

การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 24
20-22 ตุลาคม 2553 จังหวัดอุบลราชธานี

การจำแนกสัญญาณการสั่นสะเทือนของคอมเพรสเซอร์แบบลูกสูบอัดอากาศสองชั้น ด้วยโครงข่ายประสาทเทียม

Classification Vibration Signals of a Two-Stage Reciprocating Compressor using Artificial Neural Network

กิตติศักดิ์ สุดดวง, สมศักดิ์ เพ็ชรกุล และ พรชัย นิเวศน์รังสรรค์*

ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีมหานคร
51 ถนนเชื่อมสัมพันธ์ เขตหนองจอก กรุงเทพมหานคร 10530
*ผู้ติดต่อ: E-mail nporncha@mut.ac.th, โทรศัพท์/โทรสาร: 0-2988-3666 ต่อ 3110

บทคัดย่อ

การตรวจสอบสถานะของคอมเพรสเซอร์มีการศึกษาโดยใช้สัญญาณต่างๆ เช่น สัญญาณการสั่นสะเทือน สัญญาณเสียง หรือสัญญาณความดัน โดยสัญญาณที่ตรวจวัดจะเกี่ยวข้องกับกระบวนการทางกลและของไหลที่เกิดขึ้นในวัฏจักรการทำงานของคอมเพรสเซอร์ สำหรับการศึกษาที่คอมเพรสเซอร์แบบลูกสูบอัดอากาศสองชั้นจะถูกใช้จำลองการทำงานที่เงื่อนไขต่างๆ เช่น การทำงานปกติ ความเสียหายที่แผ่นวาล์วด้านดูดทางด้านห้องความดันต่ำ ความเสียหายที่แผ่นวาล์วด้านส่งทางด้านห้องความดันสูง ความเสียหายทั้งแผ่นวาล์วด้านดูด (ห้องความดันต่ำ) และ แผ่นวาล์วด้านส่ง (ห้องความดันสูง) โดยใช้สัญญาณการสั่นสะเทือนที่ตรวจวัดได้จากหัววัดการสั่นสะเทือนซึ่งติดตั้งอยู่ที่ฝาสูบของคอมเพรสเซอร์ พร้อมทั้งวัดรอบการทำงานด้วย Proximity ข้อมูลที่ตรวจวัดได้จะนำมาจำแนกประเภทด้วยโครงข่ายประสาทเทียมโดยข้อมูลจะถูกจำแนกออกเป็น 2 ประเภทคือ ปกติ (Normal) และผิดปกติ (Abnormal) ผลการทดลองแสดงให้เห็นว่าโครงข่ายประสาทเทียมมีประสิทธิภาพในการจำแนกประเภทข้อมูลเท่ากับ 97.22 เปอร์เซ็นต์

คำหลัก: โครงข่ายประสาทเทียม การจำแนก คอมเพรสเซอร์

Abstract

Condition monitoring of compressors has been studied by using various signals such as vibration, sound or pressure signals. These detected signals associate with mechanical and fluid flow processes in the compressor cycle and can be used for fault monitoring in a compressor. In this study, the two-stage reciprocating compressor was used to demonstrate various conditions e.g. normal, suction valve of low pressure damage, discharge valve of high pressure damage, suction valve of low pressure and discharge valve of high pressure damage conditions with vibration signal detected from vibration sensors attached on the cylinder head of the two-stage compressor. In addition, a proximity sensor was used to measure rotational speed of compressor. This detected data set to classification using artificial neural network were

the classified, consisting two classes there were normal class and abnormal class. Experimental results show that the classification data set performance artificial neural network is 97.22 %.

Keywords: Artificial Neural Network, Classification, Compressor.

1. บทนำ

ปัจจุบันการตรวจสอบสภาวะการทำงานของคอมเพรสเซอร์มีความจำเป็นสำหรับอุตสาหกรรมเพื่อให้คอมเพรสเซอร์ทำงานได้เต็มความสามารถและเป็นการป้องกันความเสียหายรุนแรงที่อาจเกิดขึ้น การทำงานของคอมเพรสเซอร์จะเกี่ยวข้องกับกระบวนการทางกลและทางของไหลที่สอดคล้องกับวัฏจักรการทำงานของคอมเพรสเซอร์ [1-3] เช่น การเปิดหรือปิดของวาล์วทางด้านดูดและด้านส่ง การเคลื่อนที่ของลูกสูบ การหมุนของเพลารภายในห้องอัด และการอัดตัวของอากาศในห้องอัด เป็นต้น งานวิจัยที่ผ่านมาได้มีการใช้เซนเซอร์ชนิดต่าง ๆ เพื่อตรวจวัดสัญญาณจากคอมเพรสเซอร์ เช่น กระแสไฟฟ้า ความดัน การสั่นสะเทือน เสียง อุณหภูมิแก๊ส เป็นต้น โดยได้ทำการศึกษาที่คอมเพรสเซอร์ชนิดต่าง ๆ เช่น คอมเพรสเซอร์แบบลูกสูบ [1-3] และ แบบสกรู [4-5]

การจำแนกความเสียหายหรือจากการทำงานผิดพลาดของเครื่องจักรกลจำเป็นต้องมีความรู้ความเชี่ยวชาญและประสบการณ์เพราะว่าสาเหตุและผลที่ได้มีความซับซ้อนมาก การบ่งชี้ความสัมพันธ์ระหว่างสาเหตุและลักษณะของการเสียหายต้องเป็นไปตามขั้นตอนการวิเคราะห์แบบอัตโนมัติ งานวิจัยส่วนใหญ่ได้นำไปสู่กระบวนการสร้างขั้นตอนสำหรับวิเคราะห์ความเสียหายเหล่านี้และได้มีการพัฒนาโครงข่ายประสาทเทียมซึ่งเป็นเครื่องมือสำหรับการจำแนกความเสียหายที่เงื่อนไขต่างๆ ของเครื่องจักรกล [6-7] การนำไปประยุกต์ใช้กับปัญหาของการจำแนกเงื่อนไขของเครื่องจักรจะเห็นได้จาก [6] โดยทั่วไปโครงข่ายประสาทเทียมมีความสามารถในการเรียนรู้จากข้อมูลที่สภาวะปกติและสภาวะที่เกิดการเสียหายที่ผ่านมามีในอดีตซึ่งข้อมูลเหล่านี้สามารถเก็บและนำไปใช้ในลำดับถัดไป ข้อดีของโครงข่ายประสาทเทียมนั้นก็คือสามารถเรียนรู้สภาวะของเครื่องจักรและบ่งชี้ข้อมูล

เหล่านั้นโดยไม่จำเป็นต้องเข้าใจรายละเอียดทางไดนามิกของเครื่องจักร

การศึกษาประกอบด้วย การจำลองการทำงานที่เงื่อนไขแตกต่างกัน เช่น การทำงานปกติ การเสียหายที่วาล์วด้านดูดและวาล์วด้านส่งซึ่งจะแสดงรายละเอียดไว้ในหัวข้อถัดไป การวิเคราะห์ผลทางสถิติเพื่อหาค่าพารามิเตอร์ที่ให้ผลการจำแนกข้อมูลที่ดีที่สุด การสร้างโครงข่ายประสาทเทียมเพื่อจำแนกข้อมูลจากคอมเพรสเซอร์ และการหาค่าประสิทธิภาพในการจำแนกข้อมูลที่ได้จากโครงข่ายประสาทเทียม

2. โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมหรือ Artificial Neural Networks (ANNs) เป็นศาสตร์อีกด้านหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligences) และเป็นแบบจำลองทางคณิตศาสตร์ที่มีวัตถุประสงค์เพื่อจำลองการทำงานของเซลล์ประสาท โดยมีสมมติฐานหลักว่า คอมพิวเตอร์สามารถคิดวิเคราะห์ได้เองเมื่อได้มีการเรียนรู้ข้อมูลชุดหนึ่งแล้วสามารถจดจำและประมวลผลข้อมูลแบบเดียวกันที่ไม่เคยพบเห็นมาก่อนได้ เหมือนกับสิ่งมีชีวิตในแต่ละเซลล์ประสาท (Neuron) ที่จำลองจะมีตัวแบบ (Model) ดังรูปที่ 1

จากรูปที่ 1 ข้อมูลอินพุต x_j ถูกส่งเข้ามาที่ Neural k ซึ่งข้อมูลแต่ละตัวของ x_j จะถูกคูณด้วยค่าน้ำหนัก w_{kj} และรวมกันเป็นค่ากระตุ้นของ Neural k ตามสมการที่ (1)

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (1)$$


เมื่อ $x_1, x_2, \dots, x_m$ คือ ข้อมูลอินพุต $w_{k1}, w_{k2}, \dots, w_{km}$ คือ ค่าน้ำหนักของ Neural k b_k คือ ค่าไบแอส และ y_k คือ ผลลัพธ์ของโครงข่าย ดังนั้นค่ากระตุ้น (induced local field) v_k จะถูกตัดสินโดยฟังก์ชันกระตุ้น, (Activation function) $\varphi(\cdot)$ ตามสมการที่ (2)

$$y_k = \phi(v_k) \quad (2)$$

โดยที่

$$\phi(v_k) = \frac{1}{1 + \exp(-av_k)} \quad (3)$$

เมื่อ $\phi(v_k)$ คือ ฟังก์ชันซิกมอยด์ (Sigmoid Function) และ a คือ ความชันของฟังก์ชันซิกมอยด์



รูปที่ 1 โครงสร้างของ Neural Node

2.1 โครงข่ายประสาทเทียมเปอร์เซ็ปตรอนแบบหลายชั้น (Multilayer Perceptron Network)


โครงข่ายประสาทเทียมสามารถมีได้หลายชั้นและในแต่ละชั้นประกอบด้วยหน่วยประมวลผลที่อาจมีได้มากกว่าหนึ่งตัวดังรูปที่ 2 ชั้นแรกเป็นชั้นรับข้อมูล (Input layer) ประกอบด้วยหน่วยรับข้อมูล (Input nodes) ทำหน้าที่รับข้อมูลเข้าเท่านั้นและจะไม่มีการคำนวณ ชั้นกลางเป็นชั้นซ่อน (Hidden layer) ซึ่งอยู่ถัดจากชั้นรับข้อมูลจนถึงก่อนชั้นแสดงผล ชั้นซ่อนนี้อาจมีได้มากกว่าหนึ่งชั้นแต่ละชั้นประกอบด้วย Neural จำนวนมากทำหน้าที่แปลงข้อมูลที่เข้ามาให้สามารถแยกออกจากกันได้แบบเชิงเส้น ก่อนที่จะส่งออกไปที่ชั้นแสดงผลซึ่งอาจต้องใช้ชั้นซ่อนมากกว่าหนึ่งชั้นในการแปลงข้อมูล และชั้นสุดท้ายคือชั้นแสดงผล (Output layer) เป็นชั้นที่ใช้แสดงผลลัพธ์จากการคำนวณของโครงข่ายประสาทเทียมเปอร์เซ็ปตรอนแบบหลายชั้น

(Multilayer Perceptron, MLP) ไม่สามารถเรียนรู้เพียงครั้งเดียวแล้วสามารถให้คำตอบได้ถูกต้อง ดังนั้นการที่จะทำให้ผลลัพธ์ออกมาได้ถูกต้องมากที่สุดจะต้องทำการเรียนรู้หลายๆ รอบ และให้ค่าความ

ผิดพลาดในแต่ละรอบนั้นลดลงเรื่อยๆ จนถึงจุดๆ หนึ่งที่เป็นที่ยอมรับของการทดลอง การคำนวณค่าความผิดพลาดนั้นสามารถคำนวณได้จากสูตรการหา MSE (Mean Square Error) ดังนี้

$$MSE = \frac{1}{2N} \left[\sum_{j=1}^N (d_j - y_j)^2 \right] \quad (4)$$

เมื่อ N คือ จำนวนข้อมูล d_j คือ ค่าเป้าหมาย และ y_j คือ ผลลัพธ์ของโครงข่าย ในการที่จะให้ได้ค่า MSE ต่ำๆ ก็จะต้องหาค่าน้ำหนักที่เหมาะสมให้แก่โครงข่ายประสาทเทียม



รูปที่ 2 โครงข่ายประสาทเทียมเปอร์เซ็ปตรอนแบบหลายชั้น

อัลกอริทึมของการเรียนรู้สำหรับโครงข่ายที่ใช้เป็นอัลกอริทึมแบบการแพร่กระจายค่าย้อนกลับ (Back propagation algorithm) เทคนิคที่ใช้โดยเฉพาะก็คือการเคลื่อนต่ำลง (Gradient Descent Method) ในช่วงค่าน้ำหนัก ซึ่งการเคลื่อนต่ำลงของผลรวมค่าความคลาดเคลื่อนกำลังสองที่เกี่ยวข้องกับค่าน้ำหนักที่มีการประมาณค่าโดยการแพร่กระจายค่าย้อนกลับของค่าความคลาดเคลื่อนในโครงข่าย นอกจากนี้ข้อมูลผลลัพธ์ของโครงข่ายประสาทเทียมเป็นสิ่งที่ซับซ้อนที่ไม่สามารถอธิบายได้ด้วยแบบจำลองทางคณิตศาสตร์ทั่วไป ดังนั้นจึงเป็นเหตุผลของการเรียนรู้แบบซ้ำสำหรับชุดข้อมูลที่ใช้ฝึกสอนเพื่อที่จะหาค่าที่เหมาะสมแต่ปัญหาก็คือการหาค่าต่ำที่สุดของค่าต่ำที่สุดทั้งหมด

(Global minimum) ของผลรวมของค่าความคลาดเคลื่อนกำลังสองแต่โดยทั่วไปจะอยู่ในลักษณะที่ไม่เป็นเชิงเส้นของความสัมพันธ์ของข้อมูลป้อนเข้ากับข้อมูลส่งออก ทำให้มีความเป็นไปได้ที่โครงข่ายหนึ่งสามารถเกิดความสัมพันธ์ที่แตกต่างกันจำนวนมาก

2.2. การแพร่กระจายค่าย้อนกลับ

การฝึกสอนโครงข่ายประสาทเทียม MLP โดยใช้วิธีการแพร่กระจายค่าย้อนกลับ (Back propagation) เป็นการฝึกสอนแบบมีการกำกับดูแล (Supervised training) คือจะต้องมีการเตรียมคำตอบที่ต้องการไว้ให้โครงข่ายเพื่อใช้ในการปรับตัว วิธีการนี้แบ่งออกเป็น 2 ส่วนคือ ส่วนส่งผ่านข้อมูลไปด้านหน้า (Forward pass) และส่วนแพร่กระจายค่าย้อนกลับ (Backward pass) ในการฝึกสอนนั้นจะกระทำทั้ง forward และ backward สลับกันไปจนค่าความผิดพลาดที่ได้จากการฝึกสอนมีค่าน้อยกว่าหรือเท่ากับค่าที่ต้องการ

ขั้นตอนในการฝึกสอนโครงข่ายประสาทเทียมขนาด L ชั้น มีดังนี้

1. กำหนดค่าน้ำหนัก $w_{ji}(n)$ และค่าไบแอส $b_j(n)$ เริ่มต้น

2. ป้อนข้อมูลอินพุตและกำหนดค่าเป้าหมายที่ต้องการ ($x(n), d(n)$) เมื่อ $x(n)$ คือ ข้อมูลอินพุตที่ป้อนให้กับชั้นรับข้อมูล $d(n)$ คือ ค่าเป้าหมายที่ป้อนให้กับชั้นผลลัพธ์

3. การคำนวณค่าการส่งผ่านข้อมูลไปด้านหน้า

คำนวณค่ากระตุ้นและ Function signal ของโครงข่ายตามขั้นตอนการส่งผ่านข้อมูลไปด้านหน้าในแต่ละชั้นตามลำดับตลอดโครงข่าย ดังนั้นค่ากระตุ้น $v_j^l(n)$ สำหรับ Neural j ในชั้น l คือ

$$v_j^l(n) = \sum w_{ji}^l(n) y_i^{l-1}(n) \quad (5)$$

เมื่อ $y_i^{l-1}(n)$ คือ สัญญาณผลลัพธ์ (function) ของ Neural i ในชั้นก่อนหน้า $l-1$ ที่การวนซ้ำที่ n และ $w_{ji}^l(n)$ คือ ค่าน้ำหนักของ Neural j ในชั้น l ที่ป้อนจาก Neural i ในชั้น $l-1$ สำหรับ $i=0$ จะได้ $y_0^{(l-1)}(n) = +1$ และ $w_{j0}^l(n) = b_j^l(n)$ คือ ไบแอส ที่

ใช้กับ Neural j ในชั้น l ดังนั้นสัญญาณผลลัพธ์ของ Neural j ในชั้น l คือ

$$y_j^l = \phi_j(v_j^l(n))$$

ถ้า Neural j อยู่ในชั้นซ่อนที่หนึ่ง ($l=1$) กำหนดให้

$$y_j^0(n) = x_j(n)$$

เมื่อ $x_j(n)$ คือ ข้อมูลลำดับที่ j ของข้อมูลอินพุต $x(n)$ ถ้า Neural j อยู่ในชั้นแสดงผล ($l=L$, เมื่อ L คือความลึก (depth) ของโครงข่าย) กำหนดให้

$$y_j^L = o_j(n)$$

ค่าความผิดพลาดคำนวณได้จาก

$$e_j(n) = d_j(n) - o_j(n) \quad (6)$$

เมื่อ $d_j(n)$ คือข้อมูลลำดับที่ j ค่าเป้าหมาย $d(n)$

4. การคำนวณการแพร่กระจายค่าย้อนกลับ

คำนวณค่า Local gradient, δ ของโครงข่าย กำหนดโดย

$$\delta_j^{(l)}(n) = e_j^L(n) \phi_j'(v_j^L(n)) \quad (7)$$

สมการที่ (7) สำหรับ Neural j อยู่ในชั้นแสดงผล L

$$\delta_j^{(l)}(n) = \phi_j'(v_j^l(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad (8)$$

สมการที่ (8) สำหรับ Neural j อยู่ในชั้นซ่อน l

การปรับค่าน้ำหนักของโครงข่ายในชั้น l สอดคล้องกับ Generalized delta rule

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (9)$$

เมื่อ η คือ อัตราการเรียนรู้ และ α คือ โมเมนตัม

5. ย้อนกลับไปทำขั้นตอนที่ 3 และ 4 จนกว่าค่าความผิดพลาดอยู่ในช่วงที่ยอมรับได้หรือครบจำนวนรอบของการฝึกสอนตามที่กำหนดไว้


3. กระบวนการวิจัย

3.1. การเก็บบันทึกผลข้อมูล

การจำลองสภาวะการทำงานของคอมเพรสเซอร์แบบสองลูกสูบมีข้อกำหนดดังนี้ คอมเพรสเซอร์แบบลูกสูบที่สามารถอัดอากาศได้สองชั้น ที่มีต้นกำลังเป็นมอเตอร์ 3 เฟส 50 Hz ทำงานที่ความเร็วรอบสูงสุด 1420 rpm ใช้สำหรับขับเคลื่อนคอมเพรสเซอร์ ส่วนความเร็วรอบของคอมเพรสเซอร์ควบคุมด้วยอินเวอร์เตอร์ (Inverter) เงื่อนไขการทดลองสำหรับการจำลอง

สภาวะการทำงานของคอมเพรสเซอร์แบบลูกสูบมีรายละเอียดดังนี้คือ

- การทำงานที่สภาวะปกติ
- การจำลองความเสียหายที่แผ่นวาล์วด้านดูดทางด้านห้องความดันต่ำ
- การจำลองความเสียหายที่แผ่นวาล์วด้านส่งทางด้านห้องความดันสูง
- การจำลองความเสียหายทั้งแผ่นวาล์วด้านดูด (ห้องความดันต่ำ) และแผ่นวาล์วด้านส่ง (ห้องความดันสูง)



รูปที่ 3 โครงสร้างและชิ้นส่วนของคอมเพรสเซอร์แบบลูกสูบอัดสองชั้น

ตำแหน่งติดตั้งของหัววัดการสั่นสะเทือนอยู่ที่ด้านบนของกระบอกสูบคอมเพรสเซอร์ ส่วน Proximity sensor จะติดตั้งที่ปลายของคอมเพรสเซอร์ ซึ่งกำหนดตำแหน่งอ้างอิงของศูนย์ตายบนของลูกสูบความดันต่ำไว้และโครงสร้างและชิ้นส่วนต่างๆ ของคอมเพรสเซอร์แบบลูกสูบอัดอากาศสองชั้นแสดงดังรูปที่ 3 สัญญาณการสั่นสะเทือนและสัญญาณอ้างอิงของมุมเพลอาซอเหวี่ยงจะถูกบันทึกที่แต่ละเงื่อนไขของการจำลอง สัญญาณทั้งสองจะถูกบันทึกพร้อมกันด้วยโปรแกรม LabVIEW และจะถูกเก็บเป็นไฟล์เพื่อนำไปใช้ในการวิเคราะห์ผลต่อไป ทั้งนี้การทดลองจะใช้ความถี่ 50 kHz และข้อมูลที่บันทึกเท่ากับ 50000 จุด เพื่อให้สะดวกต่อการวิเคราะห์ผลการทดลอง


ข้อมูลที่ใช้ในการทดลองมีทั้งหมด 160 วิวัจกรการทำงาน แบ่งออกเป็น 4 ประเภท คือ 1.ข้อมูลที่สภาวะปกติ 2.ข้อมูลความเสียหายที่แผ่นวาล์วด้านดูด

ทางด้านห้องความดันต่ำ 3.ความเสียหายที่แผ่นวาล์วด้านส่งทางด้านห้องความดันสูง 4.การจำลองความเสียหายทั้งแผ่นวาล์วด้านดูด (ห้องความดันต่ำ) และแผ่นวาล์วด้านส่ง (ห้องความดันสูง) แต่ในการทดลองได้แบ่งข้อมูลออกเป็น 2 ประเภท คือ ปกติ (ประเภทที่ 1) จำนวน 40 วิวัจกร ผิดปกติ (ประเภทที่ 2-4) จำนวน 120 วิวัจกร รวมทั้งหมด 160 วิวัจกร ซึ่งแต่ละวิวัจกรจะมีองค์ประกอบของคุณลักษณะข้อมูลทั้งหมด 6 คุณลักษณะ ได้แก่ ค่าพารามิเตอร์ทางสถิติซึ่งประกอบด้วย ค่าความโด่ง (Kurtosis) ค่า Crest factor ค่าความเบ้ (Skewness) ค่ารากกำลังสองเฉลี่ย (Root mean square, RMS) ค่าเบี่ยงเบนมาตรฐาน (Standard deviation) และ ค่าความแปรปรวน (Variance) ค่าพารามิเตอร์ทางสถิติดังกล่าวไม่สามารถทำนายความเสียหายได้โดยใช้แต่ละค่าพารามิเตอร์ [8] ก่อนที่จะนำข้อมูลเหล่านี้ไปทำการทดลองได้ทำการปรับค่าข้อมูลให้อยู่ในช่วงเดียวกัน (Normalize) ก่อนดังสมการ

$$\text{data} = \frac{\text{data} - \text{Min}}{\text{Max} - \text{Min}} \quad (10)$$

เมื่อ data คือ ค่าข้อมูลคุณลักษณะของวิวัจกรแต่ละค่า ส่วน Min และ Max คือ ค่าข้อมูลที่มีค่าน้อยที่สุดและมากที่สุดในแต่ละคุณลักษณะทั้ง 6 ประการตามลำดับ สัดส่วนข้อมูลที่ใช้สำหรับการทดลองแบ่งออกเป็นข้อมูลสำหรับการฝึกสอน (Train) 70 เปอร์เซ็นต์ และข้อมูลสำหรับการทดสอบ (Test) 30 เปอร์เซ็นต์ โดยจะแบ่งข้อมูลแต่ละประเภทให้มีสัดส่วนเท่าๆ กัน การกระจายตัวของข้อมูลทั้ง 4 กลุ่มแสดงดังรูปที่ 4 ซึ่งใช้วิธีการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) แปลงข้อมูลหลายมิติให้เหลือ 3 มิติ โดยการฉายภาพข้อมูลเดิมผ่านระบบเชิงเส้นที่เกิดจาก Eigen Vector ที่สัมพันธ์กับ Eigen Value ที่มีนัยสำคัญสูงสุด 3 อันดับแรก จากรูปจะเห็นว่าข้อมูลประเภทที่ 1 2 และ 3 มีการซ้อนทับกันอยู่อย่างชัดเจน ทำให้การจำแนกข้อมูลที่ปกติและผิดปกติให้ถูกต้องทั้งหมดนั้นเป็นไปได้ยากและไม่

สามารถแยกด้วยระบบเชิงเส้นได้ (Non-Linearly Separable Problem)



รูปที่ 4 การกระจายตัวของข้อมูลของคอมเพรสเซอร์แบบลูกสูบ เมื่อทำการลดเหลือ 3 มิติ ด้วย PCA

3.2. ตัวแบบโครงข่ายประสาทเทียม

เนื่องจากปัญหามีความซับซ้อนและไม่สามารถจำแนกข้อมูลด้วยตัวแบบที่ทำงานเป็นระบบเชิงเส้นได้ ทั้งนี้การกำหนดโครงสร้างของโครงข่ายประสาทเทียมที่ใช้สำหรับการทดลองนั้นได้พิจารณาถึงประสิทธิภาพของการจำแนกเพื่อที่จะให้ผลลัพธ์ของการจำแนกมีความถูกต้องมากที่สุด ดังนั้นในการทดลองจึงเริ่มต้นด้วยการทดลองเพื่อหาจำนวน Neural ในชั้นซ่อน (m_1) โดยเริ่มต้นจาก 2 Neural บรรทัดฐานที่ใช้คือจำนวน Neural ในชั้นซ่อนน้อยที่สุดที่ให้ประสิทธิภาพการจำแนกที่ดีที่สุด ตารางที่ 1 แสดงพารามิเตอร์ต่างๆ ของ MLP เพื่อใช้ในการหาจำนวน Neural ในชั้นซ่อนที่ฝึกสอนด้วยอัลกอริธึมการแพร่กระจายค่าย้อนกลับ

ตารางที่ 1 การเปลี่ยนแปลงพารามิเตอร์ของ Multilayer Perceptron

พารามิเตอร์	สัญลักษณ์	ช่วง
จำนวน Neural ในชั้นซ่อน	m_1	$(2, \infty)$
อัตราการเรียนรู้	η	$(0,1)$
โมเมนตัม	α	$(0,1)$

3.3. การทดลอง

การทดลองเริ่มจากการแบ่งข้อมูลออกเป็น 70:30

(ข้อมูลสำหรับการฝึกสอน 70 เปอร์เซ็นต์ และข้อมูลสำหรับการทดสอบ 30 เปอร์เซ็นต์) จากนั้นทำการทดลองกับข้อมูลโดยแต่ละโครงสร้างของโครงข่ายประสาทเทียมจะทำการทดลองทั้งหมด 5 ครั้งเพื่อหาค่าเฉลี่ยพร้อมทั้งวัดประสิทธิภาพการจำแนกประเภทโดยสูตรที่ใช้ในการหาประสิทธิภาพความแม่นยำในการจำแนกประเภทของข้อมูลคือ

$$\text{ประสิทธิภาพการจำแนก} = \frac{\text{True classify}}{\text{Total data}} \times 100 \quad (11)$$

เมื่อ True classify คือ จำนวนข้อมูลที่จำแนกประเภทได้ถูกต้อง และ Total data คือ จำนวนข้อมูลทั้งหมดที่ใช้ทดสอบ สำหรับจำนวนรอบของการเรียนรู้ของโครงข่ายประสาทเทียมกำหนดให้มีจำนวนรอบมากที่สุดได้ถึง 100,000 รอบ ซึ่งโครงข่ายประสาทเทียมที่เรียนรู้ได้เร็วอาจได้ผลลัพธ์ก่อน 100,000 รอบ แต่บางโครงข่ายประสาทเทียมก็อาจใช้จำนวนรอบในการเรียนรู้มากกว่านี้ก็ได้ ทั้งนี้ขึ้นอยู่กับตำแหน่งของค่าน้ำหนักเริ่มต้นและจำนวนของค่าน้ำหนักที่สามารถปรับตัวได้ในแต่ละโครงข่าย ถ้าค่าน้ำหนักเริ่มต้นมีค่าใกล้เคียงกับคำตอบก็จะใช้จำนวนรอบในการหาคำตอบน้อย แต่สำหรับโครงข่ายที่มีจำนวนของค่าน้ำหนักมากกว่าโดยส่วนใหญ่แล้วจะใช้จำนวนรอบน้อยกว่าโครงข่ายที่มีจำนวนของค่าน้ำหนักน้อยๆ แต่ถ้ามีมากเกินไปก็จะส่งผลให้โครงข่ายเกิดการจดจำข้อมูลที่เรียนรู้มากเกินไปจนทำให้เกิดผลเสียเมื่อนำไปใช้งานกับชุดข้อมูลที่เป็นชุดทดสอบซึ่งโครงข่ายไม่เคยเห็นมาก่อน จะพบว่าในกรณีเช่นนี้โครงข่ายจะให้ค่าประสิทธิภาพการจำแนกของชุดข้อมูลเรียนรู้อ่อนข้างสูงแต่จะให้ค่าประสิทธิภาพการจำแนกของชุดข้อมูลทดสอบอ่อนข้างต่ำ

4. ผลการทดลอง

โครงสร้างของโครงข่ายประสาทเทียมที่นำมาใช้ในการทดลอง คือ $6 - m_1 - 2$ เมื่อ m_1 คือ จำนวน Neural ในชั้นซ่อนซึ่งมีค่าเริ่มต้นตั้งแต่ 2 Neural ดังนั้นในการทดลองจึงเริ่มต้นด้วยจำนวน Neural ในชั้นซ่อนเท่ากับ 2 และผลการทดลองแสดงดังตารางที่ 2 โดยกำหนดให้อัตราการเรียนรู้ (η) = 0.1 และ โมเมนตัม

$(\alpha) = 0$ จากตารางที่ 2 จะเห็นได้ว่าประสิทธิภาพในการจำแนกประเภทข้อมูลคอมพิวเตอร์ด้วยโครงข่ายประสาทเทียม พบว่าโครงข่ายที่มีประสิทธิภาพในการจำแนกข้อมูลโดยเฉลี่ยมากที่สุดโดยให้ค่าสูงที่สุด 96.38 เปอร์เซนต์ เมื่อมีจำนวน Neural ในชั้นซ่อนเท่ากับ 18 Neural และเมื่อเพิ่มจำนวน Neural ในชั้นซ่อนก็ไม่ได้มีแนวโน้มว่าประสิทธิภาพการจำแนกจะดีขึ้น อีกทั้งเมื่อพิจารณาค่า MSE ก็ให้ค่าที่น้อย แต่ทั้งนี้ค่า MSE น้อยๆ ไม่ได้หมายความว่า เป็นการวางนัยโดยทั่วไปที่ดี (good generalization) เพียงแต่ว่าโครงข่ายจะให้ประสิทธิภาพการจำแนกที่ดีด้วยข้อมูลที่ไม่เคยเห็นมาก่อน ดังนั้นจึงได้เลือกจำนวน Neural ในชั้นซ่อนเท่ากับ 18 Neural


การใช้ MLP ซึ่งจำนวน Neural ในชั้นซ่อนเท่ากับ 18 Neural ร่วมกับการปรับค่าอัตราการเรียนรู้

ตารางที่ 2 ผลการทดสอบความแม่นยำเฉลี่ยในการจำแนกประเภทข้อมูลสำหรับเปอร์เซปตรอนแบบหลายชั้น


Number of Hidden Neuron	Number of Epochs	Mean Square Error	Correct Classification (%)
2	3,942	0.0573	88.88
3	2,820	0.0627	89.16
4	2,405	0.0503	92.49
5	2,951	0.0641	89.16
6	12,151	0.0262	93.88
7	14,071	0.0273	94.44
8	2,673	0.0653	91.10
9	12,436	0.0253	94.99
10	16,010	0.0177	95.55
11	12,530	0.0289	94.16
12	7,158	0.0326	94.44
13	8,989	0.0217	94.71
14	7,811	0.0289	94.16
15	10,004	0.0427	91.66
16	12,147	0.0266	94.71
17	6,137	0.0335	94.44
18	11,481	0.0202	96.38
19	10,773	0.0207	95.55
20	9,326	0.0289	93.88

$\eta \in \{0.01, 0.1, 0.5, 0.9\}$ และค่าโมเมนตัม $\alpha \in \{0.0, 0.1, 0.5, 0.9\}$ โดยพิจารณาจากประสิทธิภาพการจำแนก ผลการลู่เข้าของโครงข่ายและค่า MSE เพื่อให้ได้โครงข่ายประสาทเทียมที่ดีที่สุดและผลแสดงดังรูปที่ 5-1 ถึง 5-4 ซึ่งแต่ละรูปจะถูกแบ่งออกเป็นกลุ่มด้วยค่าอัตราการเรียนรู้ (η) ผลการทดลองกราฟแสดงการเรียนรู้สามารถสรุปได้ดังนี้


- เมื่อ η มีค่าต่ำ กราฟจะลู่เข้าช้ากว่ากราฟที่มี η สูง
- สำหรับ $\eta \rightarrow 0$ และ $\alpha \rightarrow 1$ จะเป็นการเพิ่มความเร็วในการลู่เข้า ในทางกลับกัน สำหรับ $\eta \rightarrow 1$ และ $\alpha \rightarrow 0$ กราฟจะมีการแกว่ง
- สำหรับ $\eta = \{0.5, 0.9\}$ และ $\alpha = 0.9$ จะทำให้ค่า MSE เกิดการแกว่งในระหว่างการเรียนรู้ แต่ก็ยังคงอยู่ในระดับที่ต่ำ




รูปที่ 5 - 1



รูปที่ 5 - 4




รูปที่ 5 - 2



รูปที่ 5 - 3

รูปที่ 5 กราฟการเรียนรู้รวมกับการเปลี่ยนแปลงค่า
โมเมนตัม α , และค่าอัตราการเรียนรู้รูปที่ (5-1)
 $\eta = 0.01$, (5-2) $\eta = 0.1$, (5-3) $\eta = 0.5$, (5-4)
 $\eta = 0.9$

รูปที่ 6 แสดงกราฟการเรียนรู้ที่ดีที่สุดที่ได้เลือก
มาจากแต่ละกลุ่มของกราฟการเรียนรู้ที่แสดงในรูปที่
5 ดังนั้นในการหากราฟการเรียนรู้ที่ดีที่สุดทั้งหมด
จากที่ได้กล่าวไว้ก่อนหน้านี้ จากรูปที่ 6 ได้แสดงให้เห็น
ชัดเจนว่าอัตราการเรียนรู้ที่ดีที่สุด (η_{opt})
ประมาณ 0.5 และค่าโมเมนตัมที่ดีที่สุด (α_{opt})
ประมาณ 0.5 และค่าดังกล่าวนี้ให้ประสิทธิภาพใน
การจำแนก 97.22 เปอร์เซ็นต์ และตารางที่ 3 ได้สรุป
ค่าพารามิเตอร์ที่ดีที่สุดที่ใช้ในโครงข่าย



รูปที่ 6 กราฟการเรียนรู้ที่ดีที่สุด

ตารางที่ 3 พารามิเตอร์ที่ดีที่สุดของ Multilayer Perceptron

พารามิเตอร์	สัญลักษณ์	ช่วง
จำนวน Neural ในชั้น ซ่อนที่ดีที่สุด	m_{opt}	18
อัตราการเรียนรู้ที่ดีที่สุด	η_{opt}	0.5
โมเมนตัมที่ดีที่สุด	α_{opt}	0.5

5. สรุป

งานวิจัยนี้ได้นำเสนอการจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมสำหรับจำแนกข้อมูลสัญญาณการสั่นสะเทือนที่ตรวจวัดได้จากคอมเพรสเซอร์แบบลูกสูบอัดอากาศสองชั้นสองกระบอกสูบ การทดลองได้แบ่งข้อมูลออกเป็น 2 ประเภท คือ ปกติและผิดปกติ โดยใช้วิธีการแพร่กระจายค่าย้อนกลับในการฝึกสอนโครงข่ายและเทคนิคการเคลื่อนต่ำลง ผลการทดลองที่ได้จากการปรับพารามิเตอร์ 2 ตัว คือ อัตราการเรียนรู้และโมเมนตัมเพื่อให้โครงข่ายมีประสิทธิภาพมากที่สุดและได้แสดงให้เห็นว่าโครงข่ายมีประสิทธิภาพในการจำแนกประเภทข้อมูลมากที่สุดโดยเฉลี่ยเท่ากับ 97.22 เปอร์เซ็นต์

6. เอกสารอ้างอิง

[1] El-Ghamry, M.H., Reuben, R.L., and Steel, J.A., (2003). The development of automates pattern recognition and statistical feature isolation techniques for the diagnosis of reciprocating machinery faults using acoustic emission, *Mechanical system and signal Processing*, Vol.17, 2003, pp. 805-823.

[2] Gill, J.D., Douglas, R.M., Neo, Y.S., Reuben, R. L., and Steel, J.A., (2000). Examination of Plate Valve Behavior in a small Reciprocating Compressor Using Acoustic Emission, *The 24th EWGAE conference on Acoustic Emission*, France, 2000, pp. 133-138.

[3] Gill, J.D., Brown, E.R., Twite, M., Horner, G., Reuben, R. L. and Steel, J.A., (1998). Monitoring of a large reciprocating compressor, *Proceeding of the 11th International Conference on Condition Monitoring and Diagnostic Engineering Management*, COMADEM, Monash University, Australia, 1998.

[4] Jones, R.M., (2003). Application note: CM3086, Monitoring of screw compressor bearing and rotational elements, SKF Reliability systems, 2003.

[5] Kim, T. and James Li, C. (1995). Feedforward neural networks for fault diagnosis and severity assessment of a screw compressor, *Mechanical Systems and Signal Processing*, vol. 9(5), 1995, pp. 485 – 496.

[6] Yang, B-S., Hwang, W-W., Kim, D-J., and Tan, A.C. (2005). Condition classification of small reciprocating compressor for refrigerator using artificial neural networks and support vector machines, *Mechanical Systems and Signal Processing*, vol. 19, 2005, pp. 371 – 390.

[7] James Li, C. and Yu, X. (1995). High pressor air compressor valve fault diagnosis using feedforward neural networks, *Mechanical Systems and Signal Processing*, vol. 9(5), 1995, pp. 527 – 536.

[8] K. Suddoung, and P. Nivesrangsang. (2009). Condition Monitoring of a Two-Stage Reciprocating Compressor using Vibration Siganls, *The 23rd Conference of Mechanical Engineering Network of Thailand*, ME-Nett , DRC, 2009.