย จำนวนโหนดในชั้นข้อมูลนำเข้ามีจำนวน 3 โหนด จำนวนโหนดในชั้นซ่อนได้จากการทดลองโดยเลือกจำนวนโหนดที่ให้ผลลัพธ์ที่ดีที่สุดมาเป็นตัวแบบ ซึ่งในการทดลองครั้งนี้คือ 40 โหนด จำนวนโหนดในชั้นผลลัพธ์มีจำนวน 1 โหนด โดยตัวแบบที่ได้กำหนดค่าต่าง ๆ ดังนี้ 1) เลือกใช้ฟังก์ชันการฝึกหัดแบบ TrainLM เนื่องจากสามารถประมวลผลได้ค่อนข้างเร็วและมีประสิทธิภาพ [5], [13] 2) เลือกใช้ฟังก์ชันการเรียนรู้แบบ LearnGDM 3) กำหนดให้ชั้นซ่อน 1 ชั้น 4) เลือกใช้ฟังก์ชันกระตุ้นแบบ Binary Sigmoid (logsig) ในชั้นซ่อน และแบบ Linear (purelin) ในชั้นผลลัพธ์ เนื่องจากข้อมูลที่ใช้กำหนดค่าให้อยู่ในช่วง 0 - 1 และ 5) เลือกใช้ค่าความคลาดเคลื่อนที่เกิดขึ้นคำนวณในรูปของค่า MSE, MAE, MAPE และค่าประสิทธิภาพของตัวแบบคำนวณในรูปของค่า EI ดังสมการที่ (9) - (12)

$$MSE = \frac{1}{n} \sum_{i=1}^n (T_i - O_i)^2 \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |T_i - O_i| \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{T_i - O_i}{T_i} \right| \times 100 \quad (11)$$

$$EI = \frac{\sum_{i=1}^n (T_i - \bar{T})^2 - \sum_{i=1}^n (T_i - O_i)^2}{\sum_{i=1}^n (T_i - \bar{T})^2} \times 100\% \quad (12)$$

เมื่อ

<i>MSE</i>	คือ	ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error)
<i>MAE</i>	คือ	ค่าความคลาดเคลื่อนสมบูรณ์เฉลี่ย (Mean Absolute Error)
<i>MAPE</i>	คือ	ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสมบูรณ์เฉลี่ย (Mean Absolute Percentage Error)
<i>EI</i>	คือ	ค่าดัชนีประสิทธิภาพ (Efficiency Index)
T_i	คือ	ค่าเป้าหมายสำหรับฝึกหัดลำดับที่ i
O_i	คือ	ค่าผลลัพธ์จากการทดสอบลำดับที่ i
$\bar{T}$	คือ	ค่าเฉลี่ยของค่าเป้าหมายสำหรับการฝึกหัด
n	คือ	จำนวนข้อมูลของผลลัพธ์

3.2 ตัวแบบที่ได้จากการฝึกหัดโดยใช้เทคนิคนิวโรฟซีแบบปรับตัวได้ (ANFIS) จากการทดลองจากฟังก์ชันความเป็นสมาชิกของอินพุต 8 ชนิดคือ ฟังก์ชัน trimf, trapmf, gbellmf, gaussmf, gauss2mf, pimgf, dsimgf และ psimgf โดยพิจารณาค่าความคลาดเคลื่อนของการเรียนรู้ที่มีค่าต่ำสุด ซึ่งจากการทดลองทำให้ได้ฟังก์ชันความเป็นสมาชิกของอินพุตชนิด gbellmf สำหรับสร้างเป็นตัวแบบครั้งนี้ โครงสร้างของตัวแบบ ANFIS ประกอบด้วย จำนวนโหนดในชั้นอินพุตมีจำนวน 3 โหนด จำนวนโหนดในชั้นที่ 1 ที่ได้จากการทดลองคือ (7 7 7) และจำนวนโหนดในชั้นผลลัพธ์มีจำนวน 1 โหนด โดยตัวแบบที่ได้กำหนดค่าต่าง ๆ ดังนี้ 1) เลือกใช้การเรียนรู้ในรูปแบบของอัลกอริทึมแบบไฮบริดจ์ (Hybrid) 2) การจัดกลุ่มข้อมูลใช้แบ่งแบบตาราง (Grid Partition) 3) ฟังก์ชันความเป็นสมาชิกด้านอินพุตใช้ฟังก์ชัน gbellmf ซึ่งได้จากการทดลอง 4) ฟังก์ชันความเป็นสมาชิกด้านเอาต์พุตใช้ฟังก์ชันเชิงเส้น 5) จำนวนรอบสำหรับฝึกหัดตัวแบบ 100 รอบ กับชุดข้อมูลฝึกหัดของทุกฟังก์ชัน กระทั่งมีค่าความคลาดเคลื่อนคงที่ และ 6) เลือกใช้ค่าความคลาดเคลื่อนที่เกิดขึ้นคำนวณในรูปของค่า MSE และวัดค่าประสิทธิภาพของตัวแบบคำนวณในรูปของค่า EI

3.3 ตัวแบบที่ได้จากการฝึกหัดโดยใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย (SMOreg) จากการทดลองกำหนดค่าพารามิเตอร์ในโปรแกรม Weka แล้วเลือกตัวแบบที่ให้ค่าความคลาดเคลื่อนน้อยที่สุด โดยตัวแบบที่ได้กำหนดค่าต่าง ๆ ดังนี้ 1) กำหนดค่า Complexity parameter C คือ 1.0 2) กำหนดค่า Kernel โดยค่า omega เป็น 0.1 และค่า sigma เป็น 1.0 3) เลือกกำหนดค่าขั้นตอนวิธีการเรียนรู้ (Learning Algorithm) โดยกำหนดค่า epsilon เท่ากับ 1.0E-12 ค่า epsilonParameter เท่ากับ 1.0E-5 ค่า tolerance เท่ากับ 1.0E-5 และค่า seed คือ 1

3.4 การทดสอบใช้ตัวแบบที่ได้จากวิธีที่นำเสนอทั้งสามตัวแบบมาทำการทดสอบกับชุดข้อมูลสำหรับทดสอบ โดยทำการแปลงค่าข้อมูลให้อยู่ในช่วงที่เหมาะสม และนำชุดข้อมูลสำหรับทดสอบเข้าสู่กระบวนการทดสอบด้วยตัวแบบที่ได้นำเสนอ โดยทำการทดสอบในแต่ละชุดข้อมูลสัญญาณแล้วทำการบันทึกผลลัพธ์ที่ได้เพื่อใช้สำหรับการวิเคราะห์อีกที


จากแนวคิดด้วยวิธีการเรียนรู้ในรูปแบบนี้ ทำให้ตัวแบบที่นำเสนอทั้งสามเทคนิคจากการเรียนรู้ และจัดจำรูปแบบของข้อมูลสัญญาณในหลายลักษณะข้อมูลสัญญาณ และในกระบวนการทดสอบจะทำให้ ตัวแบบสามารถแยกแยะได้ระหว่างข้อมูลสัญญาณดีกับข้อมูลสัญญาณเสีย โดยวัดจากค่าความคลาดเคลื่อน ที่ได้จากผลลัพธ์เปรียบเทียบกับค่าเป้าหมาย ซึ่งในการทดสอบจะทดสอบทีละ 1 ข้อมูลสัญญาณ ๆ ละ 58 เรคคอร์ด ในแต่ละตัวแบบที่ใช้สำหรับทดสอบ

ผลการวิจัย

จากผลการทดลองดังตารางที่ 2 เป็นตัวแบบที่ดีที่สุดในแต่ละวิธีในการทดลองครั้งนี้ เมื่อนำทั้งสามตัวแบบ มาเปรียบเทียบประสิทธิภาพของผลลัพธ์ที่ได้จากค่าความคลาดเคลื่อนที่เกิดขึ้นคำนวณในรูปแบบต่าง ๆ ทั้งสามตัวแบบมี ANN, SMOreg และ ANFIS โดยผลลัพธ์จากการฝึกหัดค่า MSE คือ $1.45\text{E-}08$, $5.60\text{E-}08$, $3.32\text{E-}09$ ตามลำดับ และผลลัพธ์จากการทดสอบค่า MSE คือ $8.30\text{E-}09$, $2.66\text{E-}07$, $3.21\text{E-}09$ และค่าร้อยละที่ได้จากค่าของ MAPE คือ 2.5807, 10.9384, 0.8061 ตามลำดับ เมื่อนำ ตัวแบบทั้งสามวิธีมาเปรียบเทียบผลลัพธ์ พบว่าตัวแบบ ANFIS มีประสิทธิภาพดีที่สุด โดยมีค่า ความผิดพลาดโดยรวมที่น้อยที่สุดกว่าตัวแบบอื่น ๆ และค่าร้อยละของ EI สูงที่สุด

ตารางที่ 2 ค่า MSE, MAE, MAPE และค่า EI ที่ได้จากการฝึกหัดทั้ง 3 ตัวแบบที่นำเสนอ

Algorithm	Training Data Set			Testing Data Set			
	MSE	MAE	MAPE	MSE	MAE	MAPE	EI (%)
ANN	$1.45\text{E-}08$	$8.28\text{E-}05$	2.99636	$8.30\text{E-}09$	$8.61\text{E-}05$	2.5807	99.999971
SMOreg	$5.60\text{E-}08$	$4.31\text{E-}05$	0.69080	$2.66\text{E-}07$	$3.32\text{E-}04$	10.9384	99.999419
ANFIS	$3.32\text{E-}09$	$3.20\text{E-}05$	0.83541	$3.21\text{E-}09$	$3.38\text{E-}05$	0.8061	99.999993



รูปที่ 9 ผลลัพธ์ของข้อมูลทดสอบที่ได้จากการทดสอบทั้งสามตัวแบบ

จากรูปที่ 9 แสดงกราฟที่ได้จากผลการทดสอบในแต่ละข้อมูลสัญญาณเปรียบเทียบประสิทธิภาพกับค่าเป้าหมายจริง (TG) จากกราฟข้อมูลสัญญาณดี เช่น ANN.G14 (คือตัวแบบ ANN ของข้อมูลสัญญาณดีที่ 14) จากทั้งสามตัวแบบจุดเส้นกราฟที่ได้จะทับกับเส้นกราฟค่าเป้าหมายไปในทิศทางเดียวกัน ส่วนเส้นกราฟสัญญาณที่มีปัญหาหรือเสีย เช่น ANN.B1 (คือตัวแบบ ANN ของข้อมูลสัญญาณเสียที่ 1) จากทั้งสามตัวแบบจุดเส้นกราฟที่ได้จะแตกต่างจากค่าเป้าหมายจริงมาก และผลจากการทดสอบดังตารางที่ 3 แสดงผลลัพธ์ที่ได้โดยวัดจากค่าความคลาดเคลื่อนต่าง ๆ ซึ่งจากการพิจารณาเปรียบเทียบตัวแบบทั้งสามวิธี โดยตัวแบบ ANFIS จะมีค่าความคลาดเคลื่อนโดยรวมน้อยที่สุด และค่าเฉลี่ยร้อยละความคลาดเคลื่อนสมบูรณ์ (MAPE) ของตัวแบบ ANFIS เมื่อพิจารณาจากชุดข้อมูลสัญญาณเสียสัญญาณที่ B5 กับ B7 เมื่อเทียบกับค่าของชุดสัญญาณดี (Gx) เป็นจำนวนเท่า ตัวแบบของ ANFIS ให้ค่าจำนวนเท่าต่างกันระหว่างข้อมูลสัญญาณเสียกับสัญญาณดีมากว่าตัวแบบอื่น

ตารางที่ 3 ค่าผลลัพธ์ที่ได้จากชุดข้อมูลทดสอบ ด้วยวิธีที่นำเสนอทั้ง 3 ตัวแบบ

Signal	ANN			ANFIS			SMOreg		
	MSE	MAE	MAPE	MSE	MAE	MAPE	MSE	MAE	MAPE
G1	8.30E-09	8.61E-05	2.5807	3.21E-09	3.38E-05	0.8061	2.66E-07	3.32E-04	10.9384
G2	9.04E-09	8.22E-05	3.6663	4.30E-09	3.45E-05	0.5021	9.12E-08	2.63E-04	10.9306
G3	7.07E-09	8.95E-05	2.8684	2.56E-09	3.05E-05	0.8849	9.11E-08	2.63E-04	10.9264
G4	7.55E-09	8.38E-05	2.9524	1.96E-09	2.76E-05	0.6402	1.11E-07	2.81E-04	10.9325
B1	6.38E-01	1.34E-01	4515.0338	2.60E-02	5.74E-02	337.0390	1.71E-02	6.25E-02	1167.4661
B2	7.40E-01	1.22E-01	4546.8742	2.99E-02	6.19E-02	270.7685	2.03E-02	6.44E-02	915.7077
B3	8.80E-01	1.30E-01	2931.1516	2.80E-02	5.85E-02	312.8957	2.02E-02	6.39E-02	873.4389
B4	5.54E-01	1.52E-01	5445.1132	2.57E-02	6.09E-02	364.4101	1.85E-02	6.38E-02	1211.6929
B5	6.49E-03	2.18E-02	53.9360	5.88E-03	1.70E-02	26.1026	5.40E-03	2.44E-02	93.9928
B6	7.95E-01	1.09E-01	4156.5641	4.00E-02	7.27E-02	267.5068	2.04E-02	6.45E-02	988.2082
B7	6.01E-03	2.07E-02	50.8847	5.64E-03	1.66E-02	25.6074	5.18E-03	2.38E-02	95.5285
G5	8.73E-09	8.43E-05	3.4033	3.97E-09	3.35E-05	1.4353	9.14E-08	2.63E-04	10.9319
G6	8.10E-09	7.01E-05	2.6451	2.75E-09	3.00E-05	0.5015	9.14E-08	2.63E-04	10.9330
G7	7.92E-09	8.38E-05	2.3637	2.04E-09	2.79E-05	0.8456	1.04E-07	2.76E-04	10.9292
G8	6.41E-09	8.29E-05	3.4909	4.77E-09	3.81E-05	1.0676	1.37E-07	3.09E-04	10.9374
G9	3.88E-08	1.40E-04	5.8569	4.41E-09	4.31E-05	1.3980	1.71E-07	3.28E-04	12.8331
G10	1.31E-07	1.95E-04	4.2932	1.62E-07	1.03E-04	1.5257	1.27E-06	3.28E-04	12.1389
G11	7.73E-09	1.14E-04	4.9224	3.84E-09	3.65E-05	1.1939	1.12E-07	2.84E-04	10.9312
G12	6.83E-08	1.32E-04	4.5826	9.31E-08	7.65E-05	1.0704	9.73E-07	4.81E-04	12.3673
G13	6.10E-08	1.47E-04	4.2078	6.01E-09	4.26E-05	1.4467	3.22E-07	3.61E-04	15.5093
G14	1.61E-07	2.65E-04	10.8271	1.65E-08	6.26E-05	0.8600	6.64E-07	4.94E-04	13.5705

อภิปรายผลและสรุป

งานวิจัยนี้ได้นำเสนอการเปรียบเทียบประสิทธิภาพของตัวแบบทั้งสามวิธี คือ ตัวแบบจากโครงข่ายประสาทเทียม ตัวแบบนิวโรฟัซซีโดยใช้เทคนิคแบบ ANFIS และตัวแบบซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย ในรูปแบบการจดจำที่ใช้สำหรับในการวิเคราะห์และแยกแยะระหว่างข้อมูลสัญญาณรูปคลื่นไฟฟ้า สัญญาณดีกับสัญญาณเสีย โดยหลักการในการสร้างตัวแบบที่นำเสนอแต่ละตัวในครั้งนี้ จะใช้ข้อมูลที่ผ่านมาผ่านกระบวนการแปลงฟูเรียร์แบบเร็วเป็นข้อมูลสำหรับใช้ในการกระบวนการฝึกหัดและทดสอบของตัวแบบทั้งสามวิธี เพื่อการหาตัวแบบที่ดีที่สุดสำหรับการวิเคราะห์ข้อมูลสัญญาณที่ใช้ในการทดลองครั้งนี้ ถึงแม้ว่าทั้งสามตัวแบบจะสามารถวิเคราะห์และแยกแยะระหว่างข้อมูลสัญญาณดีกับข้อมูลสัญญาณเสียได้ ทุกตัวอย่างถูกต้อง แต่เมื่อนำทั้งสามตัวแบบมาทำการเปรียบเทียบประสิทธิภาพ พบว่าตัวแบบที่ใช้เทคนิค ANFIS ให้ประสิทธิภาพโดยรวมดีที่สุด และแสดงถึงความสามารถในการเรียนรู้ถึงความสัมพันธ์ระหว่างข้อมูลนำเข้ากับผลลัพธ์ได้เป็นอย่างดี และผลการทดสอบสามารถแยกแยะระหว่างสัญญาณดีกับเสียได้ถูกต้อง ทุกข้อมูลสัญญาณ

อย่างไรก็ตามกรณีที่น่าสนใจตอนวิธีที่นำเสนอไปวิเคราะห์สัญญาณไฟฟ้าในรูปแบบต่าง ๆ อาจจะต้องกำหนดค่า หรือปรับค่าพารามิเตอร์ต่าง ๆ ตามความเหมาะสมของข้อมูลสัญญาณที่นำมาใช้ในการวิเคราะห์ในแต่ละงาน

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณบริษัท ซีเกท เทคโนโลยี (ประเทศไทย) จำกัด ที่อนุเคราะห์สถานที่และอุปกรณ์ในงานวิจัย

References

- [1] Kitti, A., Monthon, L., and Somchat, J. (2008). An Artificial Neural Networks Application for Harmonics Measurement in Power Systems. **The Journal of KMUTNB**. Vol. 18, No. 1, pp. 16-23
- [2] Pecharanin, N., Sone, M., and Mitsui, H. (1994). An Application of Neural Network for Harmonic Detection in Active Filter. **Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)**. Vol. 6, pp. 3756-3760. DOI: 10.1109/ICNN.1994.374807
- [3] Kittisak, K. and Somchat, J. (2010). The Use of Power Quality to Forecast Reliability in the PEA's Distribution System Using Artificial Neural Networks. **The Journal of KMUTNB**. Vol. 20, No. 1, pp. 55-63
- [4] Porramate, I. and Somchat, J. (2008). Application of Artificial Neural Network in Optimal Power Flow. **The Journal of KMUTNB**. Vol. 18, No. 2, pp. 14-23
- [5] Adisorn, K., Prajuab, I., and Wutthichai, S. (8-10 March 2017). Application of Adaptive Network-Based Fuzzy Inference System with Fast Fourier Transform for Waveform Analysis and Classification. **2017 International Electrical Engineering Congress (iEECON)**. 8-10 March 2017, Pattaya, Thailand. DOI: 10.1109/IEECON.2017.8075886

- [6] Apichit, K., Jirasak, C., and Surapan, Y. (2006). **Real Time ECG Compression/Decompression System with Multirate Digital Signal Processing**. Thesis of King Mongkut's University of Technology North Bangkok (Medical Instrumentation). pp. 6-7
- [7] Jos Arrillaga, Bruce C. Smith, Neville R. Watson, and Alan R. Wood. (1997). **Power System Harmonic Analysis**. John Wiley and Sons. pp. 7-31
- [8] Dech, T. and Phayung, M. (2011). Ensemble Data Classification Based on Decision Tree, Artificial Neuron Network and Support Vector Machine Optimized by Genetic Algorithm. **The Journal of KMUTNB**. Vol. 21, No. 2, pp. 293-303
- [9] Lin, H. C. (2004). Intelligent Neural Network Based Dynamic Power System Harmonic Analysis. **International Conference on Power System Technology, 2004. PowerCon 2004**. Vol. 1, pp. 244-248. DOI: 10.1109/ICPST.2004.1460000
- [10] R. Rojas. (1996). **Neural Network: A Systematic Introduction**. Springer. Berlin: Springer-Verlag Berlin Heidelberg.
- [11] Narimol, S. and Somchat, J. (2006). Short-term Load Forecast using Artificial Neural Networks. **The Journal of KMUTNB**. Vol. 16, No. 2, pp. 37-42
- [12] Chanwit, T. and Sirivit, T. (2013). Fault Detection and Protection of Induction Motor Using Artificial Neural Network. **The Journal of KMUTNB**. Vol. 23, No. 1, pp. 42-51
- [13] Adisorn, K., Panida, L., and Ariya, N. (2015). An Artificial Neural Network with Technical Indicators for Stock Investment: Application to the Stock Exchange of Thailand. **Information Technology Journal**. Vol. 11, No. 1, pp. 53-63
- [14] J.-S.R. Jang and Chuen-Tsai Sun. (1995). Neuro-Fuzzy Modeling and Control. **Proceedings of the IEEE**. Vol. 83, Issue 3, pp. 378-406. DOI: 10.1109/5.364486
- [15] Nunthakorn, C., Panida, L., and Ariya, N. (2015). A Neuro-Fuzzy with DCA and VA for Stock Investment: Application to the Stock Exchange of Thailand. **Information Technology Journal**. Vol. 11, No. 1, pp. 64-73
- [16] Shevada, S. K., Keerthi, S. S., Bhattacharyya, C., and Murthy, K. R. K. (2000). Improvements to the SMO Algorithm for SVM regression. **IEEE Transactions on Neural Networks**. Vol. 11, NO. 5, pp. 1188-1193. DOI: 10.1109/72.870050