


การตรวจจับความบกพร่องของลิเนียร์แบริงในสถานะใช้งานจริง
โดยใช้โครงข่ายประสาทเทียม



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมเมคคาทรอนิกส์
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2563

**LINEAR BEARING FAULT DETECTION IN
OPERATIONAL CONDITION USING
ARTIFICIAL NEURAL NETWORK**



**A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Mechatronic Engineering
Suranaree University of Technology
Academic Year 2020**

การตรวจจับความบกพร่องของลิเนียร์แบริงในสถานะใช้งานจริงโดยใช้
โครงข่ายประสาทเทียม

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



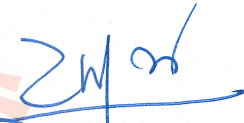
(ผศ. ดร. โสรัฎา แจ็งการ)

ประธานกรรมการ



(รศ. ดร. จิระพล ศรีเสรีสุผล)

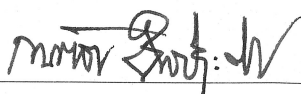
กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(รศ. ดร. บัณฑิต กฤตาคม)

กรรมการ

มหาวิทยาลัยเทคโนโลยีสุรนารี



(รศ. ร.อ. ดร. กนต์ธร ชำนิประศาสน์)

รองอธิการบดีฝ่ายวิชาการและพัฒนาความเป็นสากล



(รศ. ดร. พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

ศิวัญ เหล่าบุตรสา : การตรวจจับความบกพร่องของลิเนียร์แบริงในสถานะใช้งานจริงโดยใช้โครงข่ายประสาทเทียม (LINEAR BEARING FAULT DETECTION IN OPERATIONAL CONDITION USING ARTIFICIAL NEURAL NETWORK)
อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร.จิระพล ศรีเสริฐผล, 115 หน้า.

การศึกษานี้มุ่งเน้นเพื่อศึกษาวิธีการตรวจจับความบกพร่องของลิเนียร์แบริงในสถานะใช้งานจริงโดยใช้โครงข่ายประสาทเทียม เพื่อนำไปพัฒนาการลดต้นทุนของระบบการซ่อมบำรุง โดยมีแนวคิดจากการศึกษาของ โดยของสมาคมวิศวกรรมเครื่องกลแห่งอเมริกา (American Society for Mechanical Engineering) พบว่าค่าใช้จ่ายการซ่อมบำรุงแบบตามสถานะ (Condition Based Maintenance) ช่วยลดค่าใช้จ่ายคิดเป็น 52.94% และ 33.33% ต่อเครื่อง 1 แรงม้า เมื่อเปรียบเทียบกับการบำรุงรักษาแบบหลังเครื่องจักรเสียหาย (Break Down Maintenance) และการบำรุงรักษาแบบเชิงป้องกัน (Preventive Maintenance) ตามลำดับ ดังนั้นการศึกษานี้จึงมีวัตถุประสงค์ 1) เพื่อตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริงขณะสถานะใช้งานจริงโดยใช้โครงข่ายประสาทเทียม 2) พัฒนาระบบตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริง เพื่อลดการหยุดและความเสียหายของเครื่องจักรเนื่องจากเครื่องจักรหยุดทำงานกะทันหัน โดยการศึกษาได้ทำการเก็บรวบรวมข้อมูล 3 พารามิเตอร์ คือ FFT spectrum (dB), Motor current (mA) และค่า Crest factor ซึ่งเราจะทำการเก็บค่าทั้งหมด 50 ค่า 6 สถานะของแต่ละพารามิเตอร์ ซึ่งได้ข้อมูลทั้งหมด 300 ข้อมูลเพื่อนำไปวิเคราะห์ในโครงข่ายประสาทเทียมในตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริง ผลการศึกษาพบว่า สามารถตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริงได้ความแม่นยำทางสถิติในระดับ 91.0% สามารถปรับใช้กับการซ่อมบำรุงรักษาแบบตามสถานะ โดยใช้วิธีการตรวจจับและวินิจฉัยความบกพร่อง (Fault Detection and Diagnostic) ด้วยวิธีการโครงข่ายประสาทเทียม (Artificial Neural Network)

สาขาวิชา วิศวกรรมเมคคาทรอนิกส์
ปีการศึกษา 2563

ลายมือชื่อนักศึกษา ศิวัญ
ลายชื่ออาจารย์ที่ปรึกษา ดร.จิระพล

SIWANU LAWBOOTSA : LINEAR BEARING FAULT DETECTION IN
OPERATIONAL CONDITION USING ARTIFICIAL NEURAL
NETWORK. THESIS ADVISOR : ASSOC. PROF. JIRAPHON
SRISERTPOL, Ph.D., 115 PP.

LINEAR BEARING / ARTIFICIAL NEURAL NETWORK / FAULT DETECTION

This study focuses on methods of detecting linear bearing defects in operating conditions using Artificial Neural Networks (ANN) to be used to reduce maintenance costs. The concept is based on a study by the American Mechanical Engineering Association (ASME) that found that Condition Based Maintenance (CBM) will reduce the cost of 52.94% and 33.33% per 1 horsepower compared to Break Down Maintenance (BDM) and Preventive Maintenance (PM) for respective. The objectives of this study are as follows: 1) To fault detection and diagnostic of linear bearing in operational condition using artificial neural network 2) Develop a system to fault detection and diagnostic of linear bearing to reduce stop and damage machine to break down machine. In the study, three parameters of data were collected: FFT spectrum, Motor current and Crest factor. From the data collected, it will be calculated to find the total of 50 values in 6 conditions for each parameter, resulting in a total of 300 data for analysis in the artificial neural network to identify the condition of the defect. The results show that linear bearing defects can be classified with 91.0% statistical accuracy.

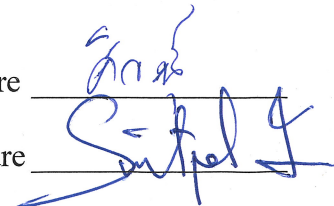
It can be adapted to use with Condition Based Maintenance (CBM) to effectively reduce maintenance costs. Fault Detection and Diagnostic (FDD) by artificial neural network.

School of Mechatronic Engineering

Academic Year 2020

Student's Signature

Advisor's Signature



กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงเพราะได้รับความกรุณาเมตตาจากท่านรองศาสตราจารย์ ดร.จิระพล ศรีเสริฐผล อาจารย์ที่ปรึกษาวิทยานิพนธ์ที่คอยให้คำปรึกษาชี้แนะแนวทางในการวิจัย และคอยสั่งสอนการดำเนินชีวิตรวมทั้งเป็นแบบอย่างการใช้ชีวิต ซึ่งผู้วิจัยขอขอบพระคุณท่านเป็นอย่างสูง

ขอขอบคุณท่านรองศาสตราจารย์ เรืออากาศเอก ดร.กนต์ธร ชำนิประศาสน์ ที่ให้คำแนะนำที่เป็นประโยชน์ในการดำเนินงานวิจัย

ขอขอบพระคุณคณาจารย์ทุกท่านที่ประสิทธิ์ประสาทวิชาความรู้ให้แก่ผู้ทำวิจัย ทั้งในอดีตจนถึงปัจจุบัน

ขอขอบคุณ พี่ประธาน ชมเมืองปัก พี่สันติ พุงกระจ่าง พี่จักรวรรดิ ดิยัง พี่สายัณ ปลั่งงู เหลื่อม และพี่ ๆ เพื่อน ๆ น้อง ๆ แผนก HGA Development ที่ช่วยให้ความสะดวกสนับสนุนทางด้านเครื่องมือและอุปกรณ์รวมทั้งให้คำแนะนำการใช้อุปกรณ์ที่ใช้ในงานวิจัย

ขอขอบคุณพี่ ๆ น้อง ๆ Lab control ทุกท่าน ที่ให้คำแนะนำและให้การช่วยเหลือเกี่ยวกับวิทยานิพนธ์

ขอขอบคุณสถาบันแสงซินโครตรอนที่ให้ทุนการศึกษา

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์เล่มนี้ ผู้วิจัยขอมอบให้พระคุณ บิดามารดาที่ล่วงลับไปแล้ว รวมถึงสมาชิกครอบครัวเหล่าบุตรสาและครอบครัวภักด์ ที่คอยให้กำลังใจและอบรมดูแลมาตั้งแต่เด็ก จนทำให้ผู้วิจัยประสบความสำเร็จในชีวิตเรื่อยมา

ศิวณ เหล่าบุตรสา

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ฉ
คำอธิบายสัญลักษณ์และคำย่อ.....	ฎ
บทที่	
1 บทนำ	
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	4
1.3 สมมุติฐานของงานวิจัย.....	4
1.4 ข้อยกเว้นเบื้องต้นและขอบเขตงานวิจัย.....	4
1.5 ระเบียบวิธีงานวิจัย.....	5
1.6 สถานที่ทำงานงานวิจัย.....	5
1.7 เครื่องมือและอุปกรณ์ที่ใช้ในงานวิจัย.....	5
1.8 ประโยชน์ที่คาดว่าจะได้รับ.....	5
1.9 การจัดทำรูปเล่ม.....	6
2 ปรัชญาบรรณกรรมและงานวิจัยที่เกี่ยวข้องกับงานวิจัย	
2.1 ระบบการซ่อมบำรุงรักษา.....	7
2.2 ระบบการตรวจสอบและจำแนกความบกพร่อง.....	9
2.2.1 ระบบการตรวจสอบและ วินิจฉัยความบกพร่องแบบจำลอง.....	9

สารบัญ (ต่อ)

หน้า

2.2.2	ระบบการตรวจสอบและวินิจฉัยความบกพร่องแบบ ไม่มีแบบจำลอง	9
2.3	แบบจำลองลิเนียร์แบริง	10
2.4	การแปลงฟูรีเยร์แบบเร็ว	12
2.5	Crest factor	12
2.6	โครงข่ายประสาทเทียม	13
2.6.1	การเรียนรู้แบบมีผู้สอน	20
2.6.2	การเรียนรู้แบบไม่มีผู้สอน	21
2.6.3	การเรียนรู้แบบเชิงบังคับ	21
2.6.4	การเรียนรู้แบบเลียนแบบ	21
2.7	Analysis of various (ANOVA)	25
2.8	การคัดแยกโดยใช้กระบวนการทางสถิติ	25
2.8.1	ค่าเบี่ยงเบนมาตรฐาน	25
2.8.2	ค่าความโค้ง	26
2.8.3	ค่าเฉลี่ยกำลังสอง	26
2.9	ปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง	26
2.9.1	งานวิจัยที่เกี่ยวข้องกับแบริง	27
2.9.2	งานวิจัยที่เกี่ยวข้องกับปัญญาประดิษฐ์	28
2.9.3	งานวิจัยที่เกี่ยวข้องกับระบบการซ่อมบำรุงและระบบ ตรวจจับความบกพร่อง	29
3	วิธีดำเนินงานวิจัย	
3.1	การตั้งค่าการทดลอง	32
3.2	สภาวะความผิดปกติของลิเนียร์แบริง	34
3.2.1	สภาวะลูกปืนปกติ	35
3.2.2	สภาวะลูกปืนเสียหาย 1 ลูก	35
3.2.3	สภาวะลูกปืนหาย 1 ลูก	36

สารบัญ (ต่อ)

หน้า

3.2.4	สถานะสารหล่อลื่นเหลือน้อย.....	36
3.2.5	สถานะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย	37
3.2.6	สถานะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย	38
3.3	ขั้นตอนการเก็บข้อมูล.....	39
3.4	การจำแนกความบกพร่องของลิเนียร์แบริงโดยใช้โครงข่ายประสาทเทียม	52
3.5	การเปรียบเทียบระหว่างโครงข่ายประสาทเทียมกับปัญญาประดิษฐ์	56
4	ผลการทดลองและวิเคราะห์ผลการทดลอง	
4.1	ขั้นตอนการเก็บข้อมูล.....	57
4.1.1	FFT spectrum	57
4.1.2	Motor current.....	59
4.1.3	Crest factor	61
4.2	ผลการทดลองการคัดแยกโดยใช้กระบวนการทางสถิติ.....	63
4.2.1	ค่าเบี่ยงเบนมาตรฐาน	64
4.2.2	ค่าความโค้ง.....	66
4.2.3	ค่าเฉลี่ยกำลังสอง	69
4.3	การตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริงโดยใช้ โครงข่ายประสาทเทียม.....	71
4.3.1	หนึ่งพารามิเตอร์.....	71
4.3.2	สองพารามิเตอร์	75
4.3.3	สามพารามิเตอร์	78
4.4	การเปรียบเทียบระหว่างโครงข่ายประสาทเทียมกับปัญญาประดิษฐ์	80
4.5	ผลการทดลองโปรแกรม Simulink ใน Matlab 2020 a	81
5	สรุปผลและข้อเสนอแนะ	
5.1	สรุป	83
5.2	ข้อเสนอแนะ.....	83
	รายการอ้างอิง	84

สารบัญ (ต่อ)

หน้า

ภาคผนวก

ภาคผนวก ก. โปรแกรม Matlab.....	85
ภาคผนวก ข. โปรแกรม Classificationlearner of Matlab 2020a	90
ภาคผนวก ค. บทความที่ได้รับการตีพิมพ์เผยแพร่และการประชุมวิชาการในต่างประเทศ.....	95
ประวัติผู้เขียน	115



สารบัญตาราง

ตารางที่		หน้า
3.1	สภาวะลูกปืนปกติ	40
3.2	สภาวะลูกปืนเสียหาย 1 ลูก	43
3.3	สภาวะลูกปืนหาย 1 ลูก	45
3.4	สภาวะสารหล่อลื่นเหลือน้อย	47
3.5	สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย	49
3.6	สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย	51
4.1	การเปรียบเทียบค่า FFT spectrum ระหว่างสภาวะลูกปืนปกติกับสภาวะอื่น ๆ	59
4.2	การเปรียบเทียบค่า Motor current ระหว่างสภาวะลูกปืนปกติกับสภาวะอื่น ๆ	61
4.3	การเปรียบเทียบค่า Crest factor ระหว่างสภาวะลูกปืนปกติกับสภาวะอื่น ๆ	63
4.4	ผลการทดลอง Simulink	82

สารบัญรูป

รูปที่	หน้า
1.1	ส่วนประกอบ HGA 1
1.2	กระบวนการผลิต HGA.....2
1.3	เครื่อง Auto Core Adhesion Mounting (ACAM).....3
1.4	หน้าที่ลิเธียมแบรีง..... 4
2.1	ระบบการซ่อมบำรุงรักษา8
2.2	ค่าใช้จ่ายในการบำรุงรักษาแบบต่าง ๆ9
2.3	ระบบตรวจสอบความผิดพลาดและจำแนกความบกพร่องแบบไม่มีแบบจำลอง10
2.4	ส่วนประกอบของลิเธียมแบรีง..... 11
2.5	โดเมนเวลา..... 13
2.6	โครงข่ายประสาทของมนุษย์ 14
2.7	โครงข่ายประสาทเทียม 15
2.8	องค์ประกอบของโครงข่ายประสาทเทียม16
2.9	ฟังก์ชันถ่ายโอนแบบจำกัดแฉ่ง 17
2.10	ฟังก์ชันถ่ายโอนแบบจำกัดแฉ่งสมมาตร 17
2.11	ฟังก์ชันถ่ายโอนแบบซิกมอยด์ 18
2.12	ฟังก์ชันถ่ายโอนแบบเชิงเส้น..... 18
2.13	ฟังก์ชันถ่ายโอนแบบลอกซิกมอยด์..... 19
2.14	ฟังก์ชันถ่ายโอนแบบเชิงเส้นจำกัด 19
2.15	ฟังก์ชันถ่ายโอนแบบเกาเซียน20
2.16	การเรียนรู้ของ Machine learning20
2.17	เครือข่ายไปข้างหน้า..... 22
2.18	Multi-layer perceptron..... 22
2.19	แบบจำลองเครือข่ายไปข้างหน้า 23
2.20	เครือข่ายป้อนกลับ25
2.21	ส่วนที่สัมผัสกับรางเลื่อน27

สารบัญรูป (ต่อ)

รูปที่		หน้า
3.1	วิธีการดำเนินงานวิจัย.....	31
3.2	บล็อกวิธีการดำเนินงานวิจัย.....	32
3.3	ตำแหน่งการติดตั้งของเซนเซอร์.....	33
3.4	รูปแผนผังการเชื่อมต่ออุปกรณ์ทำการทดลองและการรวบรวมข้อมูล.....	34
3.5	สภาวะลูกปืนปกติ.....	35
3.6	สภาวะลูกปืนเสียหาย 1 ลูก.....	35
3.7	สภาวะลูกปืนหาย 1 ลูก.....	36
3.8	สภาวะสารหล่อลื่นเหลือน้อย.....	37
3.9	สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย.....	38
3.10	สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย.....	39
3.11	แผนผังขั้นตอนการเก็บข้อมูล.....	40
3.12	แผนผังของหนึ่งพารามิเตอร์.....	53
3.13	แผนผังของสองพารามิเตอร์.....	53
3.14	แผนผังของสามพารามิเตอร์.....	54
3.15	แผนผังของโครงข่ายประสาทเทียมหนึ่งพารามิเตอร์.....	55
3.16	แผนผังของโครงข่ายประสาทเทียมสองพารามิเตอร์.....	55
3.17	แผนผังของโครงข่ายประสาทเทียมสามพารามิเตอร์.....	55
3.18	การเปรียบเทียบปัญหาประดิษฐ์ชนิดต่าง ๆ.....	56
4.1	ค่าความน่าจะเป็นของ FFT Spectrum ที่ค่าความเชื่อมั่น 95%.....	58
4.2	Boxplot of FFT spectrum at velocity 0.5 m/s.....	58
4.3	ค่าความน่าจะเป็นของ Motor current ที่ค่าความเชื่อมั่น 95%.....	60
4.4	Boxplot of Motor current at velocity 0.5 m/s.....	60
4.5	ค่าความน่าจะเป็นของ Crest factor ที่ค่าความเชื่อมั่น 95%.....	62
4.6	Boxplot of Crest factor at velocity 0.5 m/s.....	62
4.7	ค่าเบี่ยงเบนมาตรฐานของ FFT spectrum.....	64
4.8	ค่าเบี่ยงเบนมาตรฐานของ Motor current.....	65

สารบัญรูป (ต่อ)

รูปที่		หน้า
4.9	ค่าเบี่ยงเบนมาตรฐานของ Crest factor.....	65
4.10	ค่าความโค้งของ FFT spectrum	66
4.11	ค่าความโค้งของ Motor current.....	67
4.12	ค่าความโค้งของ Crest factor	68
4.13	ค่าเฉลี่ยกำลังสองของ FFT spectrum	69
4.14	ค่าเฉลี่ยกำลังสองของ Motor current	70
4.15	ค่าเฉลี่ยกำลังสองของ Crest factor	71
4.16	Confusion of FFT spectrum	72
4.17	Confusion of Motor current.....	74
4.18	Confusion of Crest factor	75
4.19	Confusion of FFT spectrum & Motor current	76
4.20	Confusion of FFT spectrum & Crest factor.....	77
4.21	Confusion of Motor current & Crest factor.....	78
4.22	Confusion of FFT spectrum & Motor current & Crest factor	79
4.23	การเปรียบเทียบแอมป์ทุกพารามิเตอร์	80
4.24	การเปรียบเทียบระหว่างโครงข่ายประสาทเทียมกับปัญญาประดิษฐ์	81
4.25	ตัวอย่างการแสดงผลของ Simulink.....	81

คำอธิบายสัญลักษณ์และคำย่อ

f_{ball}	=	ค่าความถี่ของลูกปืนที่เสียหาย (Hz)
f_{loss}	=	ค่าความถี่ของลูกปืนที่หาย (Hz)
V_{ball}	=	ค่าความเร็วของลูกปืน (mm / s)
D_b	=	ค่าความยาวของเส้นผ่านศูนย์กลาง (mm)
l	=	ระยะห่างจากจุดศูนย์กลางของลูกปืน 2 ลูก (mm)
$x(n)$	=	Sample of time domain
$X(m)$	=	Discrete Fourier Transform (DFT) ของ $x(n)$
N	=	2^k
n	=	Sample index หรือ จำนวนเต็ม
m	=	Each frequency
C	=	ค่า Crest factor
$x(t)_{peak}$	=	ค่าระดับสูงสุดของสัญญาณ (m / s^2)
$x(t)_{rms}$	=	ค่าเฉลี่ยสัญญาณ (m / s^2)
C_{dB}	=	ค่า Crest factor
p_i	=	ข้อมูลนำเข้า
w_i	=	ค่าน้ำหนัก
S	=	ค่าผลรวมของข้อมูลนำเข้ากับค่าน้ำหนัก
y	=	เอาต์พุต
p^T	=	อินพุตของ MLP
b^T	=	ไบอัสของ MLP
W	=	น้ำหนักของ MLP


บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหางานวิจัย

ปัจจุบันอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ได้มีการพัฒนาและเปลี่ยนแปลงเพื่อแข่งขันกันอย่างรวดเร็วและไม่หยุดนิ่ง ไม่ว่าจะทางด้านราคาผลิตภัณฑ์และเทคโนโลยีความเร็วในการอ่านการเขียน ฮาร์ดดิสก์ไดรฟ์ ปัจจัยหนึ่งที่สำคัญอย่างมาก คือ ต้นทุนในกระบวนการผลิตและความน่าเชื่อถือของเครื่องจักรอัตโนมัติ ได้เข้ามามีบทบาทสำคัญในการลดต้นทุน เวลา คุณภาพในการผลิตทำให้มีผลกำไรของผลิตภัณฑ์มากยิ่งขึ้น

ฮาร์ดดิสก์ไดรฟ์มีส่วนประกอบหลักที่สำคัญ คือ Head Gimbal Assembly (HGA) โดย HGA มีหน้าที่ในการอ่านเขียนข้อมูลลงแผ่นมีเดีย ซึ่ง HGA มีส่วนประกอบหลัก 2 ส่วน คือ Slider และ Suspension โดย Slider มีหน้าที่อ่านเขียนข้อมูลลงแผ่นมีเดีย ส่วน Suspension มีหน้าที่เป็นตัวยึดเหนี่ยวและเชื่อมต่อวงจร Slider ส่วน รูปที่ 1.1

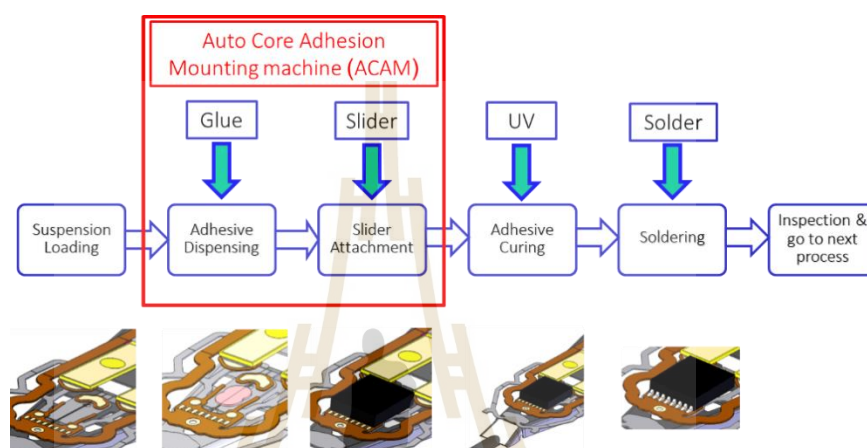


รูปที่ 1.1 ส่วนประกอบ HGA

ในกระบวนการผลิต HGA จะแบ่งขั้นตอนการผลิตหลัก ๆ ออกเป็น 6 ขั้นตอน

- โหลด Suspension
- หยอดกาวลงใน Suspension

- ติด Slider ที่ Suspension และอบกาวขึ้นพื้นฐานเพื่อไม่ให้ Slider ขยับ
 - อบกาวเพื่อให้กาวแห้งโดยใช้รังสี UV
 - เชื่อมวงจร Slider เข้ากับ Suspension
 - ตรวจสอบคุณภาพการผลิต
- ทั้ง 6 ขั้นตอนจะแสดงดังรูปที่ 1.2




รูปที่ 1.2 กระบวนการผลิต HGA


ซึ่งงานวิจัยนี้เน้นศึกษาวิจัยเกี่ยวกับเครื่อง Auto Core Adhesion Mounting (ACAM) ดังรูปที่ 1.3 เนื่องจากมีความสำคัญมากในกระบวนการผลิต HGA มีหน้าที่หยอดกาวและติดตั้ง Slider และอบกาวเบื้องต้นเพื่อไม่ให้ Slider ขยับออกจากตำแหน่งขณะเคลื่อนไหว ซึ่งอุปกรณ์การทำงานหลักประกอบด้วย Clamping unit ใช้จับยึดชิ้นงาน และ X Y Stage actuator เพื่อเคลื่อนย้ายชิ้นงานไปในตำแหน่งที่หยอดกาวและติดหัวอ่านเขียน ซึ่งเครื่อง ACAM ต้องทำงานที่ความเร็วสูงและมีความแม่นยำสูงเนื่องจากขนาดชิ้นงานมีขนาดเล็กมาก ซึ่งเมื่อเครื่อง ACAM ทำงานด้วยความเร็วสูงและเป็นเวลานาน การชำรุดของอุปกรณ์ของเครื่องจักรอัตโนมัติเป็นสิ่งที่ไม่หลีกเลี่ยงไม่ได้และอุปกรณ์ที่เสียหายหลักคือลิเนียร์แบริง เนื่องจากลิเนียร์แบริงมีหน้าที่รองรับน้ำหนักของ clamping unit และลดแรงเสียดทานขณะเคลื่อนไหวดังรูปที่ 1.4 เมื่อลิเนียร์แบริงเกิดความเสียหายจะส่งผลกระทบต่อกระบวนการผลิตดังนั้นการซ่อมบำรุงก่อนที่เครื่องจักรชำรุดจึงเป็นสิ่งสำคัญอย่างยิ่งต่อกระบวนการผลิต

ดังนั้น งานวิจัยนี้จึงได้เสนอแนะการซ่อมบำรุงตามสถานะ (Condition Base Maintenance) ของลิเนียร์แบริงในเครื่อง Auto Core Adhesion Mounting (ACAM) โดยใช้เทคนิคระบบตรวจจับ

และวินิจฉัยความบกพร่องในการตรวจจับความเสียหายของแบริ่งโดยแบ่งสถานะของแบริ่งเป็น 6 สถานะ คือสถานะลูกปืนปกติ (Healthy bearing) สถานะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) สถานะลูกปืนหาย 1 ลูก (One ball bearing loss) สถานะสารหล่อลื่นเหลือน้อย (Starved lubricant) สถานะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) และสถานะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) โดยใช้การเก็บค่า FFT spectrum, Motor current และ Crest factor ในการวิเคราะห์ข้อมูลของลิเนียร์แบริ่งและใช้โครงข่ายประสาทเทียมเพื่อตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริ่งในสถานะใช้งานจริง



รูปที่ 1.3 เครื่อง Auto Core Adhesion Mounting (ACAM)



รูปที่ 1.4 หน้าทีของลิเนียร์แบริง

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 เพื่อตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริงขณะสถานะใช้งานจริง โดยใช้โครงข่ายประสาทเทียม

1.2.2 พัฒนาระบบตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริง เพื่อลดการหยุดและความเสียหายของเครื่องจักรเนื่องจากเครื่องจักรหยุดทำงานกะทันหัน

1.3 สมมุติฐานของงานวิจัย

1.3.1 สามารถที่ใช้ปัญญาประดิษฐ์มาวิเคราะห์เพื่อลดความเสียหายเนื่องจากเครื่องจักรหยุดทำงานกะทันหัน

1.4 ข้อตกลงเบื้องต้นและขอบเขตของงานวิจัย

1.4.1 ใช้มอเตอร์แม่เหล็กไฟฟ้ากระแสตรง (Magnetic linear DC motor model Akribis SGL 100-AUM3-PS4J) โดยมีลิเนียร์แบริง 2 ตัว ในการรองรับ Clamping unit.

1.4.2 เก็บข้อมูลทั้งหมด 3 ชนิด คือ FFT spectrum, Motor current, Crest factor

1.4.3 การแบ่งสถานะลิเนียร์แบริงออกเป็น 6 สถานะคือ สถานะลูกปืนปกติ (Healthy bearing), สถานะลูกปืนเสียหาย 1 ลูก (One ball bearing damage), สถานะลูกปืนหาย 1 ลูก (One ball bearing loss), สถานะสารหล่อลื่นเหลือน้อย (Starved lubricant), สถานะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) และสถานะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant)

1.4.4 ใช้โครงข่ายประสาทเทียมในการตรวจจับและวินิจฉัยความบกพร่องสถานะลิเนียร์แบริงที่ความเร็ว 0.5 m/s

1.4.5 Clamping unit มีน้ำหนัก 7 Kg.

1.5 ระเบียบวิธีงานวิจัย

1.5.1 คำนวณค่าความรู้ ทฤษฎี เอกสารที่เกี่ยวข้องกับโครงข่ายประสาทเทียมและระบบการตรวจจับและวินิจฉัยความบกพร่อง

1.5.2 ออกแบบระบบการเก็บข้อมูลค่าของลิเนียร์แบริงขณะสภาวะใช้งานจริง โดยทำการเก็บ 3 ค่าคือ FFT spectrum, Motor current, Crest factor

1.5.3 นำข้อมูลมาวิเคราะห์โดยใช้เทคนิค FFT spectrum, Motor current, Crest factor

1.5.4 ออกแบบและวิเคราะห์ข้อมูล เพื่อตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริง โดยใช้โครงข่ายประสาทเทียม

1.5.5 สรุปผลงานวิจัย

1.5.6 จัดทำเอกสารและรายงานงานวิจัย

1.6 สถานที่ทำงานงานวิจัย

บริษัท เวสเทิร์น ดิจิตอล ประเทศไทย จำกัด แผนก HGA Development

1.7 อุปกรณ์และเครื่องมือที่ใช้ในงานวิจัย

1.7.1 Magnetic Linear DC Motor (Akribis SGL 100-AUM3-PS4J)

1.7.2 Iotech dynamic signal analyzer (640u)

1.7.3 3 Axis acceleration sensor (PCB 356A32)

1.7.4 Clamping unit 7 Kg.

1.7.5 Linear bearing (R162219320)

1.7.6 โปรแกรม eZ-Analyst

1.7.7 โปรแกรม Akribis PCSuite

1.7.8 โปรแกรม MATLAB R2020a

1.7.9 โปรแกรม Minitab 17

1.8 ประโยชน์ที่คาดว่าจะได้รับ

1.7.1 ได้ต้นแบบระบบตรวจสอบและวินิจฉัยความบกพร่องของลิเนียร์แบริง

1.7.2 สามารถประยุกต์ใช้โครงข่ายประสาทเทียม เพื่อตรวจสอบและวินิจฉัยความบกพร่องของชิ้นส่วนอื่น ๆ ของเครื่องจักรได้

1.7.3 สามารถลดต้นทุนในการบำรุงรักษาเนื่องจากเครื่องจักรชำรุดได้

1.9 การจัดทำรูปเล่ม

บทที่ 1 กล่าวถึงความเป็นมาและความสำคัญของปัญหา วัตถุประสงค์ของการวิจัย สมมุติฐานของงานวิจัย ข้อตกลงเบื้องต้นและขอบเขตของการวิจัย ระเบียบวิธีวิจัย สถานที่ทำงานวิจัย อุปกรณ์เครื่องมือและที่ใช้ในการทำงานวิจัย ประโยชน์ที่คาดว่าจะได้รับ

บทที่ 2 กล่าวถึงทฤษฎีต่างๆ รวมถึงงานวิจัยต่าง ๆ ที่เกี่ยวข้องกับงานวิจัย

บทที่ 3 กล่าวถึงวิธีการดำเนินงานวิจัย

บทที่ 4 กล่าวถึงผลการทดลองที่ได้

บทที่ 5 สรุปผลการทดลองและข้อเสนอแนะ



บทที่ 2

ปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้องกับงานวิจัย

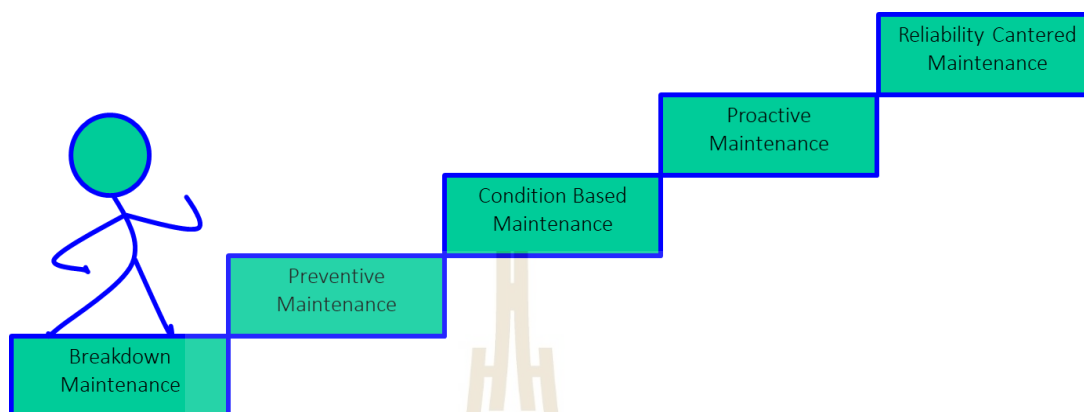
การศึกษาปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้องกับงานวิจัยครั้งนี้จะศึกษาเกี่ยวกับระบบการซ่อมบำรุงรักษา ระบบการตรวจสอบและวินิจฉัยความบกพร่อง แบบจำลองลิเนียร์แบริง การแปลงฟูริเยร์แบบเร็ว โคร่งข่ายประสาทเทียม Analysis of various (ANOVA) และการคัดแยกโดยใช้กระบวนการทางสถิติ โดยมีรายละเอียดดังนี้

2.1 ระบบการซ่อมบำรุงรักษา (Maintenance system)

ในปัจจุบันนี้กระบวนการผลิต โดยใช้เครื่องจักรจำเป็นต้องมีการซ่อมบำรุงรักษา เพื่อป้องกันเครื่องจักรเสียหาย ซึ่งหากเครื่องจักรเกิดการเสียหายจะส่งผลกระทบต่อกระบวนการผลิต ดังนั้น ระบบการซ่อมบำรุงรักษาเป็นสิ่งที่สำคัญมากต่อกระบวนการผลิต ระบบการซ่อมบำรุงรักษาสามารถแบ่งออกได้ดังนี้ ดังรูปที่ 2.1

- Break Down Maintenance (BDM) คือ การใช้งานเครื่องจักรจนกว่าจะชำรุดหรือเสียหายแล้วหยุดเครื่องจักรเพื่อทำการซ่อมบำรุงรักษา
- Preventive Maintenance (PM) คือ การออกแบบแผนงานการซ่อมบำรุงรักษาตามช่วงเวลา เพื่อหยุดเครื่องจักรเพื่อเปลี่ยนชิ้นส่วน ซึ่งเป็นรูปแบบที่นิยมใช้ในประเทศไทย
- Condition Base Maintenance (CBM) คือ การซ่อมบำรุงรักษาตามสภาพความเสียหายของเครื่องจักรด้วยวิธีการที่เหมาะสม ซึ่งมีหลายวิธีการที่สามารถใช้ตรวจสอบสภาพเครื่องจักรได้ เช่น การวิเคราะห์การสั่นสะเทือน การถ่ายภาพความร้อน การวิเคราะห์น้ำมันหล่อลื่น เป็นต้น
- Predictive Maintenance (PM) คือ การซ่อมบำรุงรักษาเชิงพยากรณ์โดยใช้ฐานข้อมูล ซึ่งเป็นการประเมินช่วงเวลาความเสียหายของเครื่องจักรและทำการซ่อมบำรุงก่อนเครื่องจักรจะเสียหาย โดยการซ่อมบำรุงรักษาแบบนี้เป็นการซ่อมบำรุงรักษาเชิงรุก
- Design Out Maintenance (DOM) คือ การซ่อมบำรุงรักษาเครื่องจักร โดยใช้ข้อมูลทางสถิติและปัญหาซ้ำซ้อนของเครื่องจักรนั้น ๆ มาทำการออกแบบและหาวิธีแก้ไขเพื่อขจัดต้นเหตุของปัญหา ซึ่งเป็นการซ่อมบำรุงรักษาเชิงรุก
- Reliability Centered Maintenance (RCM) คือ การรวบรวมการซ่อมบำรุงรักษาทั้งหมดรวมไว้ด้วยกัน กล่าวคือ เมื่อเกิดการความผิดปกติใด ๆ ในเครื่องจักร ระบบซ่อมบำรุงรักษาจะเข้าไป

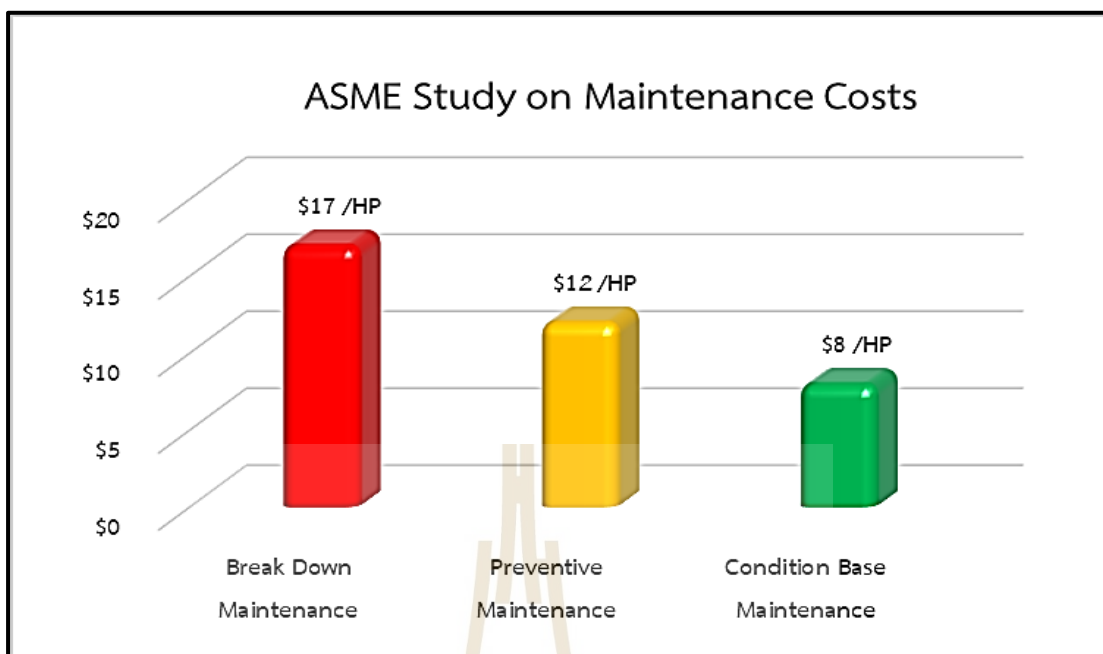
ดำเนินการทันทีเพื่อป้องกันผลกระทบต่าง ๆ ที่จะเกิดขึ้น โดยไม่ต้องรอให้เกิดความเสียหายขึ้นมา ก่อน ซึ่งถือว่าเป็นการซ่อมบำรุงรักษาที่มีประสิทธิภาพที่สุด



รูปที่ 2.1 ระบบการซ่อมบำรุงรักษา (พาราดีน จันทเขตต์, 2014)

การซ่อมบำรุงรักษาที่มีความจำเป็นอย่างยิ่งต่อกระบวนการผลิต ดังนั้น ระบบการซ่อมบำรุงรักษาที่มีประสิทธิภาพ จะส่งผลต่อประสิทธิภาพต่อกระบวนการผลิตเช่นกัน

จากการศึกษาของสมาคมวิศวกรรมเครื่องกลแห่งอเมริกา (American Society for Mechanical Engineering) จะพบว่า ค่าใช้จ่ายในการบำรุงรักษาแบบ Break Down Maintenance (BDM) โดยเฉลี่ยอยู่ที่ \$17 ต่อ 1 แรงม้า (HP) และ Preventive Maintenance (PM) จะมีค่าใช้จ่ายที่อยู่ที่ \$12 ต่อ 1 แรงม้า (HP) อย่างไรก็ตามค่าใช้จ่ายในการบำรุงรักษาที่ต่ำสุดคือการบำรุงรักษาแบบ Condition Base Maintenance (CBM) ซึ่งจะมีค่าใช้จ่ายอยู่ที่ \$8 ต่อ 1 แรงม้า (HP) ซึ่งเมื่อนำเอาการบำรุงรักษาแบบ Condition Base Maintenance (CBM) มาเปรียบเทียบกับบำรุงรักษาแบบ Break Down Maintenance (BDM) และการบำรุงรักษาแบบ Preventive Maintenance (PM) จะเห็นว่าการบำรุงรักษาแบบ Condition Base Maintenance (CBM) จะช่วยลดค่าใช้จ่ายคิดเป็น 52.94% และ 33.33% ดังรูปที่ 2.2



รูปที่ 2.2 ค่าใช้จ่ายในการบำรุงรักษาแบบต่าง ๆ

<http://www.failureprevention.net/services/reliability-and-predictive-maintenance-programs/>

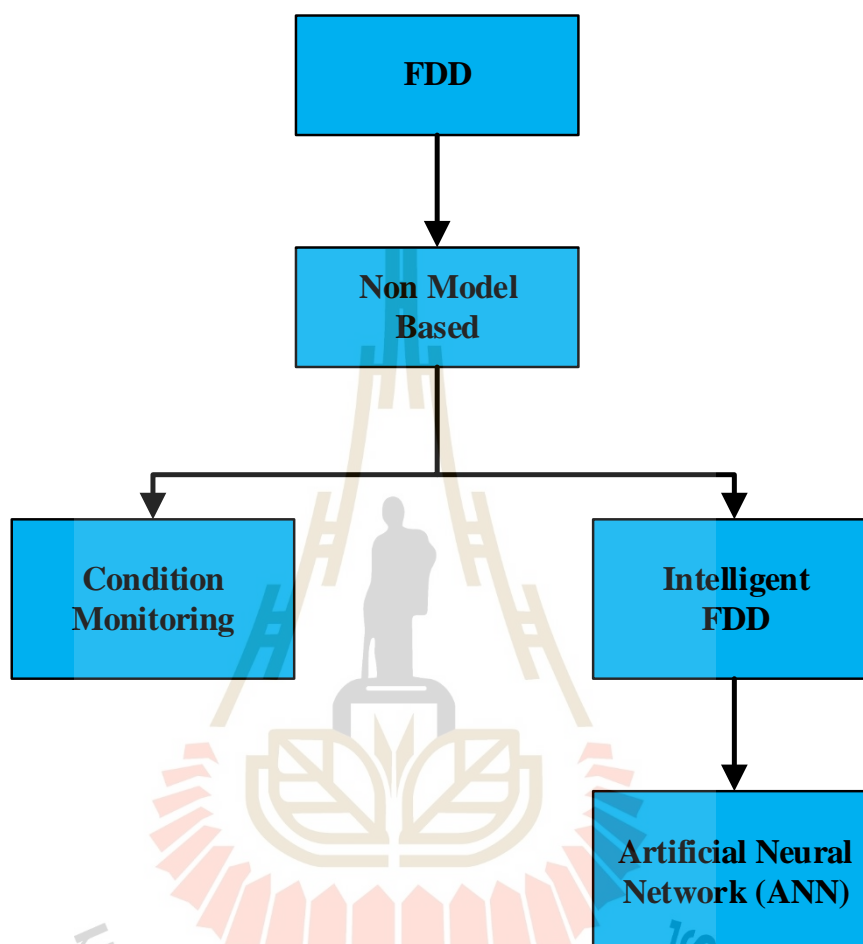
2.2 ระบบการตรวจสอบและวินิจฉัยความบกพร่อง (Fault Detection & Diagnostic)

ระบบการตรวจสอบและวินิจฉัยความบกพร่องสามารถแบ่งออกได้เป็น 2 กลุ่ม คือ ระบบการตรวจสอบและวินิจฉัยความบกพร่องแบบจำลอง (Model Base FDD) และระบบการตรวจสอบและวินิจฉัยความบกพร่องแบบไม่มีแบบจำลอง (Non-model base FDD) ดังรูปที่ 2.3

2.2.1 ระบบการตรวจสอบและวินิจฉัยความบกพร่องแบบจำลอง (Model Base FD) คือ การใช้แบบจำลองทางคณิตศาสตร์มาช่วยในการตรวจสอบและวินิจฉัยความบกพร่อง

2.2.2 ระบบการตรวจสอบและวินิจฉัยความบกพร่องแบบไม่มีแบบจำลอง (Non-Model Base) คือ ระบบการตรวจสอบและวินิจฉัยความบกพร่องโดยไม่ต้องทำแบบจำลองทางคณิตศาสตร์ ซึ่งจะใช้การวิเคราะห์ต่าง ๆ ดังต่อไปนี้ เช่น การวิเคราะห์ทางสถิติศาสตร์ การวิเคราะห์ทางสัญญาณ การวิเคราะห์โดยใช้ปัญญาประดิษฐ์ เป็นต้น ซึ่งระบบระบบการตรวจสอบความผิดปกติและวินิจฉัยความบกพร่องแบบไม่มีแบบจำลอง (Non-Model Base) สามารถแบ่งออกเป็น 2 แบบ คือ Condition Monitoring คือ การติดตามดูการทำงานของเครื่องจักร โดยที่เครื่องจักรยังทำงานดีหรือผิดปกติ และ Intelligence FDD คือการนำเอาปัญญาประดิษฐ์ (Artificial Intelligence) มาช่วยในระบบการตรวจสอบและวินิจฉัยความบกพร่องเครื่องจักร ซึ่งส่วนมากจะ


นำมาใช้กับงานที่สมองมนุษย์ไม่สามารถวิเคราะห์ได้หรืองานที่สลับซับซ้อนหรืองานที่ต้องการความแม่นยำสูง



รูปที่ 2.3 ระบบตรวจสอบและวินิจฉัยความบกพร่องแบบ ไม่มีแบบจำลอง

2.3 แบบจำลองลิเนียร์แบริง (Linear bearing model)

ลิเนียร์แบริงเป็นองค์ประกอบที่สำคัญของเครื่องจักรที่ต้องการเคลื่อนที่แบบเชิงเส้นไม่ว่าจะเป็นการเคลื่อนที่แกน X แกน Y และแกน Z ซึ่งลิเนียร์แบริงมีหน้าที่ 2 อย่างคือ ช่วยรองรับโหลดและลดแรงเสียดทานขนาดเคลื่อนที่ ซึ่งลิเนียร์แบริงสามารถแบ่งส่วนประกอบเป็น 2 ส่วน คือส่วนที่เคลื่อนที่และส่วนที่ไม่เคลื่อนที่ ดังรูปที่ 2.4



รูปที่ 2.4 ส่วนประกอบของลิเนียร์เบริง (Claudio Bianchini and et al., 2010)

ซึ่งสามารถหาความเสียหายของลูกปืนลิเนียร์เบริงได้ดังนี้
สูตรความถี่ของลูกปืนลิเนียร์เบริง

$$f_{ball} = \frac{2V_{ball}}{\pi D_b} \quad (2.1)$$

$$f_{loss} = \frac{V_{ball}}{l} \quad (2.2)$$

เมื่อ	f_{ball}	คือ	ค่าความถี่ของลูกปืนที่เสียหาย
	f_{loss}	คือ	ค่าความถี่ของลูกปืนที่หาย
	V_{ball}	คือ	ค่าความเร็วของลูกปืน
	D_b	คือ	ระยะทางเส้นผ่านศูนย์กลางของลูกปืน
	l	คือ	ระยะห่างจากจุดศูนย์กลางของลูกปืน 2 ลูก

2.4 การแปลงฟูริเยร์แบบเร็ว (Fast Fourier Transform)

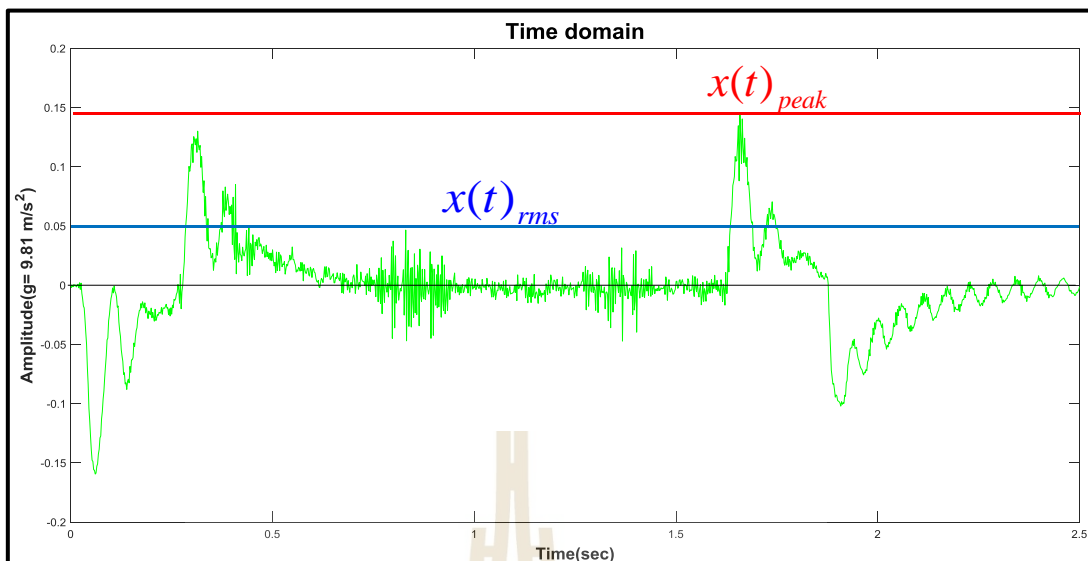
FFT คือการเปลี่ยน โดเมนเวลา (Time Domain) เป็น โดเมนความถี่ (Frequency Domain) เป็นเทคนิคสำคัญที่ใช้สำหรับวิเคราะห์ระบบและวิเคราะห์สัญญาณ ซึ่ง FFT เป็นการแก้ปัญหา Discrete Fourier Transform (DFT) ให้เร็วขึ้น เนื่องจากคำนวณ DFT ให้เร็วพอที่จะคำนวณ DFT ที่ค่า N สูงได้ภายในเวลาที่เหมาะสม DFT ก็จะไม่มีความหมาย ซึ่ง FFT เกิดขึ้นในปี 1965 โดยนักคณิตศาสตร์ 2 คน คือ Cooley และ Tukey เราเรียกวิธีที่การนี้ Cooley-Tukey FFT หรือ CT-FFT ซึ่งทั้ง 2 ท่านได้นำเสนออัลกอริทึม (พีระพล ยูวภูษิตานนท์, 2009) ดังนี้

$$X(m) = \sum_{n=0}^{N-1} x(n) [\cos(2\pi nm / N) - j \sin(2\pi nm / N)] \quad (2.3)$$

โดยที่	$x(n)$	คือ	sample of time domain
	$X(m)$	คือ	Discrete Fourier Transform (DFT) ของ $x(n)$
	N	คือ	2^k
	n	คือ	Sample index
	m	คือ	Each frequency

2.5 Crest factor

ในบางครั้งการวัดค่าสั้นสะเทือนไม่สามารถอธิบายได้ดังนั้นอีกหนึ่งวิธีที่นิยมใช้คือ Crest factor ซึ่ง Crest factor คือ อัตราส่วนของค่าระดับสูงสุดของสัญญาณ (Peak) ต่อค่าเฉลี่ย (RMS) ของสัญญาณ ค่า Crest factor นี้ใช้บ่งบอกว่ามีขนาดของแรงกระแทก (Impact) เกิดขึ้นในสัญญาณมากน้อยเพียงใดดังรูปที่ 2.5



รูปที่ 2.5 โดเมนเวลา (Time domain)

ซึ่งสูตรการหา Crest factor ได้ดังนี้

$$C = \frac{|x(t)_{peak}|}{x(t)_{rms}} \quad (2.4)$$


ในบางครั้งค่าในหน่วยแอมพลิจูดไม่สามารถอ่านค่าได้เนื่องจากค่าที่ได้ไม่ละเอียดเพียงพอ ดังนั้นเราจึงต้องเปลี่ยนค่าเป็นหน่วยเดซิเบล (dB) ซึ่งสามารถหาได้ดังนี้

$$C_{dB} = 20 \log_{10} \frac{|x(t)_{peak}|}{x(t)_{rms}} \quad (2.5)$$


2.6 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียมเป็นการจำลองการทำงานของโครงข่ายประสาทของมนุษย์ดังรูปที่ 2.6 โดยโครงข่ายประสาทของมนุษย์สามารถที่จะเรียนรู้ สามารถฝึกฝนได้ และนำความรู้ที่ฝึกฝนไปแก้ปัญหาดัง ๆ ได้ ทั้งที่เป็นเชิงเส้นหรือไม่เป็นเชิงเส้น ซึ่งโครงข่ายประสาทเทียม

เป็นแนวคิดที่จะทำให้คอมพิวเตอร์สามารถเลียนแบบการทำงานของสมองมนุษย์ได้ ซึ่งโครงข่ายประสาทเทียมเกิดขึ้นมาตั้งแต่ปี ค.ศ. 1943 โดย McCulloch และ Pitts ซึ่งปัจจุบันนี้มีการนำเอาโครงข่ายประสาทเทียมไปประยุกต์ใช้หลายด้าน เช่น งานด้านทางวิศวกรรม งานด้านธุรกิจ งานด้านแพทย์ เป็นต้น ซึ่งโครงข่ายประสาทมนุษย์จะประกอบไปด้วยส่วนประมวลผลซึ่งเรียกว่านิวรอน (Neuron) และทุกนิวรอนจะมีได้หลายอินพุตแต่จะมีได้เพียง 1 เอาต์พุต และทุก ๆ เอาต์พุตจะสามารถแยกไปยังอินพุตของนิวรอนอื่น ๆ ภายในโครงข่ายได้ และทุก ๆ อินพุตจะมีน้ำหนักเป็นตัวกำหนดกำลังในการตัดสินใจและการติดต่อภายใน ซึ่งโครงข่ายประสาทเทียมจะแบ่งออกเป็น 3 ชั้น คือ ชั้นนำเข้า (Input layer) ชั้นซ่อน (Hidden layer) และชั้นนำออก (Output layer) ดังรูปที่ 2.7



รูปที่ 2.6 โครงข่ายประสาทของมนุษย์



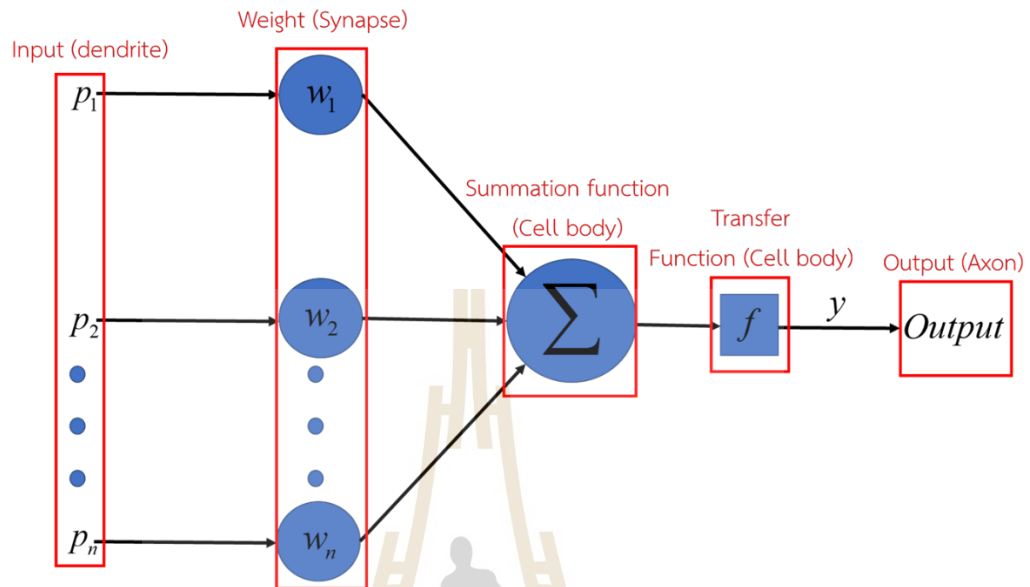
รูปที่ 2.7 โครงข่ายประสาทเทียม

ซึ่งองค์ประกอบของโครงข่ายประสาทเทียมจะประกอบด้วย 5 องค์ประกอบดังรูปที่ 2.8 คือ

- ข้อมูลอินพุต (Input) คือ ข้อมูลนำเข้า
- ฟังก์ชันถ่ายโอน (Transfer function) หน้าที่รวมค่าเอาต์พุต แล้วตัดสินใจว่าจะให้สัญญาณเอาต์พุตออกมาแบบใด
- ค่าน้ำหนัก (Weight) คือ ค่าน้ำหนักที่ได้มาจากการเรียนรู้ของโครงข่ายประสาทเทียม
- ฟังก์ชันผลรวม (Summation function: S) คือ ผลรวมของข้อมูลนำเข้า (p_i) และค่าน้ำหนัก (w_i)

$$S = \sum_{i=1}^n p_i w_i \quad (2.6)$$

- ข้อมูลเอาต์พุต (Output) คือ ผลลัพธ์ที่ได้

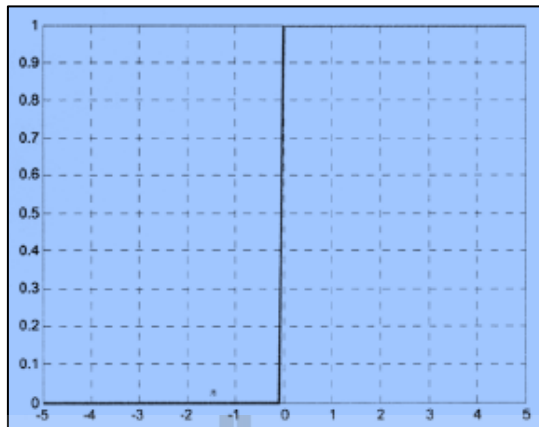


รูปที่ 2.8 องค์ประกอบของโครงข่ายประสาทเทียม

ซึ่งจะมีฟังก์ชันถ่ายโอนเป็นตัวกำหนดว่าเอาต์พุตจะเป็นแบบไหน โดยฟังก์ชันถ่ายโอนมีหลายแบบ เช่น

- ฟังก์ชันถ่ายโอนแบบจำกัดแข็ง (Hardlim) ดังรูปที่ 2.9


$$f(n) = \begin{cases} 0 & : n < 0 \\ 1 & : n \geq 0 \end{cases} \quad (2.7)$$



รูปที่ 2.9 ฟังก์ชันถ่ายโอนแบบจำกัดแข็ง (Hardlim)

- ฟังก์ชันถ่ายโอนแบบจำกัดแข็งสมมาตร (Hardlims) ดังรูปที่ 2.10

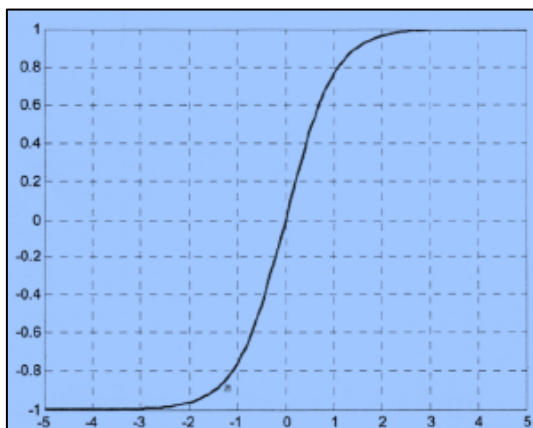
$$f(n) = \begin{cases} -1 & : n < 0 \\ 1 & : n \geq 0 \end{cases} \quad (2.8)$$



รูปที่ 2.10 ฟังก์ชันถ่ายโอนแบบจำกัดแข็งสมมาตร (Hardlims)

- ฟังก์ชันถ่ายโอนแบบแทนซิกมอยด์ (Tansig) ดังรูปที่ 2.11

$$f(n) = \frac{2}{1+e^{-2n}} - 1 = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (2.9)$$




รูปที่ 2.11 ฟังก์ชันถ่ายโอนแบบซิกมอยด์ (Tansig)

- ฟังก์ชันถ่ายโอนแบบเชิงเส้น (Purelin) ดังรูปที่ 2.12

$$f(n) = n$$

(2.10)




รูปที่ 2.12 ฟังก์ชันถ่ายโอนแบบเชิงเส้น (Purelin)

- ฟังก์ชันถ่ายโอนแบบลอกซิกมอยด์ (logsig) ดังรูปที่ 2.13

$$f(n) = \frac{1}{1+e^{-n}}$$

(2.11)




รูปที่ 2.13 ฟังก์ชันถ่ายโอนแบบลอจิกมอยด์ (logsig)

- ฟังก์ชันถ่ายโอนแบบเชิงเส้นจำกัด ดังรูปที่ 2.14

$$f(n) = \begin{cases} -1 & ; n \leq -1 \\ n & ; -1 < n < 1 \\ 1 & ; n \geq 1 \end{cases} \quad (2.12)$$


$$f(n) = \begin{cases} 0 & ; n \leq 0 \\ n & ; 0 < n < 1 \\ 1 & ; n \geq 1 \end{cases} \quad (2.13)$$



รูปที่ 2.14 ฟังก์ชันถ่ายโอนแบบเชิงเส้นจำกัด

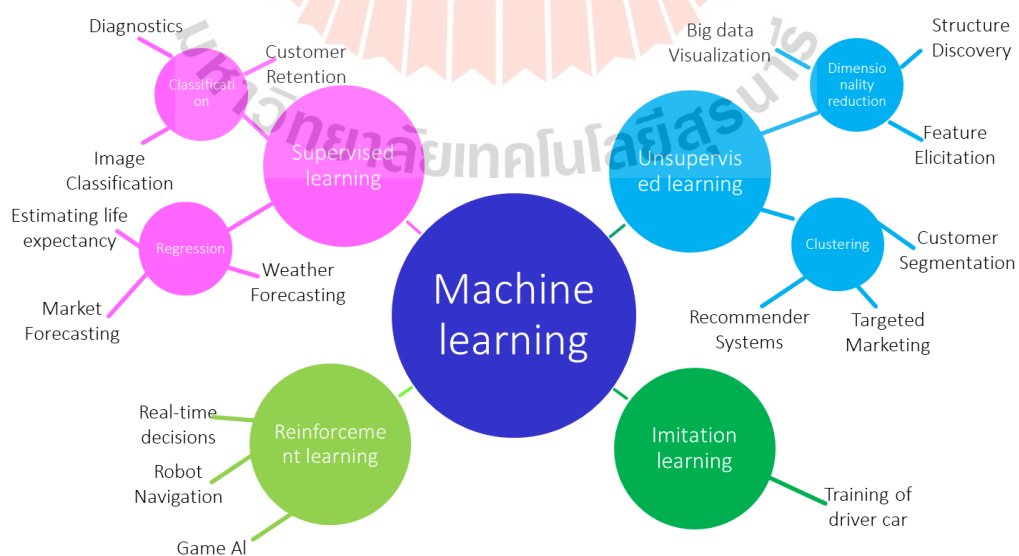
- ฟังก์ชันถ่ายโอนแบบเกาส์เซียน (Gaussian) ดังรูปที่ 2.15

$$f(n) = e^{-\left(\frac{(n-c)^2}{2\sigma^2}\right)} \quad (2.14)$$



รูปที่ 2.15 ฟังก์ชันถ่ายโอนแบบเกาส์เซียน (Gaussian)

ซึ่งโครงข่ายประสาทเทียม (Artificial Neural Network, ANN) สามารถแบ่งเป็นตามการเรียนรู้สามารถแบ่งออกได้ 4 ประเภทดังรูปที่ 2.16 คือ



รูปที่ 2.16 การเรียนรู้ของ Machine learning

2.6.1 การเรียนรู้แบบมีผู้สอน (Supervised learning) คือ การเรียนรู้ที่เตรียมคำตอบไว้แล้ว เมื่อป้อนชุดข้อมูลเข้ากับโครงข่ายประสาทเทียม โครงข่ายประสาทเทียมจะตรวจสอบว่าคำตอบที่ได้มีความถูกต้องหรือไม่ ถ้าคำตอบไม่ถูกต้องโครงข่ายประสาทเทียมก็จะปรับตัวเองเพื่อให้ได้คำตอบที่ดียิ่งขึ้น เช่น ผู้ปกครองสอนลูกว่าผลไม้ชนิดนี้คืออะไร เป็นต้น

2.6.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) คือ การเรียนรู้แบบที่จะแบ่งกลุ่ม (Class) โดยจะดูความเหมือนและความต่าง (Similarities and Differences) โดยกฎของการเรียนรู้แบ่งได้ดังนี้

- ต้องแบ่งด้วยคุณสมบัติของวัตถุ (Feature)

- สิ่งที่เหมือนกันต้องเหมือนกันมากๆ แต่สิ่งที่ต่างกันต้องต่างกันมากๆ (Intra-group similarity should be high, while inter-group similarity should be low)

เช่น การแบ่งประเภทของอาหาร เป็นต้น


2.6.3 การเรียนรู้แบบเชิงบังคับ (Reinforcement learning) เป็นการเรียนรู้โดยการเลียนแบบพฤติกรรมมนุษย์ ซึ่งการเรียนรู้แบบเชิงบังคับเป็นการเรียนรู้ที่มีทั้ง 2 แบบ กล่าวคือ มีทั้งการเรียนรู้แบบมีผู้สอนและการเรียนรู้แบบไม่มีผู้สอน โดยใช้การเรียนรู้แบบไม่มีผู้สอนในระหว่างการสอนที่มีอินพุตเพียงชุดเดียว และใช้การเรียนรู้แบบมีผู้สอนเมื่อได้ค่าเอาต์พุตและบอกว่าถูกหรือผิดแล้วจะให้ผลตอบแทน (Reward) แต่ไม่บอกว่าเอาต์พุตถูกคืออะไร เช่น การแข่งขันหมากรุกคอมพิวเตอร์ระหว่างหุ่นยนต์ AlphaGo กับ Ke Jie ซึ่งเป็นมือหนึ่งของโลก ซึ่งผลการแข่งขันหุ่นยนต์ AlphaGo สามารถเอาชนะไปทั้งหมด 3 เกมรวด เป็นต้น

2.6.4 การเรียนรู้แบบเลียนแบบ (Imitation learning) เป็นการเรียนรู้ที่คล้ายคลึงกับการเรียนรู้แบบเชิงบังคับ โดยการเรียนรู้แบบเชิงบังคับเน้นค่าเอาต์พุตบอกว่าถูกหรือผิดเมื่อเอาต์พุตถูกให้ผลตอบแทน (Reward) แต่การเรียนรู้แบบเลียนแบบผู้เรียนรู้ทำการเรียนรู้จากการสังเกตพฤติกรรมของผู้ที่มีความเชี่ยวชาญ เช่น ตอนที่เรารับรู้การขับรถ เราเรียนรู้จากผู้เชี่ยวชาญการขับรถได้ โดยที่เราเป็นผู้นั่งดูผู้เชี่ยวชาญการขับรถแล้วเราก็นำเอาสิ่งที่ได้ดูมาเลียนแบบ เป็นต้น

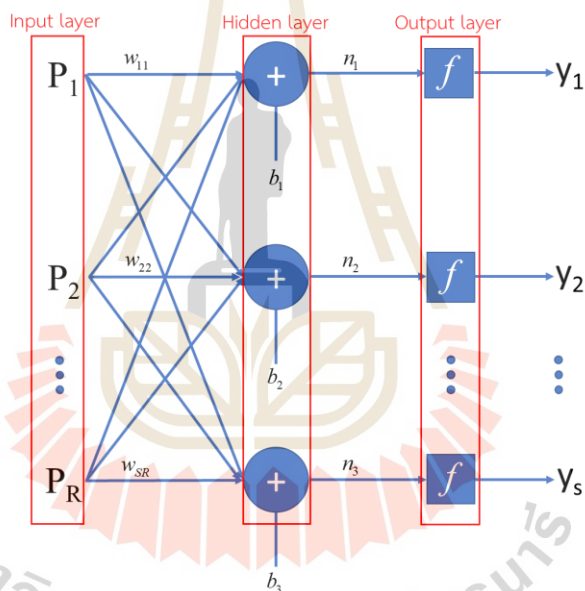
เมื่อพิจารณาสถาปัตยกรรมเครือข่ายประสาทเทียมสามารถแบ่งได้เป็น 2 ประเภท คือ เครือข่ายที่ไปข้างหน้า (Feed forward network) และเครือข่ายป้อนกลับ (Backward propagation of errors or Backpropagation)

- เครือข่ายไปข้างหน้า (Feed forward network) ดังรูปที่ 2.17 สามารถแบ่งออกได้เป็น 2 แบบ คือ แบบ Single layer perceptron เหมาะสมกับปัญหาที่เป็นระบบเชิงเส้น (linear system) ประกอบหลายอินพุตของชั้นนำเข้าก็ได้ ก็ปม (Node) ก็ได้แต่ไม่เกิน 1 ชั้นซ่อน และหลายเอาต์พุตของชั้นนำออก และแบบ Multi-layer perceptron เหมาะกับปัญหาที่ไม่เป็นเชิงเส้น

(Nonlinear system) ซึ่งประกอบด้วยชั้นซ่อนหลายชั้นและจำนวนปมหลายปมในชั้นซ่อน ดังรูปที่ 2.18



รูปที่ 2.17 เครือข่ายไปข้างหน้า (Feed forward network)



รูปที่ 2.18 Multi-layer perceptron

สามารถสร้างสมการได้ดังนี้

$$y = f(Wp + b) \tag{2.15}$$

โดยที่

$$p^T = [p_1 \quad p_2 \quad K \quad p_s] \text{ คือ อินพุตของ MLP}$$

$$b^T = [b_1 \quad b_2 \quad K \quad b_R] \text{ คือ ไบอัสของ MLP}$$


$$W = \begin{pmatrix} W_{11} & K & W_{1R} \\ M & O & M \\ W_{S1} & L & W_{SR} \end{pmatrix} \text{ คือ น้ำหนักของ MLP}$$

สามารถหาค่าความแม่นยำและค่าความผิดพลาดได้ดังนี้

$$\text{Error} = \frac{\text{Target of data} - \text{True of data}}{\text{Target of data}} \quad (2.16)$$

$$\text{Accuracy} = \text{Target of data} - \text{Error} \quad (2.17)$$

ในการคิดคำนวณหาค่าเอาต์พุตของโครงข่ายประสาทเทียม โดยต้องรู้ว่าชั้นอินพุต และชั้นเอาต์พุตเป็นอย่างไร ส่วนชั้นซ่อนเร้นเรากำหนดเอง เมื่อรู้เอาต์พุตแล้วเราสามารถที่เลือก ฟังก์ชันถ่ายโอนได้ สมมุติอินพุตเท่ากับ 3.405 เอาต์พุตมีค่าเท่ากับ 1 ส่วน โดยชั้นซ่อนมี 1 โหนด โดยกำหนดค่าน้ำหนักชั้นอินพุตเท่ากับ 0.63 ค่าน้ำหนักชั้นซ่อนเท่ากับ 0.5 ดังรูปที่ 2.19 โดยเลือกใช้ฟังก์ชันถ่ายโอนแบบซิกมอยด์



รูปที่ 2.19 แบบจำลองเครือข่ายไปข้างหน้า

ผลลัพธ์ของชั้นเอาต์พุต

$$\begin{aligned}
 y_I &= f(W_I p_I + b_I) \\
 y_I &= f((3.405 \times 0.63) + 0.5) \\
 y_I &= f(2.64515) \\
 y_I &= f\left[\frac{1}{1+e^{-2.64515}}\right] = 0.933711
 \end{aligned}$$

ผลลัพธ์ของชั้นซ่อน

$$\begin{aligned}
 y_I &= f((0.933711 \times 0.5) + 0.5) \\
 y_I &= f(0.966856) \\
 y_I &= f\left[\frac{1}{1+e^{-0.966856}}\right] = 0.724492
 \end{aligned}$$

ซึ่งเมื่อสังเกตจะเห็นว่าค่าเอาต์พุตต้องการเท่ากับ 1 แต่ได้ค่าเอาต์พุตเท่ากับ 0.724492 ดังนั้นจะเห็นว่ามีความแม่นยำ (Accuracy) และค่าความผิดพลาด (Error) ดังนี้

$$\text{Error} = \frac{1 - 0.724492}{1} = 0.275508$$

$$\text{Accuracy} = 1 - 0.275508 = 0.724492$$


- เครื่องมือย้อนกลับ (Backward propagation of errors or Backpropagation) เครื่องมือย้อนกลับต้องใช้ในการฝึกฝนด้วยวิธี Gradient Descent ใช้ค่าความผิดพลาดเป็นหลักในการเปลี่ยนแปลงค่า กล่าวคือต้องนำค่าความผิดพลาด (Error) ของชั้นนำออก (Output layer) กลับมาชั้นก่อนหน้านั้นเพื่อสังเกตค่าความผิดพลาดดังรูปที่ 2.20 โดยสามารถเขียนสมการได้ดังนี้

$$F(x) = E[(t - y)^2] \tag{2.18}$$

โดยที่

t คือ เมตริกของเป้าหมาย

y คือ เมตริกของเป้าหมาย



รูปที่ 2.20 เครือข่ายป้อนกลับ (Backward propagation of errors or Backpropagation)

2.7 Analysis of various (ANOVA)

การทดสอบความแปรปรวน (ANOVA) เป็นวิธีที่นิยมใช้มากเนื่องจากมีข้อเด่นดังนี้

- สามารถวิเคราะห์ค่าความแตกต่างได้มากกว่า 2 ประชากร
- สามารถวิเคราะห์ได้มากกว่า 1 ปัจจัย
- สามารถวิเคราะห์ปัจจัยผลกระทบซึ่งกันและกัน (Interaction)

โดยมีข้อกำหนดดังนี้ คือ

- ข้อมูลทุกข้อมูลต้องมีการกระจายข้อมูลแบบปกติ (Normal distribution) เท่านั้น โดยทำการทดสอบ Normality test และ ทดสอบ Homogeneities of Variance Test
- ค่าความผันแปรของข้อมูลของแต่ละประชากรต้องไม่แตกต่างกันอย่างมีนัยสำคัญ

2.8 การคัดแยกโดยใช้กระบวนการทางสถิติ

ซึ่งการคัดแยกข้อมูลเป็นสิ่งสำคัญอย่างยิ่ง ดังนั้น งานวิจัยนี้จึงได้นำเอาวิธีการคัดแยกโดยใช้กระบวนการทางสถิติ ประกอบด้วยค่าเบี่ยงเบนมาตรฐาน (Standard deviation), ค่าความโด่ง (Kurtosis), ค่าเฉลี่ยกำลังสอง (Root Mean Square, RMS)

2.8.1 ค่าเบี่ยงเบนมาตรฐาน (Standard deviation) ในทางวิชาสถิติและความน่าจะเป็นคือการวัดการกระจายตัวแบบหนึ่งของกลุ่มข้อมูล นิยมใช้สัญลักษณ์ อักษรกรีกซิกมาตัวเล็ก (σ) ซึ่งนิยามขึ้นจากรากที่สองของความแปรปรวนดังสมการต่อไปนี้

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (2.19)$$

2.8.2 ค่าความโด่ง (Kurtosis) คือการวัดความถี่ของข้อมูลในแต่ละค่าหรือในแต่ละช่วงของข้อมูล มีความถี่มากน้อยเพียงใด หรือมีความถี่สูงผิดปกติ ซึ่งสามารถเขียนสมการได้ ดังนี้

$$Kurtosis = \frac{1}{N} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{\sigma} \right)^4 \quad (2.20)$$

2.8.3 ค่าเฉลี่ยกำลังสอง (Root Mean Square, RMS) คือการวัดทางสถิติศาสตร์ของปริมาณที่มีการเปลี่ยนแปลงตลอดเวลา ซึ่งสามารถเขียนนิยามได้ดังนี้คือ


$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2.21)$$

โดยที่

σ	คือ ค่าเบี่ยงเบนมาตรฐาน
N	คือ จำนวนเต็มในกลุ่มตัวอย่างทั้งหมด (Sample size)
x_i	คือ ค่าข้อมูลอินพุตของกลุ่มตัวอย่าง
\bar{x}	คือ ค่าเฉลี่ยของข้อมูลทั้งหมด

2.9 ปรัชญ่วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในการตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริงเป็นเรื่องที่ยาก เนื่องจากลูกปืนของลิเนียร์แบริงไม่ได้สัมผัสกับรางเลื่อนตลอดเวลา ซึ่งส่วนที่สัมผัสรางเลื่อนเรียกว่า Area zone ดังรูปที่ 2.21 ดังนั้น หนึ่งวิธีที่นิยมนำมาใช้คือการวัดการสั่นสะเทือน แล้วนำค่าที่ได้มาวิเคราะห์โดยทาง FFT spectrum, Statistics เป็นต้น แล้วนำ Pattern ที่ได้มาจากการวิเคราะห์ แล้วทำการตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริง โดยใช้ปัญญาประดิษฐ์แบบต่าง ๆ เช่น Decision, ANN เป็นต้น โดยงานวิจัยที่ผ่านมาที่เกี่ยวข้องกับงานวิจัยนี้ ซึ่งเราสามารถนำเอางานวิจัยที่เกี่ยวข้องมาพัฒนางานวิจัยได้ดังนี้ โดยแบ่งงานวิจัยที่เกี่ยวข้องออกเป็น 3 แบบดังนี้



รูปที่ 2.21 ส่วนที่สัมผัสกับรางเลื่อน (Area zone)

2.9.1 งานวิจัยที่เกี่ยวข้องกับแบร์ริง

ในปี ค.ศ. 2014 Jaouher Ben Ali and et al. [1] ได้นำเสนอการตรวจจับความบกพร่องของลูกปืนกลมในแบร์ริงโดยใช้การวัดการสั่นสะเทือนมาวิเคราะห์หาคุณลักษณะรูปแบบ ความบกพร่อง แล้วจำแนกคุณลักษณะบกพร่องโดยใช้วิธี Empirical Mode Decomposition (EMD) ซึ่งใช้วิธีทางสถิติศาสตร์แบบ Intrinsic Mode Functions (IMFs) แล้วนำคุณลักษณะที่ได้มาฝึกสอนโดยใช้วิธีโครงข่ายประสาทเทียม Artificial Neural Network (ANN) ซึ่งผลที่ได้จากการใช้โครงข่ายประสาทเทียมคือ เพิ่มศักยภาพในการตรวจจับความบกพร่องของลูกปืนกลมในแบร์ริง

ในปี ค.ศ. 2017 Issam Attoui and et al. [2] ได้นำเสนอการระบุและจำแนกความบกพร่องของลูกปืนในแบร์ริงโดยใช้วิธี time-frequency มาวิเคราะห์หาคุณลักษณะรูปแบบความบกพร่องแล้วใช้ Adaptive Neuro-Fuzzy Inference System (ANFIS) algorithm ในการใช้ระบุและจำแนกความบกพร่องของลูกปืนในแบร์ริงซึ่งผลที่ได้ในการระบุและจำแนกความบกพร่องของลูกปืนในแบร์ริงมีความแม่นยำ 99.83%

ในปี ค.ศ. 2016 Jian Chen and et al. [3] ได้นำเสนอการวินิจฉัยความบกพร่องของแบร์ริงในเครื่องสันดาปภายในโดยใช้การวัดการสั่นสะเทือนมาวิเคราะห์ แล้วนำค่าที่ทดลองจริงและค่าที่ได้จากการสอนจากโครงข่ายประสาทเทียม (ANN) มาเปรียบเทียบกัน โดยผลที่ได้ค่าทั้งสองค่าไม่แตกต่างกัน

ในปี ค.ศ. 2018 Han Liu and et al. [4] ได้นำเสนอการวินิจฉัยความบกพร่องของ Rolling Bearing โดยใช้วิธี Recurrent Neural Networks (RNN) โดยทำการเก็บค่า dB แต่ละค่ามาแล้วทำการเปรียบเทียบแต่ละวิธี โดยวิธีที่ให้ค่าความแม่นยำในการวินิจฉัยความบกพร่องของ Rolling bearing มากที่สุดคือ GRU-based non-linear predictive denoising autoencoders (GRU-NP-DAEs)

ในปี ค.ศ. 2014 Jafar Zarei and et al. [7] ได้นำเสนอการใช้ Artificial Neural Networks (ANNs) ในการตรวจจับและจำแนกความบกพร่องของแบริ่งในมอเตอร์เหนี่ยวนำ โดยแบบสถานะของแบริ่งเป็น 4 แบบ คือ Healthy, Inner race defect, Outer race defect และ Double hole in outer race โดยเปรียบเทียบระหว่างการมี Removing Non-Bearing Fault Component (RNFC) filter และไม่มี RNFC filter ซึ่งผลที่ได้คือการมี Removing Non-Bearing Fault Component (RNFC) filter จะสามารถจำแนกสถานะของแบริ่งทั้ง 4 แบบ ได้ 100%

ในปี ค.ศ. 2011 Claudio Bianchini and et al. [9] ได้นำเสนอตรวจจับความบกพร่องของลิเนียร์แบริ่งใช้การวัดสัญญาณการสั่น โดยการใช้ Statistical methods (rms, crest factor และ Kurtosis)

ในปี ค.ศ. 2010 Bošković and et al [10] ได้เสนอการตรวจจับความบกพร่องของสารหล่อลื่นในมอเตอร์ไฟฟ้าโดยใช้การสั่นสะเทือนได้ทำการทดลองโดยแบ่งมอเตอร์ไฟฟ้าที่มีสารหล่อลื่นเป็น 63 ตัว แล้วแบ่งมอเตอร์ที่มีสารหล่อลื่นเหลือน้อยเป็น 21 โดยทำการวัดแบริ่งเสียหาย 4 สถานะคือ BPFI, BPFO, FTF, BSF ซึ่งผลที่ได้คือ เมื่อสารหล่อลื่นเหลือน้อยค่าการสั่นสะเทือนจะเพิ่มขึ้น 2 สถานะคือ BPFO,BSF

ในปี ค.ศ. 2009 พิระพล ขวัญจิตานนท์ [11] ได้เขียนบทความเกี่ยวกับแปลงฟูริเยร์แบบเร็ว ซึ่งบทความนี้จะทำให้ได้รู้จักความหมายของการแปลงฟูริเยร์แบบเร็ว (Fast Fourier Transform : FFT) และผลการแปลงจากสัญญาณในโดเมนเวลา

2.9.2 งานวิจัยที่เกี่ยวข้องกับปัญญาประดิษฐ์

ในปี ค.ศ. 2018 Zhiqiang Chen and et al. [5] ได้นำเสนองานวิจัยที่เกี่ยวข้องกับการวินิจฉัยความบกพร่องโดยใช้ Deep learning โดยทำการใช้ Deep learning ทั้งหมด 3 วิธี คือ Stacked Auto-Encoders (SAE), Deep Boltzmann Machines (DBM) และ Deep Belief Networks (DBN) ซึ่งผลที่ได้ ทั้ง 3 แบบ ให้ค่าความแม่นยำมากกว่า 99%

ในปี ค.ศ. 2018 Haidong Shao and et al. [6] ได้นำเสนอการตรวจจับความบกพร่องของ Rolling bearing โดยใช้ Continuous Deep Belief Network (CDBN) และใช้ Genetic Algorithm (GA) ในการหาค่าที่เหมาะสม โดยนำค่า Predicted และ Error (%) ของ CDBN มาทำการเปรียบเทียบ

กับอีก 3 วิธีคือ Back Propagation neural network (BP), Support Vector Regression (SVR) และ Standard Deep Belief Network (DBN) ซึ่งผลที่ได้คือ CDBN ให้ค่า Predicted มากที่สุด และให้ค่า Error (%) น้อยที่สุด

ในปี ค.ศ. 2014 Muhammet Unal and et al. [8] ได้นำเสนอการใช้ Genetic algorithm ในการหาค่าที่เหมาะสมในการใช้ ANN ในการวินิจฉัยความบกพร่องของ Rolling bearing ซึ่งงานวิจัยนี้ได้ใช้ Envelope detection และ Fast Fourier Transform (FFT) มาวิเคราะห์ ซึ่งผลที่ได้คือ การใช้ ANN โดยใช้ Genetic algorithm มาช่วยหาค่าที่เหมาะสมโดยใช้ 16 อินพุต สามารถให้ความแม่นยำ 98%

ในปี ค.ศ. 1993 Martin Fodsllette Moller [14] ได้นำเสนอ Scaled conjugate gradient algorithm เป็น Algorithm ที่รวดเร็วที่สุดในการสอนแบบมีผู้สอน (Supervised learning) โดยใช้วิธีการแก้ปัญหาหาพหุคูณของการสอนแบบมีผู้สอนคือ Parameter learning rate และ Momentum constant

2.9.3 งานวิจัยที่เกี่ยวข้องกับระบบการซ่อมบำรุงและระบบตรวจจับความบกพร่อง

ในปี ค.ศ. 2011 Halim Alwi and et al. [12] ได้เขียนถึงทฤษฎีและการออกแบบระบบตรวจสอบความบกพร่องที่ใช้กับโหมคเลื่อน

ในปี ค.ศ. 2014 พาราดีน จันทเขตต์ [13] ได้เขียนถึงระบบการซ่อมบำรุงรักษาเครื่องจักรว่ามีความสำคัญอย่างไรและประเภทของระบบการซ่อมบำรุงรักษา

สรุป

จากการศึกษาปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง ได้มีการนำเสนอวิธีการตรวจจับหาความบกพร่องของลิเนียร์แบริงและลูกกลิ้งแบริง รวมถึงการนำเอาปัญญาประดิษฐ์ (AI) แบบต่าง ๆ เช่น Back Propagation neural network (BP), Support Vector Regression (SVR), Standard Deep Belief Network (DBN), Artificial Neural Network (ANN) เป็นต้น ซึ่งเห็นว่าการนำเอา ANN มาช่วยในการหาความบกพร่องของแบริงให้ค่าความแม่นยำที่สูง ดังนั้น งานวิจัยนี้จึงได้นำเสนอการตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริง โดยจำลองสภาวะที่ลิเนียร์แบริงเสียหายได้ ซึ่งสามารถแบ่งสภาวะลิเนียร์แบริงแบ่งออกเป็น 6 สภาวะ คือ สภาวะลูกปืนปกติ (Healthy bearing), สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage), สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss), สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant), สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) และสภาวะลูกปืนหาย 1 ลูกพร้อม


สารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) โดยได้ทำการเก็บข้อมูล 3พารามิเตอร์ คือ FFT spectrum , Motor current และ Crest factor ทั้ง 6 สถานะแล้วนำข้อมูลที่ได้มาวิเคราะห์โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) เพื่อหาว่าสามารถแยกแยะสถานะทั้ง 6 สถานะได้หรือไม่และให้ค่าความแม่นยำ (Accuracy) เท่าใด



บทที่ 3

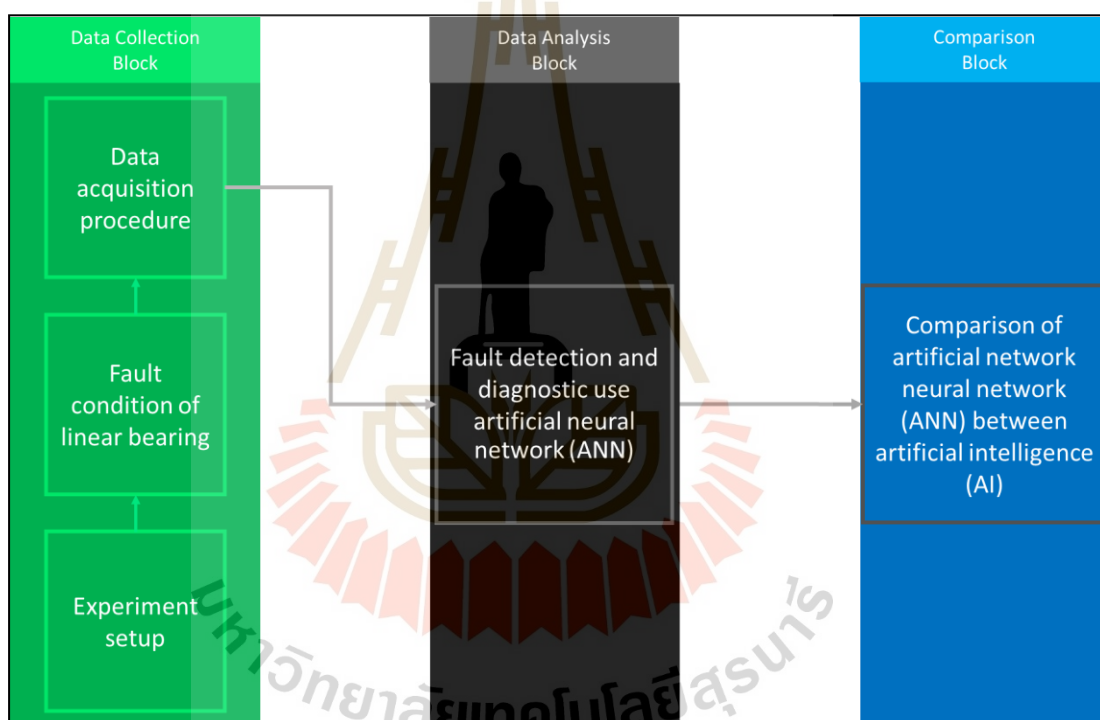
วิธีดำเนินงานวิจัย

การศึกษาวิธีการดำเนินงานวิจัย ประกอบไปด้วยการศึกษาองค์ความรู้ ทฤษฎี และเอกสารที่เกี่ยวข้องกับโครงข่ายประสาทเทียม ระบบการตรวจจับความบกพร่องและจำแนกความบกพร่อง หลังจากนั้นออกแบบระบบการเก็บข้อมูลค่าของลิเนียร์แบริง ขณะสถานะใช้งานจริง โดยทำการเก็บค่าการสั่นสะเทือน ค่ากระแส แล้วนำข้อมูลที่ได้มาวิเคราะห์เพื่อจำแนกสถานะของแบริง โดยใช้เทคนิคดังนี้ FFT spectrum, Motor current และ Crest factor แล้วทำการออกแบบและวิเคราะห์ข้อมูลเพื่อจำแนกสถานะลิเนียร์แบริงโดยใช้โครงข่ายประสาทเทียมแล้วสรุปผลงานวิจัยดังรูปที่ 3.1



รูปที่ 3.1 วิธีการดำเนินงานวิจัย

วิธีการดำเนินงานวิจัยแบ่งออกเป็น 3 ส่วน คือ ส่วนที่เก็บข้อมูล (Data collection block) , ส่วนวิเคราะห์ข้อมูล (Data analysis block) และส่วนเปรียบเทียบ (Comparison block) โดยส่วนที่เก็บข้อมูลประกอบไปด้วย การตั้งค่าการทดลอง (Experiment set up) สภาพความบกพร่องของลิเนียร์แบร์ริง (Fault condition of linear bearing) ขั้นตอนการเก็บข้อมูล (Data acquisition procedure) ,ส่วนวิเคราะห์ข้อมูลประกอบด้วย การตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบร์ริงโดยใช้โครงข่ายโครงข่ายประสาทเทียม (Fault detection and diagnostic use artificial neural network) และส่วนเปรียบเทียบ (Comparison block) ประกอบด้วยการเปรียบเทียบระหว่างโครงข่ายปัญญาประดิษฐ์กับปัญญาประดิษฐ์ ดังรูปที่ 3.2




รูปที่ 3.2 บล๊อควิธีการดำเนินงานวิจัย


3.1 การตั้งค่าการทดลอง (Experiment setup)

การเก็บค่าข้อมูลโดยใช้ Magnetic linear DC Motor (Akribic SGL 100-AUM3-PS4J) โดยทำการเร่งความเร็ว 0.50 m/s และความเร่ง 1.0 m/s² ที่ระยะทาง 400 มิลลิเมตร โดยมีโหลด 7 Kg ติดตั้งไว้ส่วนบนของ linear DC Motor ติดตั้งเซนเซอร์วัดความเร่ง 3 แกน (3 Axis acceleration sensor model PCB 356A32) โดยติดตั้งไว้ใกล้กับลิเนียร์แบร์ริงให้มากที่สุด กำหนดให้แกน X ไป

ตามแนวนอน แกน Y ตั้งฉากกับแกน X และแกน Z ตั้งฉากกับแนวนอน ดังรูปที่ 3.3 ทำการเชื่อมต่อ เซนเซอร์วัดความเร่งเข้ากับ iOtech dynamic signal (640u) เพื่อแปลงสัญญาณทางไฟฟ้าเป็นสัญญาณ ทางกลแล้วต่อสัญญาณเข้าโปรแกรม Ez-analyst เพื่อที่แสดงผลออกมาทางหน้าจอดังรูปที่ 3.4



รูปที่ 3.3 ตำแหน่งการติดตั้งของเซนเซอร์ (Set up sensor of linear bearing)




รูปที่ 3.4 รูปแผนผังการเชื่อมต่ออุปกรณ์ทำการทดลองและการรวบรวมข้อมูล (Schematic of experiment setup and Data Acquisition)

3.2 สภาพความผิดปกติของลิเนียร์แบร์ริง (Fault condition of linear bearing)

ในการศึกษาความบกพร่องของลิเนียร์แบร์ริงแบ่งออกเป็น 6 สภาวะ คือ สภาวะลูกปืนปกติ (Healthy bearing) สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) และสภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant)

3.2.1 สภาวะลูกปืนปกติ (Healthy bearing)


สภาวะที่ลูกปืนสมบูรณ์ไม่เสียหายและมีสารหล่อลื่น 100% กล่าวคือสภาวะที่ลูกปืนสมบูรณ์ที่สุดหรือลูกปืนที่ออกมาจากโรงงานใหม่ ๆ ดังรูปที่ 3.5



รูปที่ 3.5 สภาวะลูกปืนปกติ (Healthy bearing)

3.2.2 สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage)


สภาวะที่ทำให้ลูกปืนเกิดความเสียหาย ซึ่งในงานวิจัยนี้เลือกใช้วิธีที่ทำให้ลูกปืนเสียหาย ใช้วิธีการเจียรระโนโดยใช้เครื่องเจียรระโนดังรูปที่ 3.6



รูปที่ 3.6 สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage)

3.2.3 สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss)

เป็นสภาวะที่ลูกปืนเกิดการหลุดหายซึ่งเกิดได้หลายปัจจัย แต่ในงานวิจัยนี้กระทำโดยการถอดลูกปืนออกมา 1 ลูก ดังรูปที่ 3.7



รูปที่ 3.7 สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss)

3.2.4 สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant)

สภาวะที่ลูกเก็บบไม่มีสารหล่อลื่นหรือไม่มีเลย โดยที่สารหล่อลื่นมีหน้าที่สำคัญใหญ่ ๆ คือลดแรงเสียดทานและป้องกันสนิม โดยงานวิจัยนี้ทำให้สารหล่อลื่นเหลือน้อยด้วยวิธีนำเอาดัลล์ลูกปืนแช่ด้วยน้ำยา Isopropyl alcohol (IPA) แล้วใช้สัญญาณ Ultrasonic ทำความสะอาดโดยใช้เครื่อง BRANSON (2510) ดังรูปที่ 3.8



รูปที่ 3.8 สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant)

3.2.5 สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant)

เป็นการรวม 2 สภาวะคือ สภาวะลูกปืนเสียหาย 1 ลูกกับสภาวะสารหล่อลื่นเหลือน้อย ดังรูปที่ 3.9



รูปที่ 3.9 สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant)

3.2.6 สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant)

เป็นสภาวะที่รวมกัน 2 สภาวะคือลูกปืนหาย 1 ลูกกับสภาวะสารหล่อลื่นเหลือน้อย

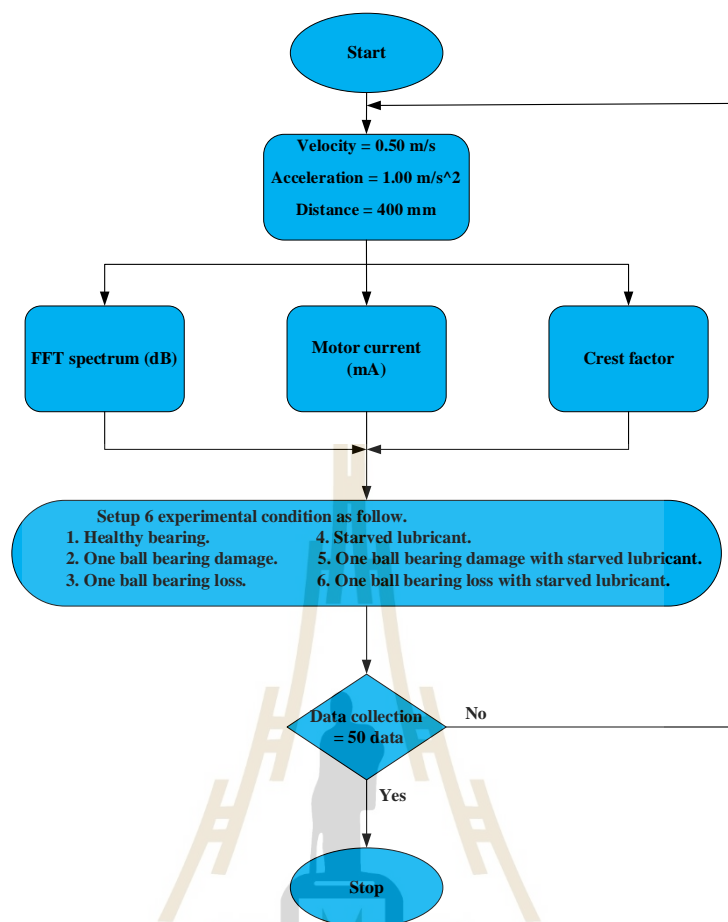
ดังรูปที่ 3.10



รูปที่ 3.10 สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved loss)

3.3 ขั้นตอนการเก็บข้อมูล (Data acquisition procedure)

ทำการเก็บข้อมูล 3 แบบคือ FFT spectrum (dB) โดยใช้โปรแกรม Ez-analyst การเก็บค่าข้อมูล, Motor current (mA) ใช้โปรแกรม Akribis PCSuite การเก็บค่าข้อมูล และการเก็บค่า Crest factor โดยนำค่า Time domain มาคำนวณ โดยทำการเก็บมาทั้งหมด 50 ค่า ทั้ง 6 สภาวะคือ 1) สภาวะลูกปืนปกติ (Healthy bearing) 2) สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) 3) สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) 4) สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) 5) สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) 6) สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) ซึ่งได้ข้อมูลทั้งหมด 300 ชุด ดังรูปที่ 3.11



รูปที่ 3.11 แผนผังขั้นตอนการเก็บข้อมูล (Flowchart of data acquisition procedure)

โดยค่าที่เก็บมาทั้ง 6 สถานะแสดงดังนี้

- สถานะลูกปืนปกติ (Healthy bearing) ดังตารางที่ 3.1

ตารางที่ 3.1 สถานะลูกปืนปกติ (Healthy bearing)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-114.444	1070	4.693
-108.470	1059	4.480
-112.784	1067	4.351
-117.739	1082	4.377
-110.926	1074	4.618
-109.368	1028	5.047

ตารางที่ 3.1 สภาวะลูกปืนปกติ (Healthy bearing) (ต่อ)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-113.129	1102	4.646
-112.032	1091	4.656
-115.086	1051	4.228
-111.399	1025	4.573
-114.321	1080	4.307
-113.104	1079	4.399
-112.281	1044	4.311
-109.251	1056	4.547
-111.851	1087	4.260
-112.299	1067	4.285
-111.467	1093	4.524
-115.182	1061	4.635
-113.878	1074	4.362
-111.139	1035	4.080
-113.303	1078	4.105
-110.854	1041	4.170
-118.491	1017	4.385
-110.410	1036	4.527
-110.171	1047	4.358
-117.528	1049	4.344
-112.617	1017	4.521
-114.930	1051	4.430
-110.307	1057	4.377
-112.849	1075	4.397
-113.384	1021	4.330
-115.002	1095	4.360
-110.384	1020	4.693
-110.118	1052	4.089

ตารางที่ 3.1 สภาวะลูกปืนปกติ (Healthy bearing) (ต่อ)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-113.661	1085	4.233
-117.330	1061	4.164
-111.603	1054	4.654
-109.622	1089	4.120
-115.097	1084	4.360
-110.724	1062	4.377
-111.470	1056	4.360
-112.458	1061	4.191
-115.168	1048	4.360
-111.990	1034	4.377
-114.693	1086	4.285
-113.275	1040	4.693
-116.295	1080	4.444
-117.353	1062	4.377
-115.964	1067	4.477
-111.685	1078	4.094

- สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) ดังตารางที่ 3.2

ตารางที่ 3.2 สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-90.950	1114	3.992
-88.527	1128	4.391
-92.875	1123	3.752
-91.804	1112	4.229
-90.849	1106	4.507
-91.870	1106	3.958
-92.013	1127	3.702
-92.573	1071	4.148
-93.243	1108	3.958
-89.450	1075	4.376
-91.247	1105	3.858
-90.741	1108	3.843
-91.567	1120	3.889
-91.871	1121	4.488
-93.412	1102	4.376
-92.891	1124	4.301
-95.646	1091	4.374
-92.104	1111	3.966
-93.660	1107	4.261
-93.208	1095	4.025
-93.991	1123	4.761
-90.798	1094	3.850
-92.658	1102	3.911
-91.967	1100	3.848
-91.232	1094	5.000
-92.075	1127	4.859
-89.020	1122	4.206
-90.448	1106	4.069

ตารางที่ 3.2 สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) (ต่อ)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-91.988	1131	4.523
-92.445	1116	4.089
-91.155	1089	4.562
-91.816	1129	4.376
-92.723	1081	3.737
-90.462	1102	4.374
-89.973	1089	4.359
-91.593	1100	3.851
-92.250	1096	4.067
-93.733	1111	4.142
-91.308	1078	4.331
-94.621	1092	4.115
-89.223	1085	4.245
-91.433	1134	4.025
-92.455	1101	4.376
-93.818	1102	4.115
-93.011	1101	3.958
-91.444	1109	4.115
-92.496	1076	3.958
-93.648	1088	4.025
-94.694	1092	4.115
-94.433	1100	3.992

- สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) ดังตารางที่ 3.3

ตารางที่ 3.3 สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-93.311	1128	4.606
-95.064	1075	4.088
-98.423	1080	4.178
-92.100	1098	4.008
-100.571	1097	3.587
-97.587	1087	4.021
-96.275	1070	4.151
-95.654	1057	4.482
-96.635	1087	3.983
-96.848	1051	3.984
-94.629	1083	4.726
-96.698	1098	4.320
-93.336	1115	3.702
-94.602	1125	3.506
-97.393	1099	3.721
-99.279	1105	4.117
-93.451	1081	3.735
-97.043	1080	3.910
-91.956	1103	4.414
-95.924	1126	3.806
-98.077	1074	3.957
-97.226	1082	3.798
-97.605	1090	4.260
-96.835	1102	4.041
-95.038	1087	3.926
-95.50	1077	3.798

ตารางที่ 3.3 สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) (ต่อ)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-95.380	1070	4.057
-93.699	1090	3.934
-95.691	1095	3.920
-92.694	1136	3.792
-95.762	1098	3.858
-95.611	1089	3.843
-97.889	1113	3.958
-96.930	1115	4.097
-94.212	1091	3.568
-94.266	1095	3.668
-95.470	1084	4.040
-94.665	1101	4.254
-94.525	1102	3.717
-94.865	1136	4.027
-98.137	1075	3.806
-97.078	1094	4.128
-96.078	1112	3.862
-92.134	1072	3.752
-96.490	1076	3.858
-92.955	1110	3.577
-97.544	1088	4.179
-94.783	1087	4.179
-98.540	1102	4.097
-94.945	1108	3.756

- สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) ดังตารางที่ 3.4

ตารางที่ 3.4 สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-108.494	1080	4.493
-113.082	1119	4.132
-112.223	1087	4.264
-111.308	1105	4.423
-114.130	1073	4.381
-114.110	1086	4.013
-110.743	1117	4.079
-109.190	1101	4.419
-112.505	1097	4.099
-110.541	1113	4.143
-114.784	1143	4.391
-113.215	1081	4.289
-113.167	1073	4.692
-114.598	1122	3.800
-113.220	1113	3.916
-113.801	1102	4.152
-111.805	1088	4.445
-111.481	1083	4.384
-112.138	1045	4.279
-113.158	1084	4.292
-109.480	1089	4.595
-115.196	1077	4.592
-111.296	1092	4.325
-112.332	1089	4.585
-111.821	1095	4.412
-111.410	1108	4.313
-107.845	1118	4.173
-109.979	1083	4.112

ตารางที่ 3.4 สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) (ต่อ)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-110.060	1132	4.389
-112.180	1058	4.079
-111.764	1075	4.265
-113.164	1079	4.171
-110.944	1099	3.787
-112.608	1102	4.478
-111.826	1097	4.445
-113.364	1093	4.138
-110.614	1116	4.105
-114.462	1113	4.116
-110.429	1133	4.020
-112.446	1118	3.963
-111.765	1063	4.605
-109.923	1103	4.426
-113.501	1086	3.898
-112.181	1086	4.706
-112.823	1117	4.108
-113.580	1128	4.002
-111.239	1108	4.208
-109.155	1107	4.121
-111.442	1109	4.303
-111.479	1110	4.248

- สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) ดังตารางที่ 3.5

ตารางที่ 3.5 สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-101.177	1182	4.017
-99.717	1172	4.164
-99.483	1155	4.226
-100.135	1133	4.243
-98.258	1123	3.903
-100.085	1164	4.088
-99.556	1128	4.340
-102.168	1138	4.144
-100.867	1143	4.087
-99.515	1139	4.430
-100.279	1147	4.621
-97.342	1140	4.211
-101.352	1130	4.041
-100.077	1167	3.934
-98.351	1147	4.189
-99.450	1155	3.976
-101.609	1146	4.346
-99.747	1141	4.013
-102.157	1122	4.354
-100.109	1121	4.232
-97.536	1149	4.233
-97.722	1101	4.237
-102.678	1160	4.087
-99.109	1120	4.265
-99.060	1154	4.217
-100.136	1150	4.218
-97.270	1143	4.208

ตารางที่ 3.5 สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) (ต่อ)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-101.392	1167	4.389
-101.684	1121	4.163
-101.316	1160	3.972
-99.097	1132	4.429
-99.847	1134	3.934
-100.620	1132	4.055
-98.948	1122	3.866
-101.618	1157	4.200
-98.659	1187	4.211
-98.665	1120	4.380
-100.291	1112	4.354
-98.955	1158	3.860
-100.198	1148	4.106
-98.574	1189	4.065
-98.028	1139	4.168
-100.581	1137	4.028
-101.594	1133	4.163
-100.122	1151	3.866
-99.307	1150	4.429
-101.369	1157	4.232
-100.980	1162	3.908
-97.182	1158	4.521
-99.470	1143	4.123

- สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) ดังตารางที่ 3.6

ตารางที่ 3.6 สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-94.271	1272	3.670
-95.141	1257	3.970
-94.370	1257	3.778
-94.394	1261	4.354
-94.915	1252	3.832
-95.061	1215	3.509
-94.848	1286	3.542
-93.211	1246	3.430
-92.621	1247	4.249
-92.282	1267	3.941
-92.603	1234	3.703
-95.041	1213	3.698
-94.743	1278	3.828
-94.741	1293	4.039
-94.838	1249	3.887
-92.831	1359	3.705
-92.780	1291	3.934
-92.629	1277	3.416
-93.908	1296	4.159
-93.845	1285	3.858
-96.588	1286	3.744
-94.546	1267	4.260
-93.654	1295	3.886
-91.221	1287	3.724
-91.339	1286	4.161
-93.607	1321	3.952
-94.316	1295	3.952

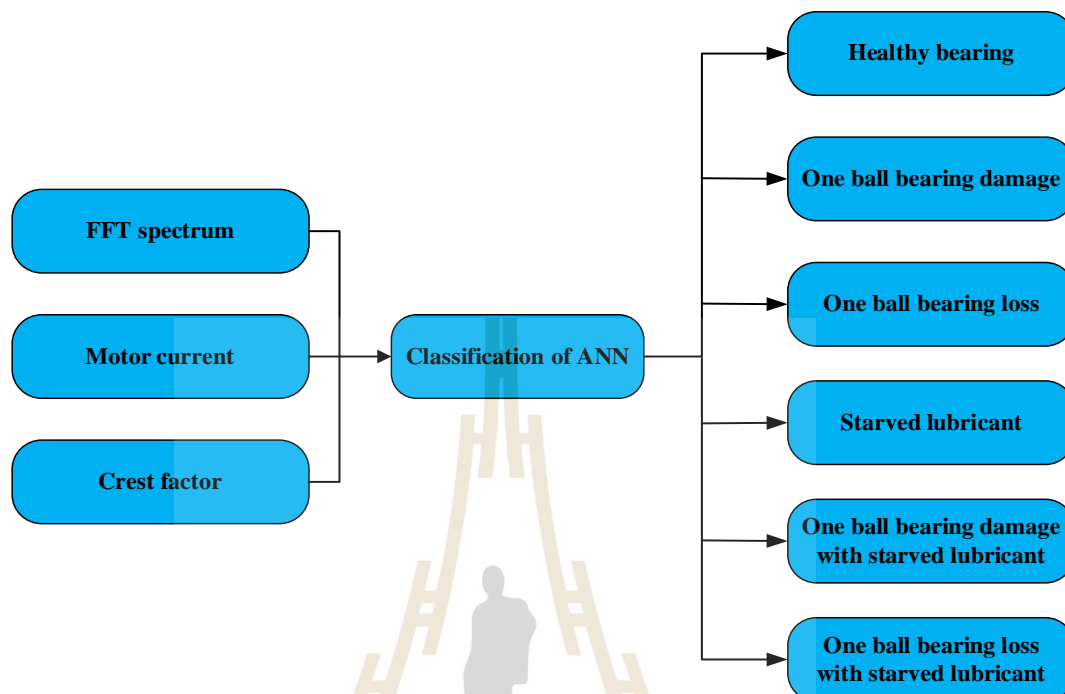
ตารางที่ 3.6 สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) (ต่อ)

FFT Spectrum (dB)	Motor current (mA)	Crest factor
-94.933	1317	4.096
-92.121	1319	4.238
-95.553	1292	3.655
-92.804	1314	3.671
-93.157	1309	3.646
-95.595	1307	4.127
-96.051	1295	4.392
-92.776	1266	4.152
-94.798	1302	3.438
-93.261	1318	4.150
-90.841	1271	3.602
-92.119	1352	4.051
-90.331	1309	4.144
-97.711	1292	3.842
-94.316	1288	3.593
-93.268	1333	4.157
-94.013	1261	3.688
-94.637	1283	3.932
-91.613	1305	3.785
-95.011	1292	3.759
-93.171	1301	3.663
-95.802	1299	3.733
-94.994	1307	3.685


3.4 การตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริงโดยใช้โครงข่ายประสาทเทียม (Fault detection and diagnostic use artificial neural network)

ซึ่งในงานวิจัยนี้จะนำเอาข้อมูลมาทำการแบ่งคัดแยกออกเป็น 3 แบบคือ หนึ่งพารามิเตอร์ (Single parameter) ดังรูปที่ 3.12, สองพารามิเตอร์ (Double parameter) ดังรูปที่ 3.13, สามพารามิเตอร์

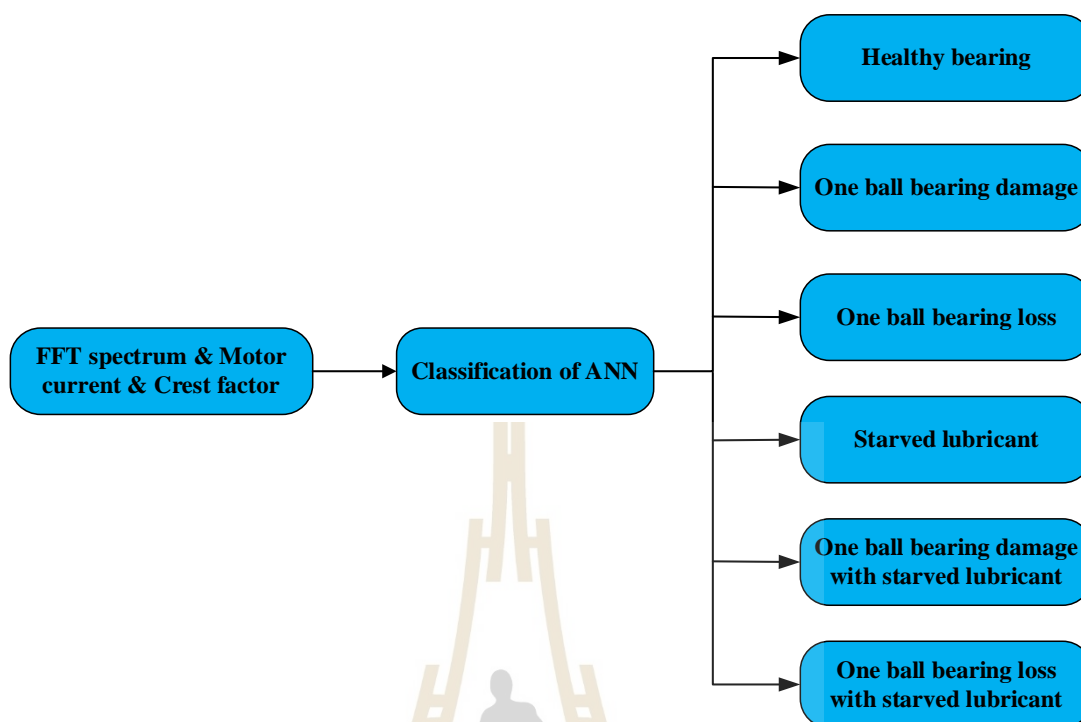
(Triple parameter) ดังรูปที่ 3.14 เพื่อหาพารามิเตอร์ไหนให้ค่าความแม่นยำมากที่สุด



รูปที่ 3.12 แผนผังของหนึ่งพารามิเตอร์ (Schematic of single parameter)



รูปที่ 3.13 แผนผังของสองพารามิเตอร์ (Schematic of double parameter)




รูปที่ 3.14 แผงผังของสามพารามิเตอร์ (Schematic of triple parameter)

นำทั้ง 3 แบบมาเปรียบเทียบกันว่าแบบไหนให้ค่าแม่นยำสุด ซึ่งจะทำให้การเชื่อมต่อโครงข่ายประสาทเทียมออกเป็น 3 แบบ คือ


- หนึ่งพารามิเตอร์ (Single parameter) โดยทำการเชื่อมต่อโครงข่ายประสาทเทียมดังนี้คือ ชั้นขาเข้า (Input) 1 ชั้น, ชั้นซ่อน (Hidden) 10 ชั้น และชั้นออก (Output) 6 ชั้น ดังรูปที่ 3.15 โดยใช้ Scaled conjugate gradient algorithm ในการสอนจะแบ่งข้อมูลดังนี้ 70% ใช้ในการสอน (Training) 15% ใช้ในการตรวจสอบ (Validation) และอีก 15% ใช้สำหรับการทดสอบ (Test)

- สองพารามิเตอร์ (Double parameter) ทำการเชื่อมต่อโครงข่ายประสาทเทียมดังนี้คือ ชั้นขาเข้า (Input) 2 ชั้น, ชั้นซ่อน (Hidden) 10 ชั้น และชั้นออก (Output) 6 ชั้น ดังรูปที่ 3.16 โดยใช้ Scaled conjugate gradient algorithm ในการสอนซึ่งจะแบ่งข้อมูลดังนี้ 70% ใช้ในการสอน (Training) 15% ใช้ในการตรวจสอบ (Validation) และอีก 15% ใช้สำหรับการทดสอบ (Test)


- สามพารามิเตอร์ (Triple parameter) ทำการเชื่อมต่อโครงข่ายประสาทเทียมดังนี้คือ ชั้นขาเข้า (Input) 3 ชั้น, ชั้นซ่อน (Hidden) 10 ชั้น และชั้นออก (Output) 6 ชั้น ดังรูปที่ 3.17 โดยใช้ Scaled conjugate gradient algorithm ในการสอนโดยจะแบ่งข้อมูลดังนี้ 70% ใช้ในการสอน (Training) 15% ใช้ในการตรวจสอบ (Validation) และอีก 15% ใช้สำหรับการทดสอบ (Test)



รูปที่ 3.15 แผนผังของโครงข่ายประสาทเทียมหนึ่งพารามิเตอร์




รูปที่ 3.16 แผนผังของโครงข่ายประสาทเทียมสองพารามิเตอร์



รูปที่ 3.17 แผนผังของโครงข่ายประสาทเทียมสามพารามิเตอร์

3.5 การเปรียบเทียบระหว่างโครงข่ายปัญญาประดิษฐ์กับปัญญาประดิษฐ์

โดยทำการเปรียบเทียบความแม่นยำระหว่างโครงข่ายประสาทเทียมกับปัญญาประดิษฐ์แบบอื่น โดยจะสุ่มมา 2 แบบคือ K-Nearest Neighbors (KNN), Decision Tree ดังรูปที่ 3.18 ใช้โปรแกรม Matlab 2020a ในการวิเคราะห์



รูปที่ 3.18 การเปรียบเทียบปัญญาประดิษฐ์ชนิดต่าง ๆ

สรุป

ในการดำเนินงานวิจัยต้องมีความเข้าใจเกี่ยวกับการวัดการสั้นสะท้อนรวมถึงความเข้าใจเกี่ยวกับปัญญาประดิษฐ์ สามารถแบ่งออกได้เป็น 3 ส่วนใหญ่ ๆ ดังนี้

ส่วนที่ 1 เป็นการออกแบบการติดตั้งอุปกรณ์ วิธีการจำลองความเสียหายของลิเนียร์แบริง รวมไปถึงการเก็บข้อมูล

ส่วนที่ 2 เป็นการนำเอา Artificial neural network (ANN) มาทำการตรวจจับและวินิจฉัยความบกพร่องลิเนียร์แบริงเพื่อหาพารามิเตอร์ไหนให้ค่าความแม่นยำมากที่สุด โดยทำการแบ่งข้อมูลที่ได้ออกเป็น 3 ชุดดังนี้ Training (70%), Validation (15%), Test (15%) และใช้ Scaled conjugate gradient algorithm มาสอน (Train)

ส่วนที่ 3 เป็นส่วนของการนำเอาของพารามิเตอร์ที่ให้ค่ามากที่สุดมาเปรียบเทียบกับปัญญาประดิษฐ์แบบอื่น ๆ เพื่อหาพารามิเตอร์แบบไหนให้ค่าความแม่นยำมากที่สุด โดยงานวิจัยนี้ได้สุ่มปัญญาประดิษฐ์มา 2 แบบคือ K-Nearest Neighbors (KNN), Decision Tree

บทที่ 4

ผลการทดลองและวิเคราะห์ผลการทดลอง

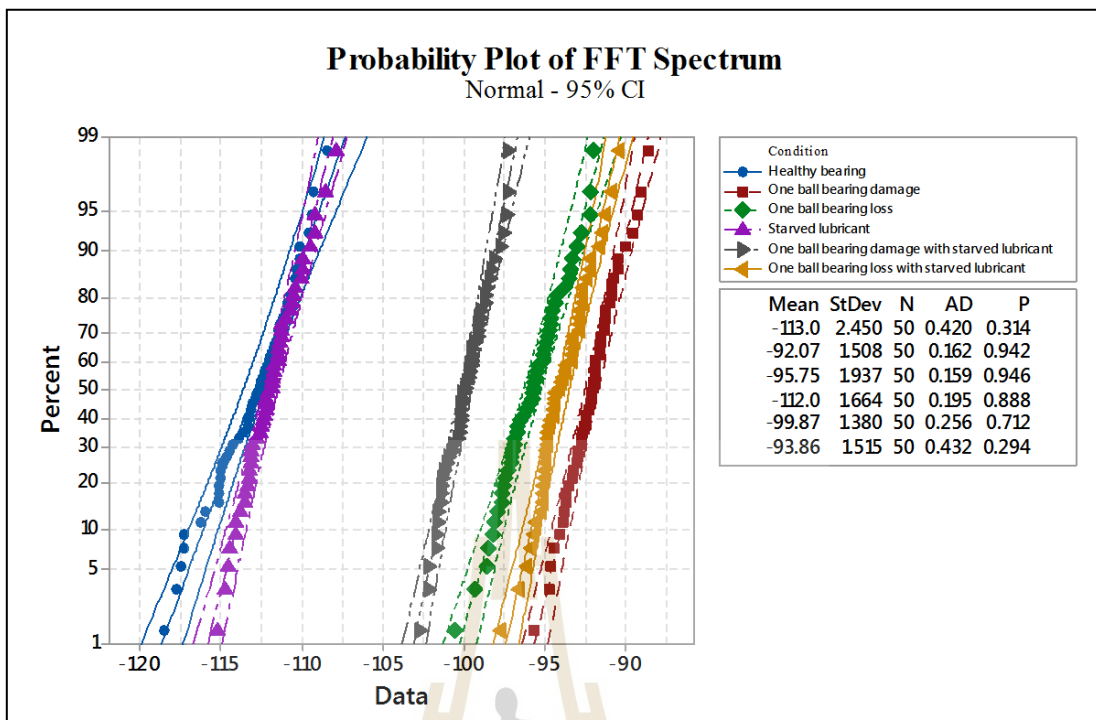
ผลการทดลองและวิเคราะห์ผลการทดลองแบ่งออก 4 หัวข้อใหญ่ ๆ คือ ขั้นตอนการเก็บข้อมูล (Data acquisition procedure), ผลการทดลองการคัดแยกโดยใช้กระบวนการทางสถิติ, การตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบริงโดยใช้โครงข่ายประสาทเทียม (Fault detection and diagnostic use artificial neural network), การเปรียบเทียบระหว่างโครงข่ายประสาทเทียมกับปัญญาประดิษฐ์แบบอื่น ๆ (Comparison of artificial neural network between artificial intelligence) และผลการทดลองจากโปรแกรม Simulink ใน Matlab 2020a ดังต่อไปนี้

4.1 ขั้นตอนการเก็บข้อมูล (Data acquisition procedure)


นำข้อมูลที่ได้ทั้ง 3 ปัจจัย คือ FFT Spectrum, Motor current และ Crest Factor โดยนำเอาข้อมูลทั้ง 6 สถานะมาแยกออกเป็นสองกลุ่ม คือ กลุ่มหนึ่งปัจจัย (Single) ประกอบด้วย สถานะลูกปืนปกติ (Healthy bearing), สถานะลูกปืนเสียหาย 1 ลูก (One ball bearing damage), สถานะลูกปืนหาย 1 ลูก (One ball bearing loss), สถานะสารหล่อลื่นเหลือน้อย (Starved lubricant) ส่วนอีกกลุ่มเป็นกลุ่มรวมปัจจัย (Combine) ประกอบด้วยสถานะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) และสถานะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) โดยนำเอาข้อมูลที่ได้ทั้งหมดมาวิเคราะห์ทางสถิติ ใช้วิธี Analysis of Variance (ANOVA) เพื่อหาว่าสามารถแยกแยะได้หรือไม่ ซึ่งการวิเคราะห์โดยใช้วิธี ANOVA จะมีข้อกำหนด ดังนี้ คือข้อมูลที่ได้ต้องเป็นข้อมูลภาวะปกติ (Normality) กล่าวคือ ข้อมูลที่ได้ต้องไม่ใช่ข้อมูลที่ทำขึ้นหรือสร้างขึ้น ต้องเป็นข้อมูลที่ได้มาจากการทดลองจริง และค่าความผันแปรของข้อมูลของแต่ละประชากรจะต้องไม่แตกต่างกันอย่างมีนัยสำคัญ

4.1.1 FFT spectrum

จากการตรวจสอบข้อมูลที่ได้มาพบว่าข้อมูลภาวะปกติ (Normality) เป็นข้อมูลเนื่องจากค่า Probability value หรือ ค่า P-Value มีค่ามากกว่า 0.05 ที่ความเชื่อมั่น 95% ดังรูปที่ 4.1



รูปที่ 4.1 ค่าความน่าจะเป็นของ FFT Spectrum ที่ค่าความเชื่อมั่น 95%



รูปที่ 4.2 Boxplot of FFT spectrum at velocity 0.5 m/s

จากรูปที่ 4.2 พบว่าค่ากลาง (Mean) ของแต่ละสภาวะ 6 สภาวะ โดยสภาวะลูกปืนปกติ (Healthy bearing) มีค่า -112.9780 dB, สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) มีค่าเท่ากับ -92.0682 dB, สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) มีค่าเท่ากับ -95.7481 dB, สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) มีค่าเท่ากับ -111.9600 dB, สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) มีค่าเท่ากับ -99.8688 dB และสภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) มีค่าเท่ากับ -93.8644 dB

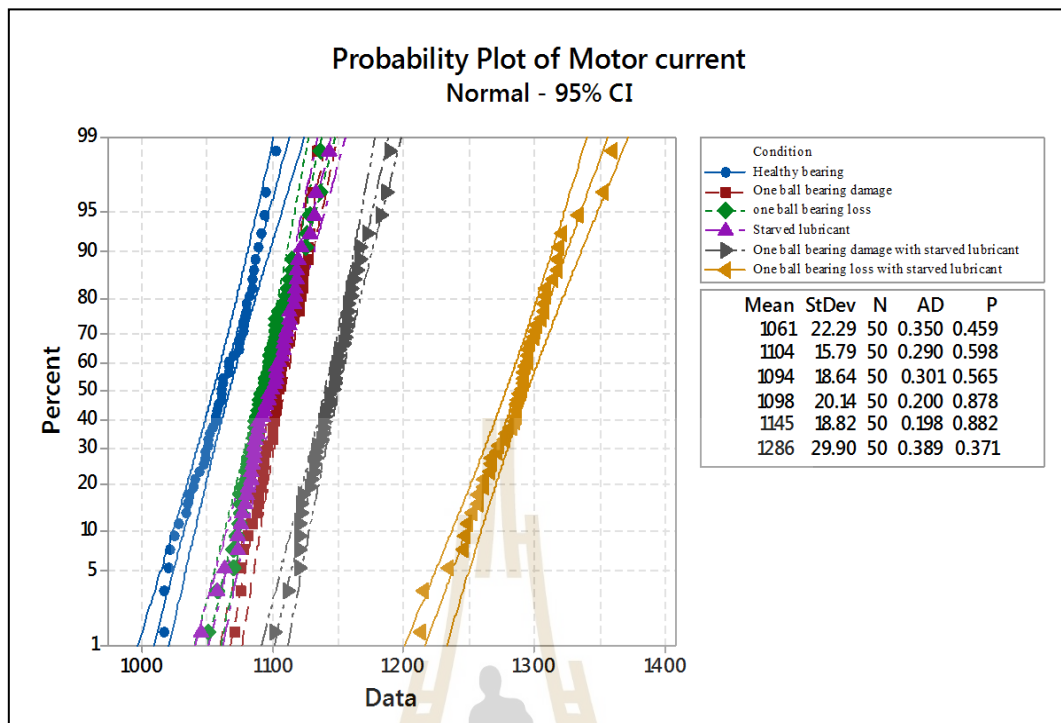
ตารางที่ 4.1 การเปรียบเทียบค่า FFT spectrum ระหว่างสภาวะลูกปืนปกติกับสภาวะอื่น ๆ

Target	Fault bearing conditions	Delta	%
Healthy bearing	One ball bearing damage	20.909	18.51
Healthy bearing	One ball bearing loss	17.230	12.86
Healthy bearing	Starved lubricant bearing	1.018	0.90
Healthy bearing	One ball bearing damage with starved lubricant	13.109	11.60
Healthy bearing	One ball bearing loss with starved lubricant	19.113	12.51


จากตารางที่ 4.1 พบว่าค่าความแตกต่างมากที่สุดจะอยู่ที่สภาวะลูกปืนปกติ (Healthy bearing) เปรียบเทียบกับสภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) โดยมีค่าเท่ากับ 18.51% และค่าความแตกต่างที่น้อยที่สุดอยู่ที่สภาวะลูกปืนปกติ (Healthy bearing) เปรียบเทียบกับสภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) โดยมีค่าเท่ากับ 0.90% โดยไม่สามารถที่แยกแยะความแตกต่างได้เนื่องจากค่า Delta น้อยกว่า 5%

4.1.2 Motor current

จากการตรวจสอบว่าข้อมูลที่ได้นำมาพบว่าข้อมูลสภาวะปกติ (Normality) ที่ได้มาเป็นข้อมูลเนื่องจากค่า Probability value หรือ ค่า P-Value มีค่ามากกว่า 0.05 ที่ความเชื่อมั่น 95% ดังรูปที่ 4.3



รูปที่ 4.3 ค่าความน่าจะเป็นของ Motor current ที่ค่าความเชื่อมั่น 95%



รูปที่ 4.4 Boxplot of Motor current at velocity 0.5 m/s

จากรูปที่ 4.4 เราจะทราบว่าค่ากลาง (Mean) ของแต่ละสภาวะ 6 สภาวะ โดยสภาวะลูกปืนปกติ (Healthy bearing) มีค่าเท่ากับ 1060.56 mA, สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) มีค่าเท่ากับ 1104.48 mA, สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) มีค่าเท่ากับ 1093.92 mA, สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) มีค่าเท่ากับ 1097.90 mA, สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) มีค่าเท่ากับ 1144.78 mA และสภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) มีค่าเท่ากับ 1286.08 mA


ตารางที่ 4.2 การเปรียบเทียบค่า Motor current ระหว่างสภาวะลูกปืนปกติกับสภาวะอื่น ๆ

Target	Fault bearing conditions	Delta	%
Healthy bearing	One ball bearing damage	43.920	4.14
Healthy bearing	One ball bearing loss	33.360	3.15
Healthy bearing	Starved lubricant bearing	37.340	3.52
Healthy bearing	One ball bearing damage with starved lubricant	84.220	7.94
Healthy bearing	One ball bearing loss with starved lubricant	225.520	21.26


จากตารางที่ 4.2 พบว่าค่าความแตกต่างมากที่สุดจะอยู่ที่สภาวะลูกปืนปกติ (Healthy bearing) เปรียบเทียบกับสภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) โดยมีค่าเท่ากับ 21.26% และค่าความแตกต่างที่น้อยที่สุดอยู่ที่สภาวะลูกปืนปกติ (Healthy bearing) เปรียบเทียบกับสภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) โดยมีค่าเท่ากับ 3.15% ซึ่งไม่สามารถแยกแยะความแตกต่างได้ เนื่องจากค่า Delta น้อยกว่า 5%

4.1.3 Crest factor

จากการตรวจสอบข้อมูลที่ได้พบว่า ข้อมูลที่ได้มาเป็นข้อมูลภาวะปกติ (Normality) เนื่องจากค่า Probability value หรือ ค่า P-Value มีค่ามากกว่า 0.05 ที่ความเชื่อมั่น 95% ดังรูปที่ 4.5



รูปที่ 4.5 ค่าความน่าจะเป็นของ Crest factor ที่ค่าความเชื่อมั่น 95%



รูปที่ 4.6 Boxplot of Crest factor at velocity 0.5 m/s

จากรูปที่ 4.6 พบว่าค่ากลาง (Mean) ของแต่ละสภาวะ 6 สภาวะ โดยสภาวะลูกปืนปกติ (Healthy bearing) มีค่าเท่ากับ 4.40066, สภาวะลูกปืนเสียหาย 1 ลูก (One ball bearing damage) มีค่าเท่ากับ 4.16690, สภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) มีค่าเท่ากับ 3.97500, สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) มีค่าเท่ากับ 4.22025, สภาวะลูกปืนเสียหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing damage with starved lubricant) มีค่าเท่ากับ 4.16893 และ สภาวะลูกปืนหาย 1 ลูกพร้อมสารหล่อลื่นเหลือน้อย (One ball bearing loss with starved lubricant) มีค่าเท่ากับ 3.86764

ตารางที่ 4.3 การเปรียบเทียบค่า Crest factor ระหว่างสภาวะลูกปืนปกติกับสภาวะอื่นๆ

Target	Fault bearing conditions	Delta	%
Healthy bearing	One ball bearing damage	0.234	5.31
Healthy bearing	One ball bearing loss	0.426	9.67
Healthy bearing	Starved lubricant bearing	0.180	4.10
Healthy bearing	One ball bearing damage with starved lubricant	0.232	5.27
Healthy bearing	One ball bearing loss with starved lubricant	0.533	12.11

จากตารางที่ 4.3 พบว่าค่าความแตกต่างมากที่สุดจะอยู่ที่สภาวะลูกปืนปกติ (Healthy bearing) เปรียบเทียบกับสภาวะลูกปืนหาย 1 ลูก (One ball bearing loss) โดยมีค่าเท่ากับ 12.11% และค่าความแตกต่างที่น้อยที่สุดอยู่ที่สภาวะลูกปืนปกติ (Healthy bearing) เปรียบเทียบกับสภาวะสารหล่อลื่นเหลือน้อย โดยมีค่าเท่ากับ 4.10% ซึ่งไม่สามารถแยกแยะความแตกต่างได้ เนื่องจากค่า Delta น้อยกว่า 5%


4.2 ผลการทดลองการคัดแยกโดยใช้กระบวนการทางสถิติ

โดยทำการนำข้อมูลทั้งหมดมา 300 ข้อมูลมาทำการคัดแยกโดยใช้กระบวนการทางสถิติ โดยงานวิจัยนี้หาค่าเบี่ยงเบนมาตรฐานซึ่งแสดงดังรูปที่ 4.7-4.9 ค่าความโด่งแสดงดังรูปที่ 4.10-4.12 และค่าเฉลี่ยกำลังสองแสดงดังรูปที่ 4.13-4.15 ของแต่ละพารามิเตอร์ (FFT spectrum, Motor current, Crest factor) ซึ่งจะแบ่งออกเป็น 6 สภาวะดังนี้คือ ข้อมูลตั้งแต่ 1-50 (Healthy bearing) ,51-100 (One

ball bearing damage), 101-150 (One ball loss bearing loss) , 151-200 (Starved lubricant) , 201-250 (One ball bearing damage with starved lubricant) , 251-300 (One ball bearing loss with starved lubricant)


4.2.1 ค่าเบี่ยงเบนมาตรฐาน (Standard deviation)

- FFT Spectrum




รูปที่ 4.7 ค่าเบี่ยงเบนมาตรฐานของ FFT spectrum

- Motor current



รูปที่ 4.8 ค่าเบี่ยงเบนมาตรฐานของ Motor current


- Crest factor



รูปที่ 4.9 ค่าเบี่ยงเบนมาตรฐานของ Crest factor


4.2.2 ค่าความโด่ง (Kurtosis)

- FFT spectrum



รูปที่ 4.10 ค่าความโด่งของ FFT spectrum


-Motor current



รูปที่ 4.11 ค่าความโค้งของ Motor current

มหาวิทยาลัยเทคโนโลยีสุรนารี


- Crest factor



รูปที่ 4.12 ค่าความโด่งของ Crest factor


4.2.3 ค่าเฉลี่ยกำลังสอง (Root Mean Square, RMS)

- FFT spectrum




รูปที่ 4.13 ค่าเฉลี่ยกำลังสองของ FFT spectrum

- Motor current



รูปที่ 4.14 ค่าเฉลี่ยกำลังสองของ Motor current

- Crest factor




รูปที่ 4.15 ค่าเฉลี่ยกำลังสองของ Crest factor

4.3 การตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์แบร์ริงโดยใช้โครงข่ายประสาทเทียม (Fault detection and diagnostic use artificial neural network)

นำเอาข้อมูลที่เก็บได้มาวิเคราะห์ โดยใช้ Artificial neural network (ANN) แล้วนำมาเปรียบเทียบว่าพารามิเตอร์แบบไหนให้ค่าความแม่นยำ (Accuracy) ที่สุด โดยแบ่งหัวข้อมออกเป็น 3 หัวข้อใหญ่คือ หนึ่งพารามิเตอร์, สองพารามิเตอร์และสามพารามิเตอร์ โดยเราแบ่งข้อมูลทั้งหมด 300 ชุด แบ่งออกเป็น Training 210 ชุด Validate 45 ชุด และ Test 45 ชุด

4.3.1 หนึ่งพารามิเตอร์ (Single parameter)

- FFT spectrum



รูปที่ 4.16 Confusion of FFT spectrum

จากรูปที่ 4.16 พบว่าค่าความแม่นยำสำหรับการสอน (Training) มีค่าเท่ากับ 61.4% การตรวจสอบ (Validation) มีค่าเท่ากับ 57.8% และการทดสอบ (Test) มีค่าเท่ากับ 66.7% และเมื่อรวมทั้งหมดมีค่าความแม่นยำเท่ากับ 61.7% ซึ่งเราสามารถคำนวณหาความแม่นยำได้ดังนี้

$$Accuracy = \frac{\text{True of data}}{\text{Total of data}} \tag{4.1}$$

- Training

จากรูปที่ 4.7 (a) ค่าข้อมูลทั้งหมดที่เอามา Train มีทั้งหมด 210 ชุด และมีค่าที่ถูกต้องทั้งหมด 17+30+16+24+30+12 ดังนั้นเราสามารถหาความแม่นยำ ดังนี้

$$Accuracy_{Training} = \frac{17 + 30 + 16 + 24 + 30 + 12}{210} \times 100 = 61.4\%$$

- Validation

จากรูปที่ 4.7 (b) ค่าข้อมูลทั้งหมดที่เอามา Validation มีทั้งหมด 45 ชุด ดังนั้น ค่าความแม่นยำดังนี้

$$Accuracy_{Validation} = \frac{3+6+5+2+7+3}{45} \times 100 = 57.8\%$$

- Test

จากรูปที่ 4.7 (c) ค่าข้อมูลทั้งหมดที่เอามา Test มีทั้งหมด 45 ชุด ดังนั้น ค่าความแม่นยำ ดังนี้

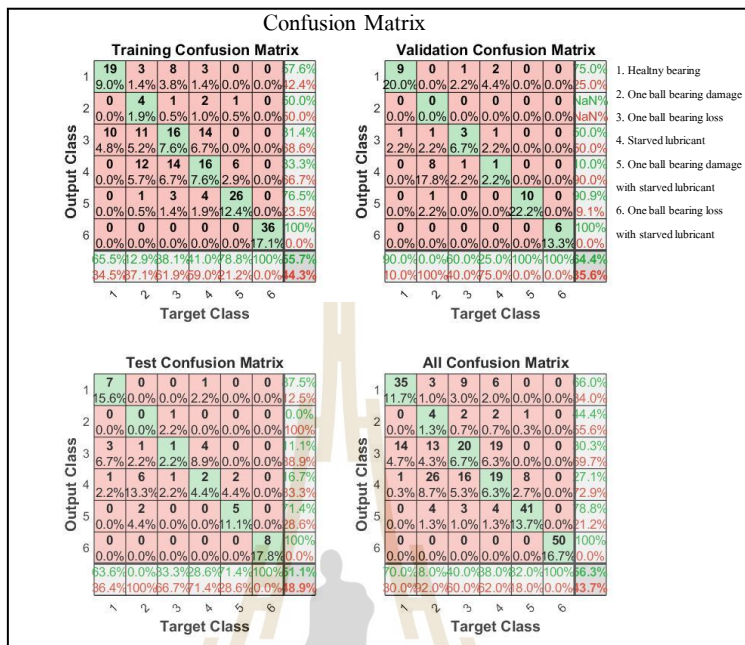
$$Accuracy_{Test} = \frac{7+4+5+3+8+3}{45} \times 100 = 66.7\%$$

- All

จากรูปที่ 4.7 (b) ค่าข้อมูลทั้งหมดที่เอามา All มีทั้งหมด 300 ชุด ดังนั้น ค่าความแม่นยำ ดังนี้

$$Accuracy_{All} = \frac{27+40+26+29+45+18}{300} \times 100 = 61.7\%$$

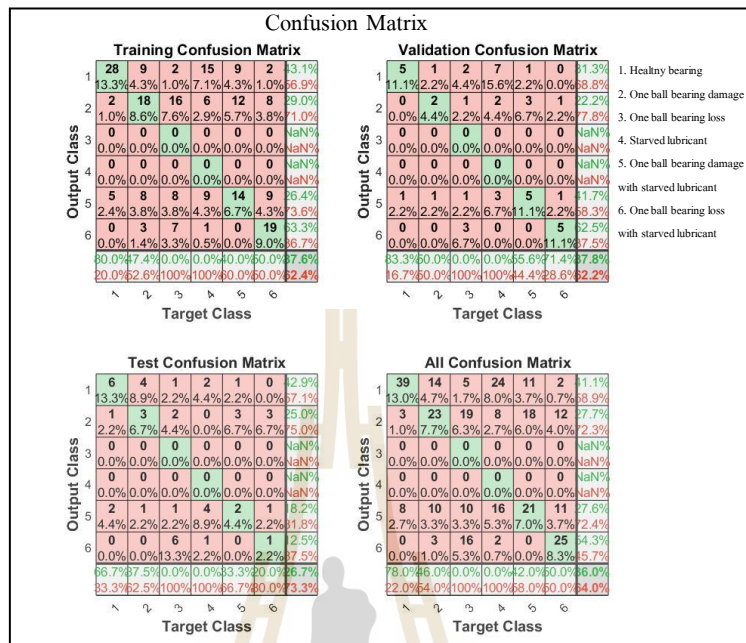
- Motor current



รูปที่ 4.17 Confusion of Motor current

จากรูปที่ 4.17 พบว่าค่าความแม่นยำสำหรับการสอน (Training) มีค่าเท่ากับ 55.7% การตรวจสอบ (Validation) มีค่าเท่ากับ 64.4% และการทดสอบ (Test) มีค่าเท่ากับ 51.1% และเมื่อรวมทั้งหมดมีค่าความแม่นยำเท่ากับ 56.3%

- Crest factor

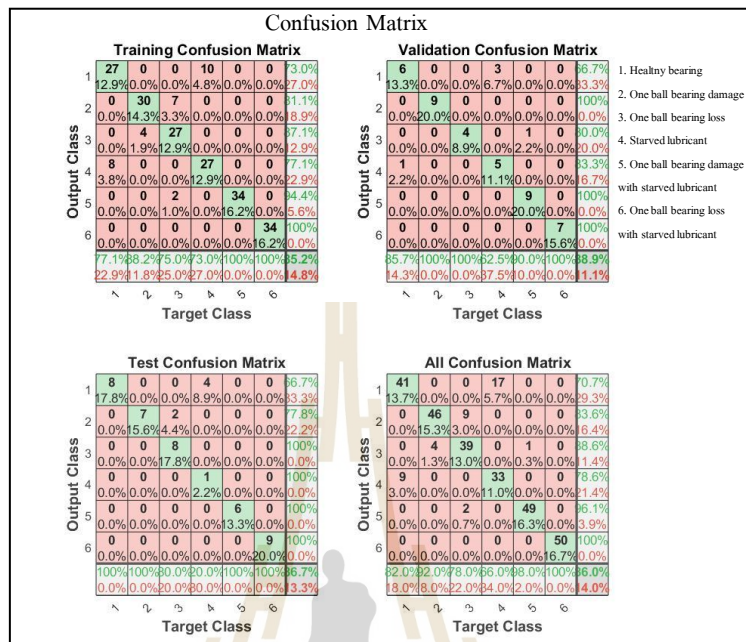


รูปที่ 4.18 Confusion of Crest factor

จากรูปที่ 4.18 พบว่าค่าความแม่นยำสำหรับการสอน (Training) มีค่าเท่ากับ 37.6% การตรวจสอบ (Validation) มีค่าเท่ากับ 37.8% และการทดสอบ (Test) มีค่าเท่ากับ 26.7% และเมื่อรวมทั้งหมดมีค่าความแม่นยำเท่ากับ 36.0%

4.3.2 สองพารามิเตอร์ (Double parameter)

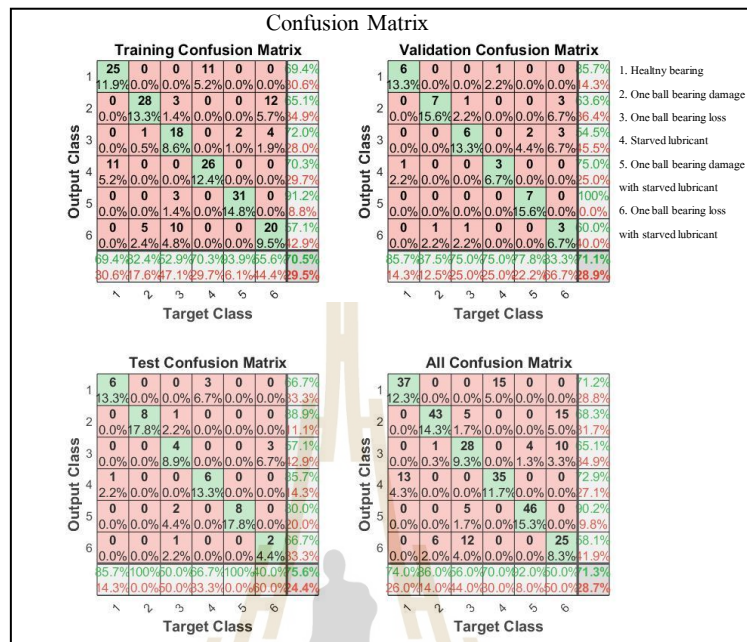
- FFT spectrum & Motor current



รูปที่ 4.19 Confusion of FFT spectrum & Motor current

จากรูปที่ 4.19 พบว่าค่าความแม่นยำสำหรับการสอน (Training) มีค่าเท่ากับ 85.2% การตรวจสอบ (Validation) มีค่าเท่ากับ 88.9% และการทดสอบ (Test) มีค่าเท่ากับ 86.7% และเมื่อรวมทั้งหมดมีค่าความแม่นยำเท่ากับ 86.0%

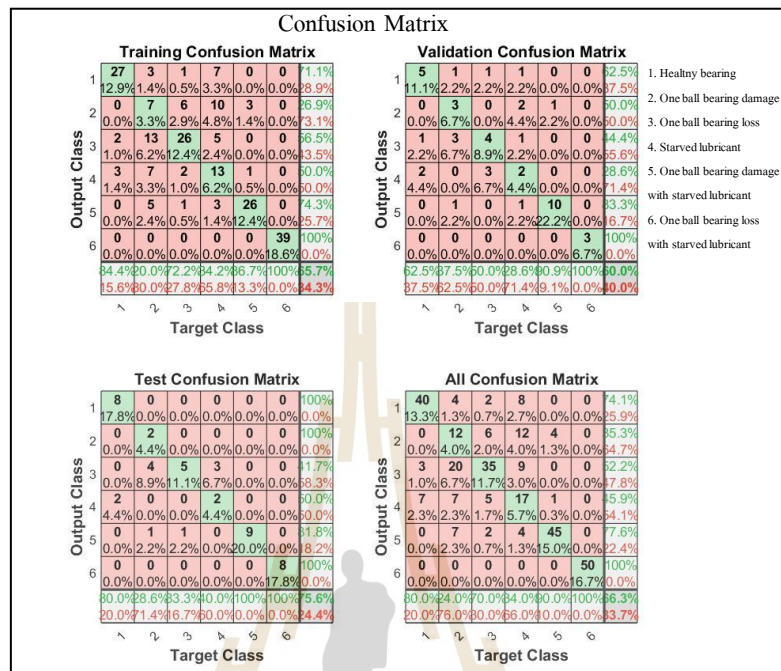
- FFT spectrum & Crest factor



รูปที่ 4.20 Confusion of FFT spectrum & Crest factor

จากรูปที่ 4.20 พบว่าค่าความแม่นยำสำหรับการสอน (Training) มีค่าเท่ากับ 70.5% การตรวจสอบ (Validation) มีค่าเท่ากับ 71.1% และการทดสอบ (Test) มีค่าเท่ากับ 75.6% และเมื่อรวมทั้งหมดมีค่าความแม่นยำเท่ากับ 71.3%

- FFT Motor current & Crest factor

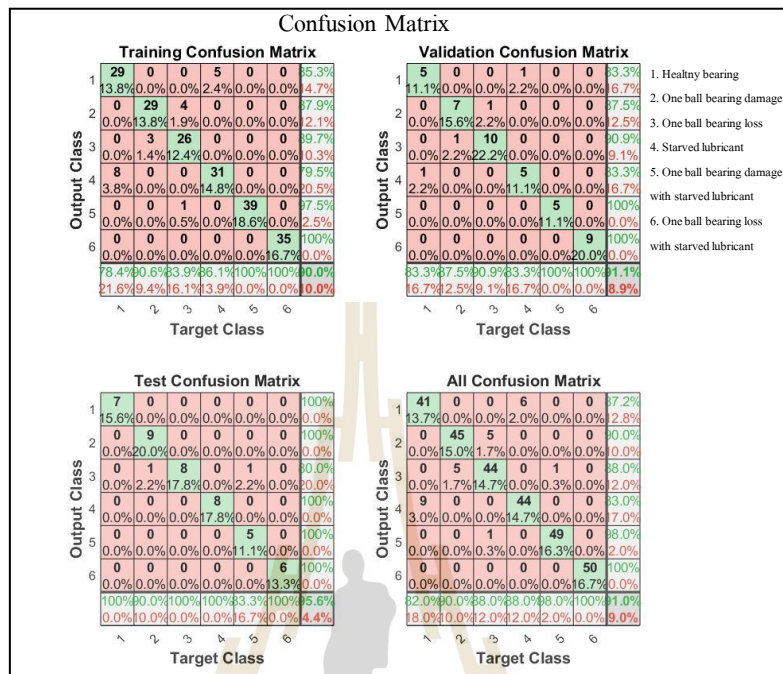


รูปที่ 4.21 Confusion of Motor current & Crest factor

จากรูปที่ 4.21 พบว่าค่าความแม่นยำสำหรับการสอน (Training) มีค่าเท่ากับ 65.7% การตรวจสอบ (Validation) มีค่าเท่ากับ 60.0% และการทดสอบ (Test) มีค่าเท่ากับ 75.6% และเมื่อรวมทั้งหมดมีค่าความแม่นยำเท่ากับ 66.3%

4.3.3 สามพารามิเตอร์ (Triple parameter)


- FFT spectrum & Motor current & Crest factor



รูปที่ 4.22 Confusion of FFT spectrum & Motor current & Crest factor

จากรูปที่ 4.22 พบว่าค่าความแม่นยำสำหรับการสอน (Training) มีค่าเท่ากับ 90.0% การตรวจสอบ (Validation) มีค่าเท่ากับ 91.1% และการทดสอบ (Test) มีค่าเท่ากับ 95.6% และเมื่อรวมทั้งหมดมีค่าความแม่นยำเท่ากับ 91.0%

เมื่อเรานำเอาทุกพารามิเตอร์มาเปรียบเทียบกัน เราพบว่าค่าความแม่นยำมากที่สุดคือ FFT spectrum & Motor current & Crest factor โดยมีค่าความแม่นยำอยู่ที่ 91% ดังรูปที่ 4.23




รูปที่ 4.23 การเปรียบเทียบความแม่นยำทุกพารามิเตอร์

4.4 การเปรียบเทียบระหว่างโครงข่ายประสาทเทียมกับปัญญาประดิษฐ์

(Comparison of artificial neural network between artificial intelligence)

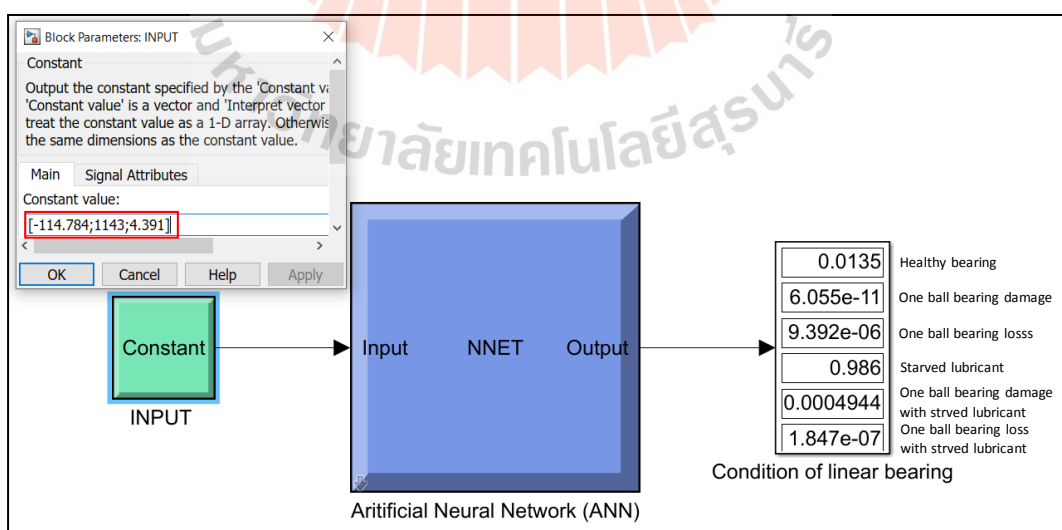
ทำการเปรียบเทียบหาค่าความแม่นยำของปัญญาประดิษฐ์ทั้งหมด 6 แบบ คือ K-Nearest Neighbors (KNN), Decision Tree, Artificial Neural Network (ANN) ซึ่งผลที่ได้คือ K-Nearest Neighbors (KNN) = 83.3%, Decision Tree = 84.0% และ Artificial Neural Network (ANN) = 91.0% ดังรูปที่ 4.24



รูปที่ 4.24 การเปรียบเทียบระหว่างโครงข่ายประสาทเทียมกับปัญญาประดิษฐ์

4.5 ผลการทดลอง Simulink ใน Matlab 2020a

ทำการจำลองการทำงานของ Artificial Neural Network ใน Simulink ของ Matlab 2020a ดังรูปที่ 4.25 โดยการสุ่มอินพุตขึ้นมา 5 อินพุตแล้วให้โปรแกรมคำนวณหาสภาวะของลิเนียร์แบริง ซึ่งผลการทดลองที่ได้ดังตารางที่ 4.4



รูปที่ 4.25 ตัวอย่างการแสดงผลของ Simulink

จากรูปสังเกตเห็นว่า เมื่อใส่อินพุตคือ ค่า FFT = -114.784 , ค่า Motor current = 1143 และ ค่า Crest factor = 4.391 จำแนกสถานะของลิเนียร์แบริง คือ สภาวะสารหล่อลื่นเหลือน้อย (Starved lubricant) ซึ่งมีความน่าจะเป็นถึง 98.60%

ตารางที่ 4.4 ผลการทดลอง Simulink

Input			Output	
FFT spectrum (dB)	Motor current (mA)	Crest factor	Condition	Probability (%)
-100.135	1133	4.243	One ball bearing damage With starved lubricant	99.43
-92.603	1234	3.703	One ball bearing loss With starved lubricant	99.88
-95.595	1307	4.127	One ball bearing loss With starved lubricant	99.83
-114.784	1143	4.391	Starved lubricant	98.60
-119	1056	4.300	Healthy bearing	95.48

สรุป

จากการนำข้อมูลมาวิเคราะห์ทางสถิติที่ความเชื่อมั่น 95% โดยใช้วิธี Analysis of Variance (ANOVA) เพื่อแยกแยะหาสถานะแบริง เราพบว่าข้อมูลทั้งหมดเป็นข้อมูลปกติ (Normality) และข้อมูลทั้งหมดไม่สามารถที่จะแยกแยะสถานะของลิเนียร์แบริงได้ เนื่องจากข้อมูลมีค่าที่ใกล้เคียงกันมาก เนื่องจากค่า Delta มีค่าน้อยมากเมื่อเทียบกับสถานะลูกปืนปกติ เช่น ค่า Delta ของ FFT spectrum เมื่อนำเอาสถานะสารหล่อลื่นเหลือน้อยมาเทียบกับสถานะลูกปืนปกติจะพบว่ามีค่า Delta อยู่ที่ 1.018 หรือคิดเป็น 0.90% ซึ่งถือว่าน้อยมาก เป็นต้น ดังนั้นจึงนำเอา Artificial Neural Network (ANN) มาช่วยในการแยกแยะสถานะของลิเนียร์แบริง ซึ่งสามารถแยกแยะสถานะได้ โดยได้ค่าความแม่นยำของแต่ละพารามิเตอร์ดังนี้คือ Crest factor = 36.0%, Motor current = 56.3%, FFT spectrum = 61.7%, Motor current & Crest factor = 66.3%, FFT spectrum & Crest factor = 71.3 %, FFT crest factor & Motor current = 86.0%, FFT spectrum & Motor current & Crest factor = 91.0% ซึ่งเมื่อนำเอา ANN มาเปรียบเทียบกับ Artificial Intelligent (AI) ชนิดอื่น ๆ พบว่า ANN ให้ค่าความแม่นยำมากที่สุด

บทที่ 5

สรุปและข้อเสนอแนะ

5.1 สรุป

ในอดีตการตรวจจับและวินิจฉัยความบกพร่องของอุปกรณ์โดยใช้ปัญญาประดิษฐ์ เป็นสิ่งที่ทำได้ยากเนื่องจากปัจจัยหลายด้านไม่ว่าจะเป็นทั้งด้านอุปกรณ์ ทุน รวมไปถึงเทคโนโลยี แต่ปัจจุบันการตรวจจับและวินิจฉัยความบกพร่องของอุปกรณ์โดยใช้ปัญญาประดิษฐ์ เป็นสิ่งที่สามารถทำได้ ดังนั้น งานวิจัยนี้ จึงได้ทำการศึกษาและออกแบบระบบตรวจจับและวินิจฉัยความบกพร่องคันลิเนียร์เบริงในสภาวะจริงโดยใช้โครงข่ายประสาทเทียม ซึ่งสามารถสรุปผลงานวิจัยได้ดังนี้

- 1) สามารถใช้โครงข่ายประสาทเทียมในตรวจจับและวินิจฉัยความบกพร่องของลิเนียร์เบริงได้ โดยมีความแม่นยำมากที่สุดคือ FFT spectrum & Motor current & Crest factor = 91%
- 2) ในการเปรียบเทียบแต่ละปัญญาประดิษฐ์ (AI) พบว่าโครงข่ายประสาทเทียม (ANN) ให้ค่าความแม่นยำมากที่สุดคือ 91% เมื่อเทียบกับปัญญาประดิษฐ์ (AI) ชนิดอื่น ๆ

5.2 ข้อเสนอแนะ

- 1) งานวิจัยนี้ได้จำลองการทำงานของเครื่อง Auto Core Adhesion Mounting (ACAM) เนื่องจากเครื่องจักรยังไม่รองรับเทคโนโลยีระบบโครงข่ายประสาทเทียม (ANN)
- 2) ในงานวิจัยนี้เป็นระบบตรวจจับและวินิจฉัยความบกพร่อง (FDD) สามารถที่นำเอาระบบนี้ไปต่อยอดเป็นระบบตรวจจับความบกพร่องและควบคุม (FTC) ได้

รายการอ้างอิง

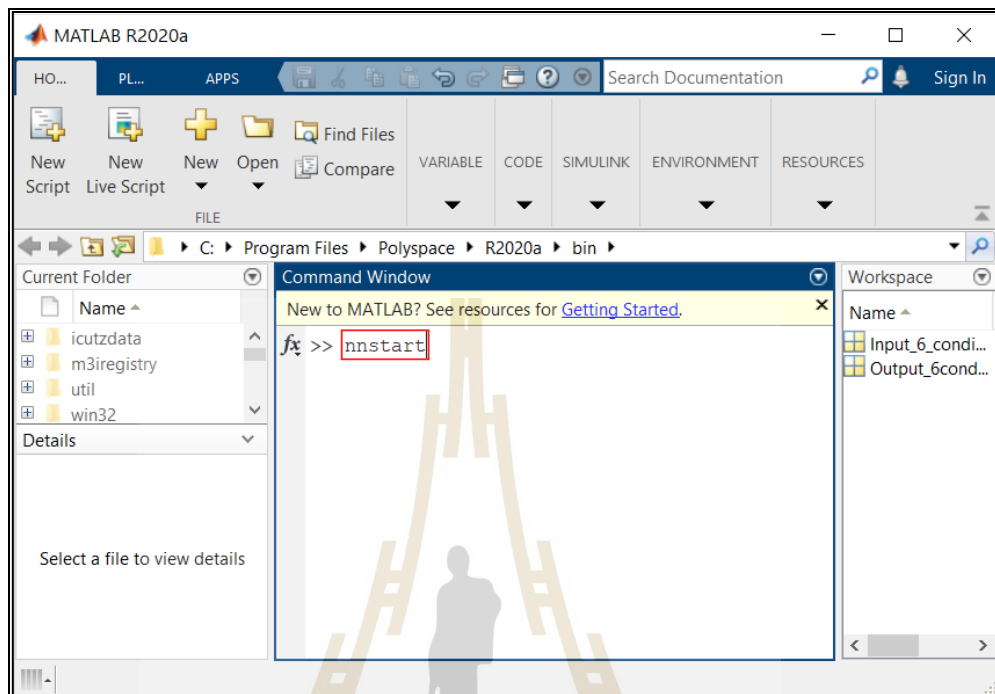
- [1] A.B. Jaouher, F. Nader, C.M. Brigitte, F. Farhat, *Applied Acoustics*, **89**, 16-27 (2014).
- [2] A. Issam, F. Nadir, B. Nadir, O. Brahim, D. Adel. *Journal of Sound and Vibration*, **397**, 241-265 (2017).
- [3] C. Jian, R.B. Robert, *Mechanism and Machine Theory*, **104**, 161-176 (2016).
- [4] L. Han, Z. Jianzhong, Z. Yang, J. Wei, Z. Yuncheng, *ISA Transactions*, **77**, 167-178 (2018).
- [5] C. Zhiqiang, D. Shengcai, C. Xudong, L. Chuan, S. Rene-Vinicio, Q. Huafeng, *Microelectronics Reliability*, **75**, 327-333 (2017).
- [6] S. Haidong, j. Hongkai, L. Xingqiu, L. Tianchen, *Computer in Industry*, **96**, 27-39 (2018)
- [7] Z. Jafar, A.T. Mohammad, R.K. Hamid, *Mechatronics*, **24**, 151-157 (2014)
- [8] U. Muhammet, O. Mustafa, D. Mustafa, K. Haluk, *Measurement*, **58**, 187-196 (2014)
- [9] B. Cluaudio, I. Fabio, C. Marco, R. Riccardo, B. Alberto, *IEEE Transactions on Industrial Electronics* **58**, 1684-1694 (2011).
- [10] P. Bošković, J. Petrović, B. Musizza, Đ. Juričić, *Tribology International*, **43**, 1683-1692 (2010)
- [11] พีระพล ขวัญจิตานนท์, (2009), DSP 6 The Fast Fourier Transform (FFT) การแปลงฟูรีเยร์แบบเร็ว. สืบค้น https://embedsigproc.files.wordpress.com/2008/09/dsp_2552_6.pdf
- [12] H. Alwi et al., *Fault Detection and Fault-Tolerant Control Using Sliding Modes*, *Advances in Industrial Control*, DOI 10.1007/978-0-85729-650-4_13, © Springer-Verlag London Limited 20
- [13] พาราดีน จันทเขตต์. (2014). เครื่องจักรคุยกับเรา (Our machine is talking?). *MECHANICAL TECHNOLOGY (Maintenance)*, 14 (152), 43-45
- [14] M.F. Martin, *Neural Network*, **6**, 525-533 (1993)



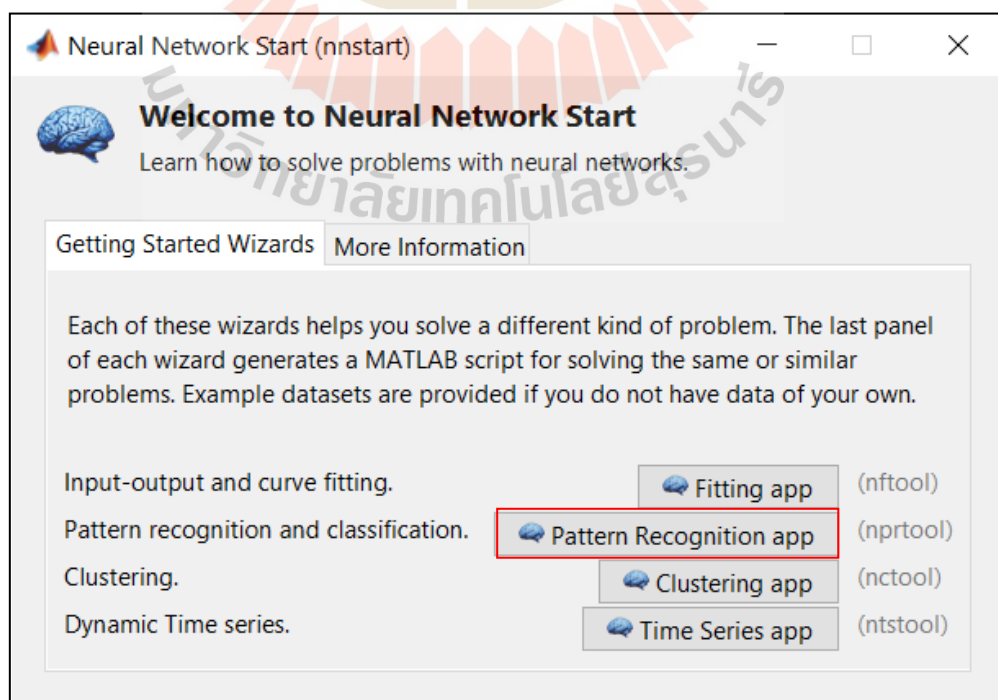
ภาคผนวก ก

โปรแกรม MATLAB 2020a

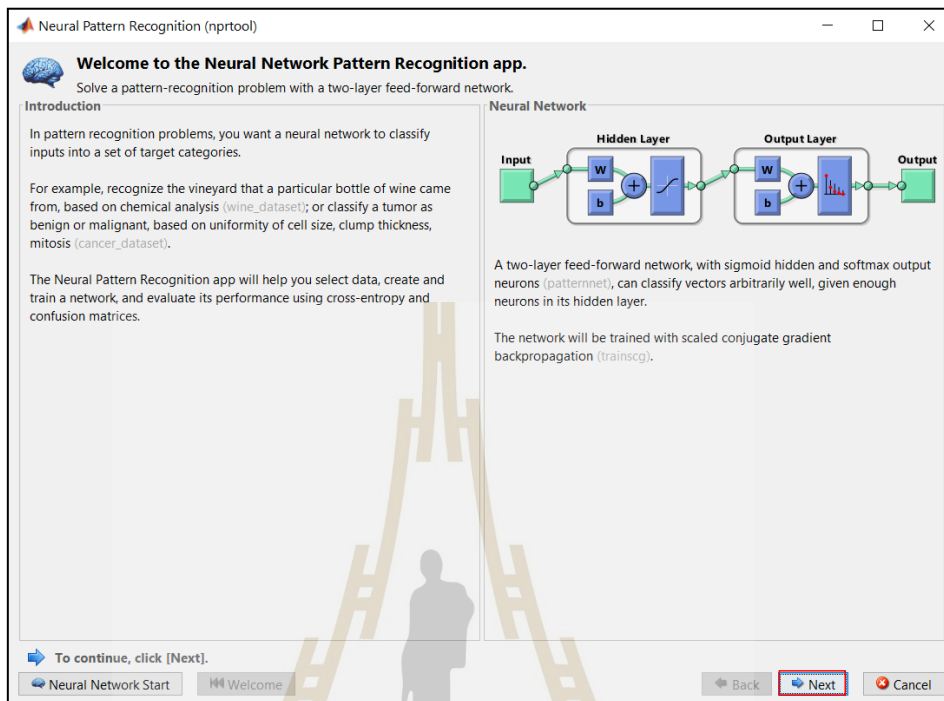
- พิมพ์ nnstart



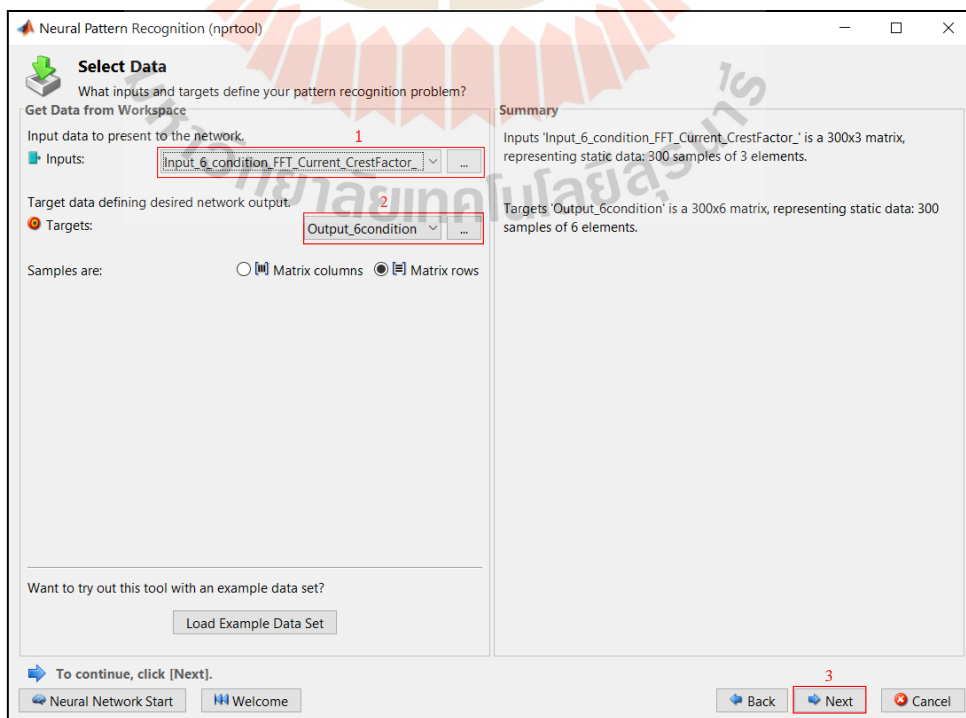
- เลือก Pattern Recognition app



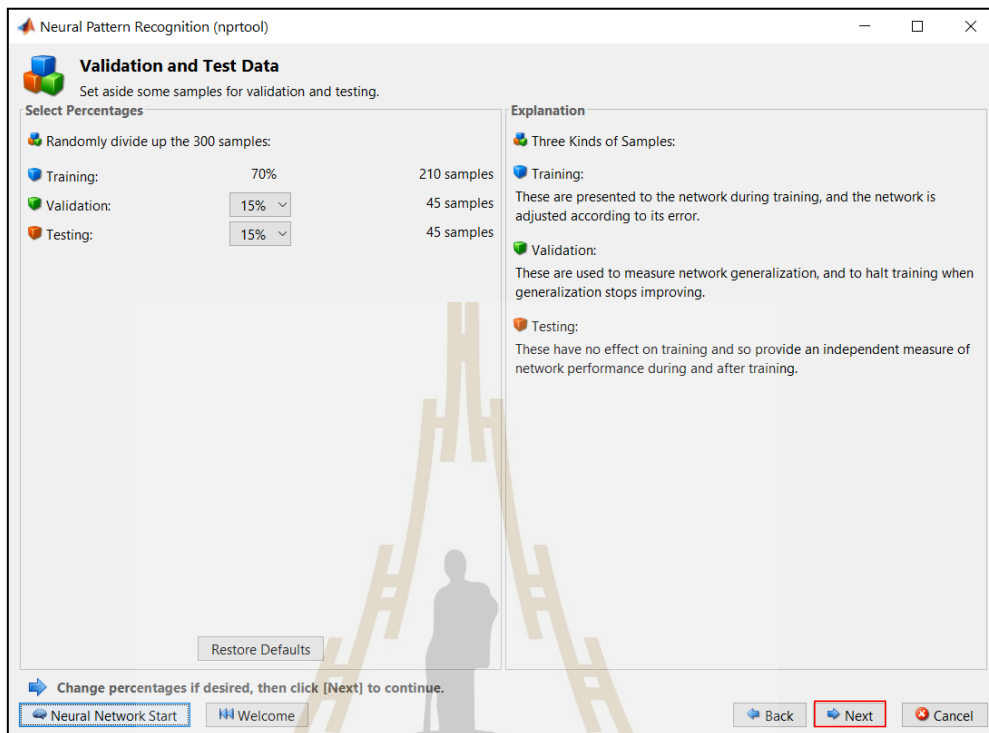
- คติกลุ่ม Next



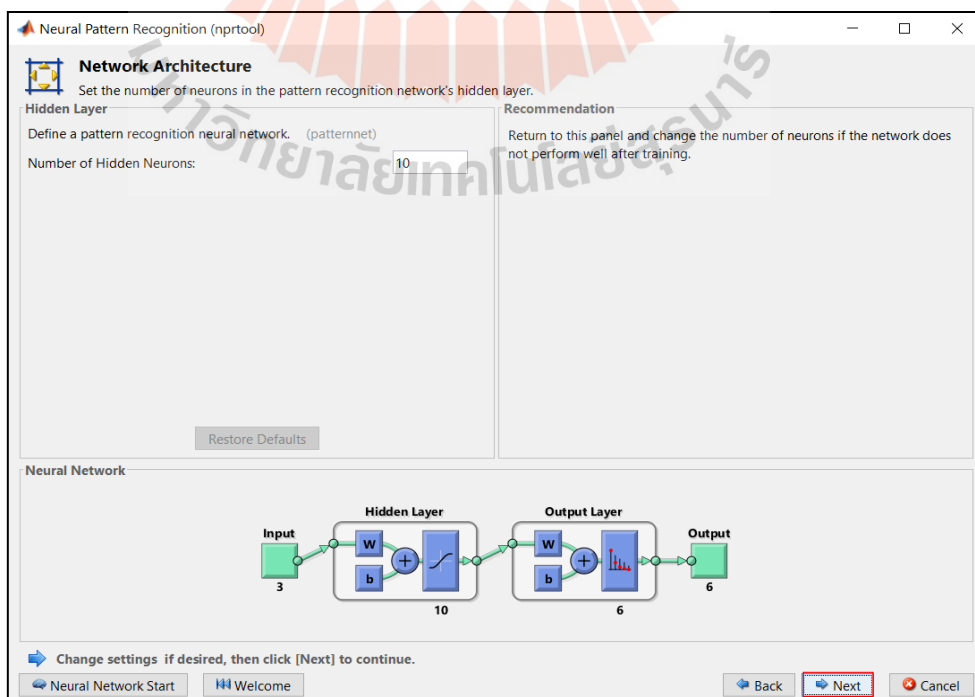
- Import input และ Import output หลังจากนั้นกดปุ่ม Next



- กดปุ่ม Next



- กดปุ่ม Next



- กดปุ่ม Train

Neural Pattern Recognition (nprtool)

Train Network

Train the network to classify the inputs according to the targets.

Train Network

Train using scaled conjugate gradient backpropagation. (trainscg)

Training automatically stops when generalization stops improving, as indicated by an increase in the cross-entropy error of the validation samples.

Results

	Samples	CE	%E
Training:	210	-	-
Validation:	45	-	-
Testing:	45	-	-

Notes

- Training multiple times will generate different results due to different initial conditions and sampling.
- Minimizing Cross-Entropy results in good classification. Lower values are better. Zero means no error.
- Percent Error indicates the fraction of samples which are misclassified. A value of 0 means no misclassifications, 100 indicates maximum misclassifications.

! Train network, then click [Next].

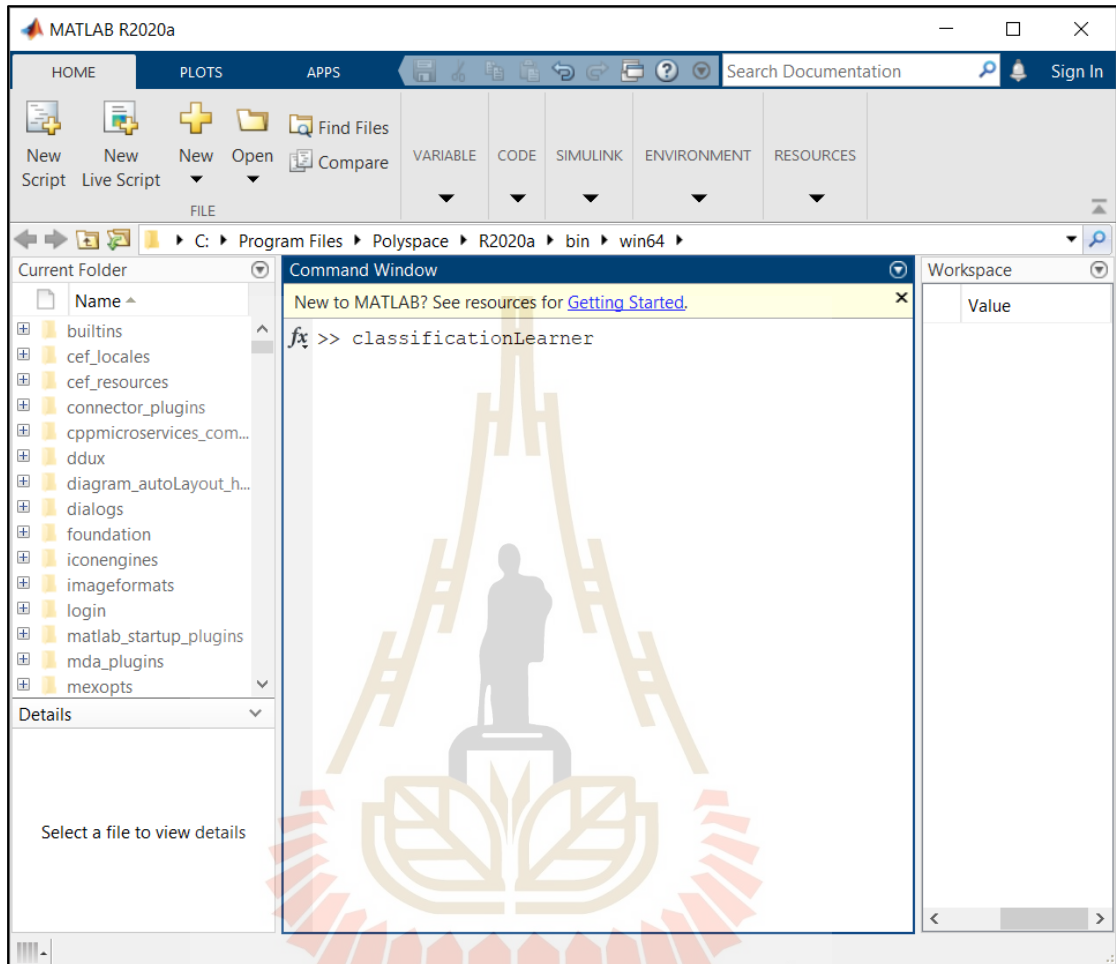


ภาคผนวก ข

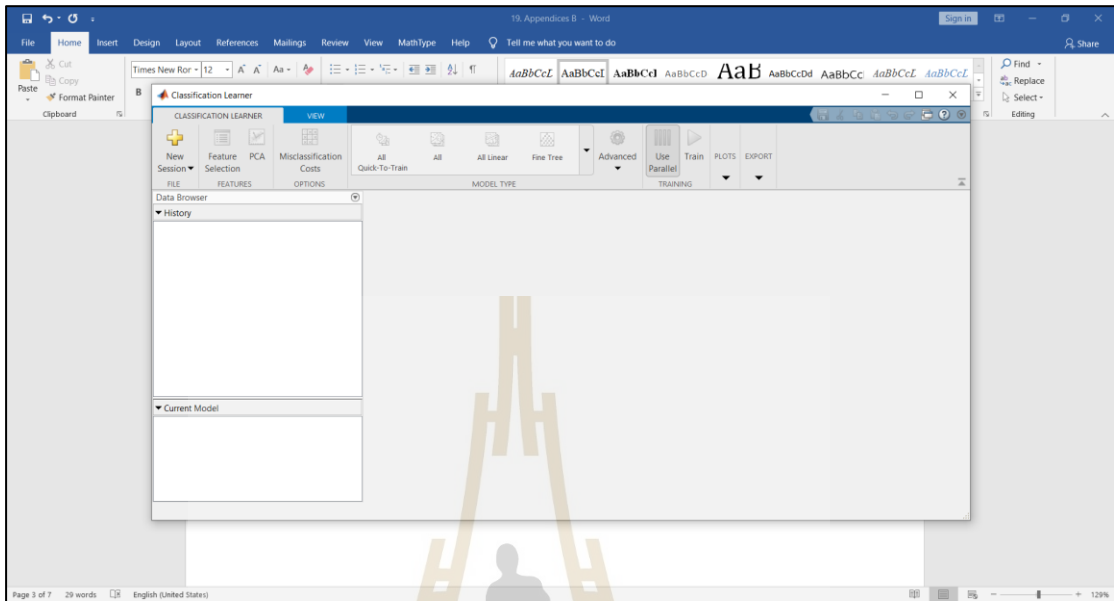
การใช้ Classificationlearner of Matlab 2020a

มหาวิทยาลัยเทคโนโลยีสุรนารี

- พิมพ์คำสั่ง `classificationLearner` แล้วกด Enter



- กด New Session แล้วเลือก From File




- กด Import Selection

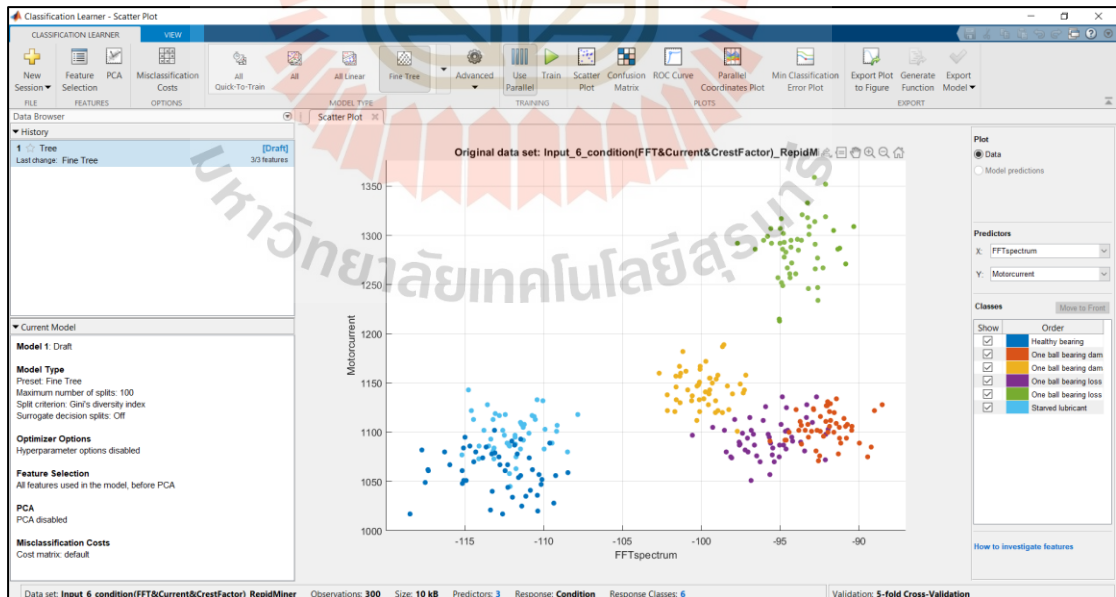
The screenshot shows the 'Import Selection' dialog box in MATLAB. The 'Import Selection' button is highlighted. Below the dialog, a table of data is visible, including columns for 'InputCondition', 'FFT Spectrum', 'Motor current', 'Crest factor', and 'Condition'.

Number	InputCondition	FFT Spectrum	Motor current	Crest factor	Condition
1	-114.4440	1070	4.6933	Healthy be...	
2	-108.4700	1059	4.4804	Healthy be...	
3	-112.7840	1067	4.3513	Healthy be...	
4	-117.7390	1082	4.3772	Healthy be...	
5	-110.9260	1074	4.6178	Healthy be...	
6	-109.3680	1026	5.0468	Healthy be...	
7	-113.1290	1102	4.6456	Healthy be...	
8	-112.0320	1091	4.6564	Healthy be...	
9	-115.0860	1051	4.2275	Healthy be...	
10	-111.3990	1025	4.5729	Healthy be...	
11	-114.3210	1080	4.3068	Healthy be...	
12	-113.1040	1079	4.3991	Healthy be...	
13	-112.2810	1044	4.3114	Healthy be...	
14	-109.2510	1056	4.5472	Healthy be...	
15	-111.8510	1087	4.2599	Healthy be...	
16	-112.2990	1067	4.2847	Healthy be...	
17	-111.4670	1093	4.5236	Healthy be...	
18	-115.1820	1061	4.6347	Healthy be...	
19	-113.8780	1074	4.3619	Healthy be...	
20	-111.1390	1035	4.0805	Healthy be...	
21	-113.3030	1078	4.1055	Healthy be...	
22	-110.8540	1041	4.1703	Healthy be...	
23	-118.4910	1017	4.3854	Healthy be...	
24	-110.4100	1036	4.5265	Healthy be...	
25	-110.1710	1047	4.3576	Healthy be...	
26	-117.5780	1049	4.3444	Healthy be...	
27					


-เลือกไฟล์ Input แล้วกด Start Session



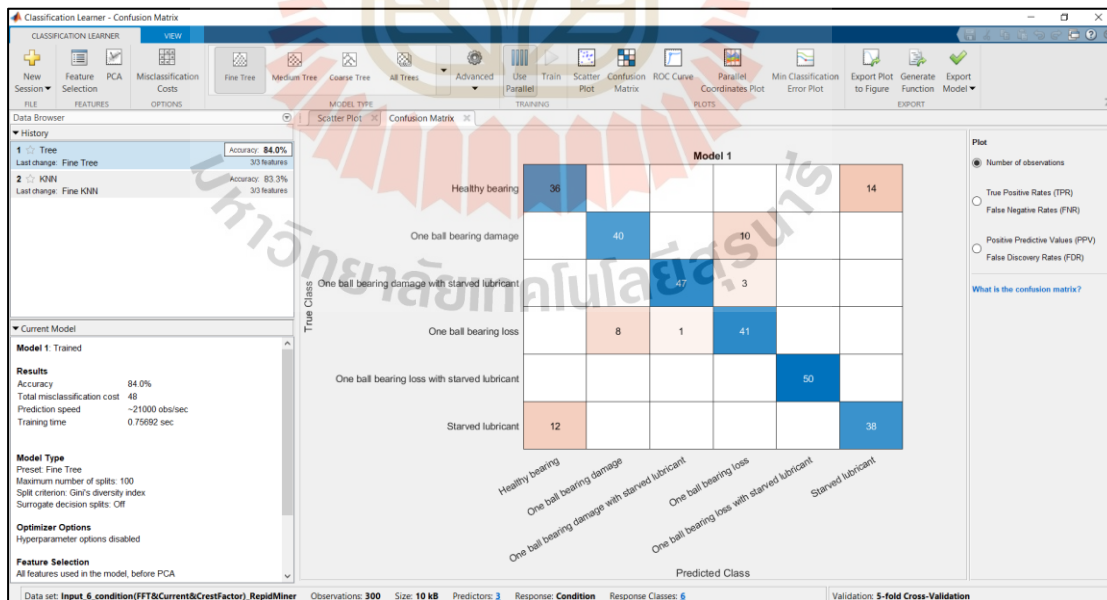
-เลือก Artificial Intelligent ที่เราต้องการแล้วกด



- รอนโปรแกรมคำนวณเสร็จ



- Result





ภาคผนวก ค


บทความที่ได้รับการตีพิมพ์เผยแพร่และการประชุมวิชาการในต่างประเทศ

มหาวิทยาลัยเทคโนโลยีสุรนารี

รายชื่อบทความที่ได้รับการตีพิมพ์เผยแพร่และการประชุมวิชาการในต่างประเทศ

Siwanu, L., Prathan, C., and Jiraphon, S. (2019). **Linear Bearing Fault Detection in Operational Condition Using Artificial Neural Network**. ITM Web of Conferences **24** (2019) Rome, Italy. pp.36-48.

Prathan, C., Siwanu, L., and Jiraphon, S. (2019). **Fault Detection of Linear Bearing in Auto Core Adhesion Mounting Machine Using Artificial Neural Network**. WSEAS TRANSACTIONS on SYSTEMS and CONTROL (Vol. 14).



- International conference

ITM Web of Conferences 24, 01004 (2019)
AMCSE 2018

<https://doi.org/10.1051/itmconf/20192401004>

Linear Bearing Fault Detection in Operational Condition Using Artificial Neural Network

Sivanu Lawbootsa¹, Prathan Chommaungpuck^{1,2} and Jiraphon Srisertpol^{1*}

¹ School of Mechanical Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand

² Western Digital (Thailand) Co.Ltd, Bang Pa-in Industrial Estate, Ayutthaya 13160, Thailand

Abstract Nowadays, Factors of a competition of Hard Disk Drive (HDD) industry have reduced the cost of manufacturing process via increasing the rate of productivity and reliability of the automation machine. This paper aims to increase the efficacy of Condition-Based Maintenance (CBM) of linear bearing in Auto Core Adhesion Mounting machine (ACAM). The linear bearing faults considered in three causes such as healthy bearing, one ball bearing damage and one ball bearing damage with starved lubricant. The Fast Fourier Transform spectrum (FFT spectrum) can be detected for linear bearing faults and Artificial Neural Network (ANN) method used to analyze the cause of linear bearing faults in operational condition. The experimental results show the potential application of ANN and FFT spectrum technique as Fault Detection and Isolation (FDI) tool for linear bearing fault detection performance. The accuracy and decision making of ANN is enough to develop the diagnostic method for automation machine in operational condition.

1 Introduction

Hard Disk Drive (HDD) industry has a competition of product price and speed of reading and writing technology. The cost of manufacturing process and reliability of the automation machine are the important role to profit margin of a product. Head Gimbal Assembly (HGA) is the major component in HDD. HGA assembly process is used Auto Core Adhesion Mounting machine (ACAM) to attach the slider to suspension as shown in Fig.1, then connect the circuit between slider and suspension. ACAM machine is used to adhesive dispense and attach the slider to suspension with requiring both short cycle time and high accuracy. ACAM machine used the motor to transfer HGA clamping unit from position to position and linear bearing are integrated to support and friction reduction propose while movement. According, to the machine is continues run to support production. Linear bearing faults are the direct impact to ACAM machine efficacy reduction. The preliminary damage of the linear bearing must be detected before the machine breaks down. Thus, the Condition-Based Maintenance (CBM) of the linear bearing condition is necessary.

In order to detect faults of Rolling Element Bearings (REBs), faulty diagnoses are used. For automatic condition, monitoring provide by using Empirical Mode Decomposition (EMD) to extract the vibration signal. Artificial Neural Network (ANN) was applied to classify

bearing defects. The result indicates that the classifier is promising for high accuracy of fault bearing detection [1]. Fault diagnostics of ball bearing Adaptive Neuro Fuzzy Inference Systems (ANFIS) is used for automatically identify and classify of bearing fault it was found the accurate classification of 99.83% [2].



Fig.1 Auto Core Adhesion Mounting machine (ACAM)

The method presents the Artificial Neural Network (ANN) in machine condition monitoring and the result compares of simulation and experiment [3]. The paper on fault diagnosis of rolling bearings with recurrent neural

* Corresponding author: jiraphon@sit.ac.th

network based autoencoders describe about the effect of ambient noise to extract the diagnostic result, therefore multiple sensors were used. Recurrent Neural Network (RNN) is used to a rotary machine for classifying fault. The model for predicting using Gated Recurrent Unit (GRU) based on this advantage is to utilize information from multiple sensors [4]. Zhiqiang Chen provided the deep neural network to rolling bearing fault diagnosis. Vibration signal of seven fault patterns in term of time and frequency domain was used for data training in three deep learning model which are consist of Stacked Auto-Encoders (SAE), Deep Boltzmann Machines (DBM) and Deep Belief Networks (DBN) all models are efficient to classify. The accuracy achieved more than 99% [5]. The detection of rolling bearing fault are used Continuous Deep Belief Network(CDBN) and Continuous Restricted Boltzmann machines(CRBMs). The CDBN are optimized with genetic algorithm(GA)[6].The four condition of detection and classification in roller bearing: healthy, inner race defect, outer race defect and double holes in outer race used an Artificial Neural Network (ANN)[7]. Fault diagnosis of rolling bearing are analysis by Hilbert Transform(HT) and Fast Fourier Transform(FFT). Artificial Neural Network used genetic algorithm into optimization[8]. In addition, the model of linear bearing was employed to detect fault form vibration signal. Statistical analysis is an extension method to analyze vibration moreover in order to detect the fault of linear bearing the vibration model has important [9]. Convolution neural network was provided due to fault classification of the rolling bearing by using vibration signal data. The training structure defines the hierarchical and back propagation process to classify the result indicate that the training simple affect to accuracy which is more sample the accuracy can be achieved [10]. Fault identification in the paper on sparse classification based on dictionary learning for planet bearing fault identification. Four conditions (sun gear, planet gear, ring gear and rolling gear) of fault was investigated. Chuan Zhao discusses spares method based on dictionary learning it has a merit of tackling raw inputs. On the other hand the vibration signal it cannot be learning to optimize inasmuch, map to transform the signal vector to a matrix form which retains the intrinsic fault feature information is used [11]. To analyze nonlinear vibration signal of rotating electrical machine three intelligence approach of the artificial neural network, genetic algorithms and active-set methods were proposed. The comparison is the numerical method with the help of different measures [12]. The Singular Spectral Analysis (SSA) is a time domain analysis technique this show the complex feature extraction. Roller element of bearing fault was detected by the applied neural network on singular spectral and evaluation using two experimental datasets. The result revealed that bearing fault diagnosis is simple, noise tolerant and efficient [13].

This paper aims to increase the efficacy of Condition-Based Maintenance (CBM) of linear bearing in Auto Core Adhesion Mounting machine (ACAM) by Fault Detection and Isolation (FDI) technique. The mechanical failure of linear bearing considered in three

causes such as healthy bearing, one ball bearing damage and one ball bearing damage with starved lubricant. The analytical results of linear bearing fault by using the Fast Fourier Transform (FFT) spectrum and the Artificial Neural Network (ANN) methodology are proposed in this research.

2 Theoretical backgrounds

2.1 Fault Detection and Isolation (FDI)

Fault Detection and Isolation (FDI) technique, is widely used in many applications in control system. FDI is used to detect fault or failure then find the location or type of fault. So that feedback information to reconfiguration controller for eliminate or minimize the effect on the overall system performance. The classifications of FDI were divided into two major groups, which are model-based and non model-based. Non model-based schemes are include Condition Monitoring and Intelligent FDI as shown in Fig.2

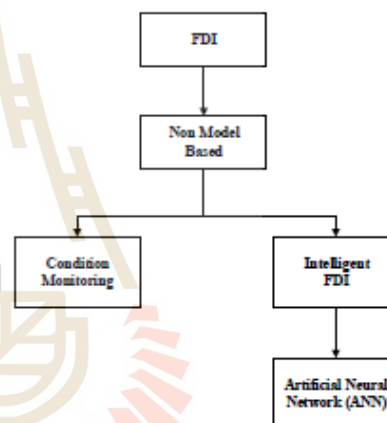


Fig.2 Fault Detection and Isolation (FDI)

2.2 Artificial neural network

The feed forward perceptron can be separated into Single Layer Perceptron (SLP) and Multilayer Perceptron (MLP). The multilayer perceptron consists of multiple neurons and multiple parallels. The multilayer perceptron include of the input layer, hidden layer and output layer is shown in Fig.3.

The output function can be expressed in term of the matrix as follow:

$$y = f(Wp + b) \quad (1)$$

Where $p^T = [p_1 \ p_2 \ \dots \ p_n]$ is the input of MLP
 $b^T = [b_1 \ b_2 \ \dots \ b_n]$ is the bias of MLP and

$W = \begin{pmatrix} W_{11} & \dots & W_{1n} \\ \vdots & \ddots & \vdots \\ W_{m1} & \dots & W_{mn} \end{pmatrix}$ is weight of MLP




Fig.3 Multilayer Perceptron (MLP)

2.3 Linear bearing model

The linear bearing with recirculating ball bearings designed to use for move heavy loads along the precision linear path. The linear bearing consists of 2 major components with moving carriage and precision linear rail as shown in Fig.4. The ball or roller is used for the movement between carriage and linear rail with frictionless. According to continues run of linear bearing the contact between ball bearing and precision rail is the lead to worn out of mechanical part and degeneration of lubricant.




Fig. 4 Component and ball element of linear bearing.

To define the characteristic frequency of the ball bearing, the contact between ball bearing to rail and carriage each time and ball bearing completes rotation. The characteristic frequency of ball bearing is described as

$$f_{ball} = \frac{2V_{ball}}{\pi D_b} \quad (2)$$

Where V_{ball} is velocity of ball bearing and D_b is diameter of ball bearing.

2.4 Fast Fourier Transform (FFT) spectrum

In general vibration signal was analyzed both time domain and frequency domain. The most common technique for fault diagnostic to identify the status of the machine is the vibration analysis. However, when the component of machine such as linear bearing moving it will be generated vibration signal at several frequencies. Therefore time domain analysis is difficult to extract the machine condition. Traditional analysis has generally relied upon spectrum analysis based on Fast Fourier Transform (FFT) spectrum which are the signal processing in frequency domain since was shown as eq.3. It is the most important technique to detect the fault frequency of fault linear bearing.

$$X(f) = \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} x(t) \cdot e^{-i2\pi ft} dt \quad (3)$$

3 Experimental setup and procedure

3.1 Data collection

In this research, the experimental setup was performed with using the linear DC Motor (SGL 100-AUM3-PS4J model). The experiment was setup by installed a clamping unit with the load 7 kg on the top of linear DC motor. The acceleration sensor set up with the X -axis parallel to the direction of movement to the floor plane, Y -axis perpendicular to the X -axis and Z -axis perpendicular to the floor plan. Because the X -axis heavily affected by free movement but Y -axis and Z -axis fixed movement due to the mechanic of magnetic linear DC motor. Vibration Measurement by acceleration sensor and data acquisition via IOTech and EZ-Analyst software. The acceleration sensor measurement PCB Piezotronics (356A32 model) is employed in these experiments. The vibration sensitivity of sensor is 99.2 mV/g in X -axis direction, 98.1 mV/g in Y -axis direction and 101.1 mV/g in Z -axis direction respectively. Sampling frequency is 4000 Hz. The operational condition of linear motor was setup based on current setting in production mode with acceleration 1.00 m/s², velocity of 0.5 m/s and moving distance of 400 mm for data collection.

Table 1. Ball fault characteristic frequencies

Motor speed (m/s)	Ball speed (m/s)	Ball Frequency (Hz)
0.50	0.25	53.00




Fig.5 Experimental setup




Fig. 6 (a) Healthy bearing (b) One ball bearing damage (c) One ball bearing damage with starved lubricant

The experimental setup is shown in Fig. 5. The data collection of three conditions were consisted of the healthy bearing, one ball bearing damage and one ball bearing damage with starved lubricant. The healthy bearing is perfect bearing is shown in Fig. 6 (a). one ball bearing damage is simulate by manual gridding surface of ball bearing with area 2.565 mm^2 as depicted in Fig. 6(b). The one ball bearing damage with starved lubricant was conducted by using isopropyl alcohol (IPA) cleaner and BRANSON (2510 model) digital ultrasonic cleaning to remove grease at carriage and rail as shown in Fig.6(c). Data collection by measuring vibration signal as above

setting each condition are collect 50 data points total 150 data samples.

As setup motor speed 0.5 m/s the characteristic frequency of ball bearing is calculate per equation (2) result shown as Table 1.

3.2 Classification of Artificial Neural Network (ANN)

The data of FFT spectrum is used for detecting and isolating of fault bearing conditions. These difficult to detection and isolation of fault bearing conditions in operational condition. In this section, detection and isolation of linear bearing condition require the ANN technique to forecasting models linear bearing condition. To simplified procedure the model, we selected 150 data samples to feed into the ANN models. Since the FFT spectrum values of various 3 bearing condition are very different.

Artificial neural network steps as 1 input layer, 1 hidden layer 10 nodes and 3 output as shown in Fig. 7. The ANN training was done the using the scaled conjugate gradient algorithm by dividing the data into 70%-15%-15% for training, validation and testing.




Fig.7 Artificial Neural Network (ANN)

4 Result and discussion

FFT spectrum data comparison for all 3 conditions considering that healthy bearing, one ball bearing damage and one ball bearing damage with starved lubricant were tested of linear bearing. Result shown as Fig. 8, Fig.9 and Table 2. Both fault bearing conditions are clearly segregate from healthy. Thus, in order to test the effectiveness of the proposed method for FFT spectrum. The FFT spectrum comparison of healthy bearing and fault bearing conditions. One ball bearing damage and one ball bearing damage with starved lubricant are increased by 18.52% and 11.62%, respectively as shown in Table 3




Fig.8 Frequency domain (dB) for velocity 0.50 m/s.




Fig.9 Boxplot comparison all 3 conditions at velocity 0.50 m/s

Table 2. Amplitude (dB) at velocity 0.50 m/s

Condition	95% Confidence interval
Healthy bearing	-113.49 to 112.46
One ball bearing damage	-92.58 to -91.55
One ball bearing damage with starved lubricant	-100.38 to -99.35

Table 3. Comparison of between healthy bearing and fault bearing conditions.

Target	Fault bearing conditions	Delta	%
Healthy bearing	One ball bearing damage	20.93	18.52
Healthy bearing	One ball bearing damage with starved lubricant	13.13	11.62

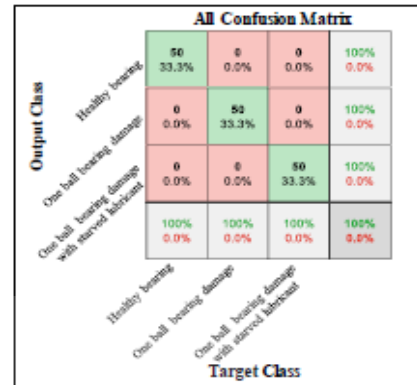


Fig.10 Confusion matrix

The ANN result shown the training stopped at 26th iterations. The detection and isolation values of the linear bearing condition of ANN training. The ANN can satisfy effectiveness detect and isolate of the linear bearing condition. The confusion matrix is conducted by comparing the forecast accuracy convergence. The accuracy percentage of the accuracy is 100%, as shown in Fig.10. The test results demonstrated the detection and isolation values with decision making of the ANN analysis.

5 Conclusion

FDI method can be used for reliability improvement of the automation machine. Preliminary mechanical failure detection of the automation machine is very important in operational condition before the machine breaks down. This paper presents linear motor fault detection using FFT spectrum and ANN method in operational condition. The vibration amplitude can be analyzed the linear bearing faults at ball frequency of 53 Hz, according to motor speed of 50 m/s. In case of healthy bearing has been compared with one ball bearing damage and one ball bearing damage with starved lubricant, the vibration amplitudes were increased 18.52% and 11.62%, approximately. The decision making of ANN method can be correctly identified the linear bearing fault. The experimental results show potential application of ANN and FFT spectrum technique as FDI tool for linear bearing fault detection performance.

Acknowledge

This research was supported by the Research and Researcher for Industry (RRI) under the Thailand Research Fund (TRF) offers a Scholarship for Ph.D. Students, Suranaree University of Technology (SUT) agency through grant PHD60I0043.

References

1. A.B. Jaouher, F. Nader, C.M. Brigitte, F. Farhat, *Applied Acoustics*, **89**, 16-27(2015).
2. A. Issam, F. Nadir, B. Nadir, O. Brahim, D. Adel, *Journal of Sound and Vibration*, **397**, 241-265(2017).
3. C. Jian, R.B. Robert, *Mechanism and Machine Theory*, **104**, 161-176(2016).
4. L. Han, Z. Jianzhong, Z. Yang, J. Wei, Z. Yuncheng, *ISA Transactions*, **77**, 167-178(2018).
5. C. Zhiqiang, D. Shengcai, C. Xudong, L. Chuan, S. Rene-Vinicio, Q. Hunfeng, *Microelectronics Reliability*, **75**, 327-333(2017).
6. S. Haidong, j. Hongkai, L. Xingqiu, L. Tianchen, *Computer in Industry*, **96**, 27-39(2018).
7. Z. Jafar, A.T. Mohammad, R.K. Hamid, *Mechatronics*, **24**, 151-157(2014).
8. U. Muhammet, O. Mustafa, D. Mustafa, K. Haluk, *Measurement*, **58**, 187-196(2014).
9. B. Chuaudio, I. Fabio, C. Marco, R. Riccardo, B. Alberto, *IEEE Transactions on Industrial Electronics*, **58**, 1684-1694(2011).
10. L. Chen, W. Zhenya, Z. Bo, *Advanced Engineering Informatics*, **32**, 139-151(2017).
11. Z. Chuan, F. Zhipeng, W. Xiukun, Q. Yong, *Expert Systems With Applications*, **108**, 233-245(2018).
12. A.Z.R. Muhammad, A.N. Shahab, A.B. Saeed, *Neurocomputing*, **219**, 280-299(2017).
13. M. Bubathi, M.A. Sanjith, B. Kishnakumar, S.A.V. Satya Murty, *Mechanical System and Signal Processing*, **35**, 150-166(2013).

มหาวิทยาลัยเทคโนโลยีสุรนารี

Fault Detection of Linear Bearing in Auto Core Adhesion Mounting Machine Using Artificial Neural Network

PRATHAN CHOMMAUNGPUCK, SIWANU LAWBOOTSA and JIRAPHON SRISERTPOL

School of Mechanical Engineering, Institute of Engineering

Suranaree University of Technology

111 University Avenue Muang, Nakhon Ratchasima 30000

THAILAND

prathan.chommaungpuck@wdc.com, ttorec16@gmail.com, jiraphon@sut.ac.th

Abstract: Nowadays, the major competition of Hard Disk Drive (HDD) industry is to reduce the cost of manufacturing process via increasing the rate of productivity and reliability of the automation machine. This study aims to increase the efficacy of Condition-Based Maintenance (CBM) of linear bearing in Auto Core Adhesion Mounting machine (ACAM). The linear bearing faults were considered in six fault conditions. The Fast Fourier Transform spectrum (FFT spectrum), motor current and crest factor can be detected for linear bearing faults. The Artificial Neural Network (ANN) method was used to analyze and classify the cause of linear bearing faults into operational condition. The experimental results showed the application of ANN as Fault Detection and Isolation (FDI) tool for linear bearing fault detection performance. The accuracy and decision making of ANN are enough to develop the diagnostic method for automation machine in operational condition.

Key-Words: Fault detection and isolation, Linear bearing, Artificial neural network, Fast Fourier transform spectrum, Condition-Based Maintenance.

1 Introduction

Hard Disk Drive (HDD) industry has a competition of product price and capacity of data storage. The cost of manufacturing process and reliability of the automation machine play an important role in profit margin of a production. Head Gimbal Assembly (HGA) is used for reading and writing data in HDD [1]. HGA assembly process used Auto Core Adhesion Mounting machine (ACAM) (Fig 1) to adhesive glue and attach the slider to suspension requiring short cycle time and high accuracy in submicrometer. The ACAM machine was drive HGA clamping unit by motor with link together with linear bearing to transfer work pieces to decide position then processing. The machine was run continuously with high-speed condition. The deterioration of linear bearing shows trend to early fault and causes unplanned downtime of machine. The minor reliability of linear bearing can severely decrease machine performance and reliability. Hence, the preliminary damage of the linear bearing must be detected before the machine breaks down. Thus, the Condition-Based Maintenance (CBM) of the linear

bearing condition is necessary. In order to detect faults of rolling element bearings, faulty diagnoses are used. For automatic condition, monitoring system provides by using empirical mode decomposition to extract the vibration signal. Artificial Neural Network (ANN) was applied to classify bearing defects. The result indicates that the classifier is promising for high accuracy of fault bearing detection [2]. Fault diagnostics of ball bearing Adaptive Neuro Fuzzy Inference Systems (ANFIS) is used for automatically identifying and classifying of bearing fault. It reveals the accurate classification of 99.83% [3]. The artificial neural network (ANN) is used to diagnosis of big-end bearing knock faults in IC engines. The experiment investigates on normal bearing clearances and different oversize bearing clearances. The envelope of vibration signal is the data for training the model. It was demonstrated that the model could successfully detect different bearing knock faults in actual tests, and classify the faults location [4]. The paper on fault diagnosis of rolling bearings with recurrent neural network based auto encoders describes the effect of ambient noise to extract the diagnostic result, therefore multiple sensors were

used Recurrent Neural Network (RNN) is used to a rotary machine for classifying fault. The model for predicting using Gated Recurrent Unit (GRU) based on this advantage utilizes information from multiple sensors (5). Zhiqiang Chen provided a deep neural network to rolling bearing fault diagnosis. Vibration signal of seven fault patterns in terms of time and frequency domain was used for data training in three deep learning models, which consist of Stacked Auto-Encoders (SAE), Deep Boltzmann Machines (DBM) and Deep Belief Networks (DBN) all models are efficient to classify. The accuracy achieved more than 99% (6). In addition, the model of linear bearing is employed to detect fault from vibration signal. Statistical analysis is an extension method to analyze vibration. Moreover, in order to detect the fault of linear bearing, the vibration model is important (7). Convolution neural network was provided due to fault classification of the rolling bearing by using vibration signal data. The training structure defines the hierarchical and back propagation process to classify the result indicating that the training sample affect to accuracy, which is more sample the accuracy, can be achieved (8). Fault identification in the paper on sparse classification is based on dictionary learning for planet bearing fault identification. Four conditions (sun gear, planet gear, ring gear, and rolling gear) of fault were investigated. Chuan Zhao discusses sparse method based on dictionary learning that it has a merit of tackling raw inputs. On the other hand, the vibration signal cannot be optimized inasmuch, mapped to transform the signal vector to a matrix form which retains the intrinsic fault feature information (9). To analyze nonlinear vibration signal of rotating electrical machine three intelligence approaches: the artificial neural network, genetic algorithms and active-set methods were proposed (10). The Singular Spectral Analysis (SSA) is a time domain analysis technique. This shows the complex feature extraction. Roller element of bearing fault was detected by the applied neural network on singular spectral and evaluation using two experimental datasets. The result revealed that bearing fault diagnosis was simple, noise tolerant and efficient (11). Compound dies are widely used in stamping industrial. The stripper is the main component in compound die, which was used for producing more accurate sheet metal parts without any internal or external defects. However, the study on fatigue life of strippers was spread. Sahunkhe, S

presented the method for life cycle prediction of stripper by comparing two approaches: artificial neural network (ANN) and adaptive neuro fuzzy inference (ANFIS) in the process of training. This training used four input for creating the model including maximum principle stress, minimum principle stress, amplitude stress, and mean stress. The desired output of prediction is life cycle of stripper. The result revealed that the ANFIS is a suitable method for predicting a life cycle because it showed higher predictability than ANN (12). Bettine, F provided the novel approach for predicting kinematic errors of trochoidal machining by using artificial neural network (ANN). The model of ANN was proposed in multilayer perceptron (MLP) to find the inverse kinematics solution for a five-axis machine. For the training data set, 1042 samples were used for each axis. The result of training obtains less than 1 second. The result of validation displayed the model performance with nearly zero error (13). The model based on machine learning was applied for fault diagnosis of injection machine. The experiment revealed that it was possible to create a machine-learning-based fault diagnostics model that was trained on process data (14). The paper on Condition monitoring and fault diagnostics for hydropower plants describes a fault diagnosis and classification of data using the support vector machine. This work investigates the hydropower plants under varying speed conditions, by using the envelope order tracking analysis scheme (15).



Fig.1 Auto Core Adhesion Mounting machine (ACAM)

This study aims to increase the efficacy of condition-based maintenance of linear bearing in ACAM machine by using fault detection and isolation technique. The mechanical failure of linear bearing can be classified into six causes such as healthy bearing, one ball bearing damage, one ball bearing loss, starved lubricant bearing, one ball bearing damage with starved lubricant, and one ball bearing loss with starved lubricant. The three signal processing techniques were used for data collecting as FFT spectrum, time waveform and motor current. This research proposes Artificial Neural Network (ANN) methodology to be used for analyzing the root causes of the linear bearing fault in operational condition.

2 Theoretical Background

The analysis method can be analysed the linear bearing fault of the automation machine such as frequency of fault ball bearing and frequency of the loss ball bearing using Fast Fourier Transform (FFT) spectrum. The artificial neural network (ANN) can be correctly identified linear bearing fault condition.

2.1 Linear ball bearing model

The linear bearing with recirculating ball bearings was designed to use for moving heavy loads along the precision linear path. The linear bearing consists of two major components with moving carriage and precision linear rail as shown in Fig.2. The ball bearing is used for movement between the carriage and linear rail with frictionless during translation.




Fig.2 Elements of the linear bearing.

2.1.1 Fault on ball bearing damage

The fault characteristic frequency of the ball bearing was caused by the contact between the ball bearing to rail and carriage on each time when completing one cycle. The characteristic frequency of fault ball bearing is described as Eq. (1)

$$f_{ball} = \frac{2V_{ball}}{\pi D_b} \quad (1)$$

where f_{ball} is the characteristic frequency of ball bearing, V_{ball} is the velocity of the ball bearing, D_b is the diameter of the ball bearing and l is the central distance of two balls bearing

2.1.2 Fault on one ball bearing loss

The characteristic frequency of the loss of ball bearing in carriage is defined as Eq. (2)

$$f_{loss} = \frac{V_{ball}}{l} \quad (2)$$

2.2 Fault detection and isolation (FDI)

Fault detection and isolation technique is used to detect and isolate the system condition. Then diagnostic and feedback information is applied to reconfigure the appropriate controller mechanism or parameter to minimize the impact of the overall system

2.3 Artificial Neural Network (ANN)

The Artificial Neural Network uses the principle of neural simulation. Each of the neural communicates with each other through electrical stimulation. The ANN can be classified into feed forward perceptron and backpropagation.

2.3.1 Feed forward perceptron

The feedforward perceptron is the simplest type of artificial neural network. The algorithm of this network is the information moves from the input node to the output node in only one direction by through the hidden mode and there are no cycles in the network. The feedforward neural network divided into two methods first is the single layer perceptron and another is a multi-layer perceptron (MLP). The single layer perceptron consists of a hidden node only one layer that a capable of learning linearly separable

patterns, on the other hand, the multi-layer perceptron can be used several hidden layers that is the variety of learning techniques as shown in Fig 3.




Fig3 Schematic of multi-layer perceptron.

The output function can be expressed in terms of the matrix as Eq (3):

$$y = f(Wp + b) \quad (3)$$

where $p^T = [p_1 \ p_2 \ \dots \ p_S]$ is the input of MLP. $b^T = [b_1 \ b_2 \ \dots \ b_R]$ is the bias of MLP

and $W = \begin{bmatrix} W_{11} & \dots & W_{1R} \\ \vdots & \ddots & \vdots \\ W_{S1} & \dots & W_{SR} \end{bmatrix}$ is the weight of MLP.

2.3.2 Backpropagation

The backpropagation is the training method of an artificial neural network. The algorithm uses gradient descent to optimize the error function by return the error value of the output in each hidden layer. When the data entering each input layer into the network output layer will be compared to the target as shown in Fig 4. The algorithm will adjust the weight and bias of the network to minimize the average square error of the output layer and target.




Fig4 Schematic backpropagation

$$F(x) = E[(t - y)^2] \quad (4)$$

In case of more than one output

$$F(x) = E[(t - y)^T (t - y)] \quad (5)$$

Where x is the matrix of weight and bias, t is the matrix of the target, and y is the matrix of the output

2.4 Fast Fourier transform (FFT) spectrum

The Fast Fourier Transform (FFT) is a signal processing method, it is used to converse the time waveform to spectrum referred to as the frequency domain. The mathematical of FFT is used to arrange the complex waveform into its harmonic component shown as Eq. (6).

$$X(k) = \sum_{n=1}^{N-1} x(k) \cos \frac{2\pi kn}{N} - j \sum_{n=1}^{N-1} x(k) \sin \frac{2\pi kn}{N} \quad (6)$$

The waveform contains N samples. The two components included cosine and sine function, j is represent for the phase of signal. The spectrum is illustrated as frequency and amplitude referring to Eq. (6). Only vibration spectrum is considered.

2.5 Crest factor

The analysis of vibration sometime can be explained by crest factor, which is the ratio of the peak value to the root mean square(RMS) value as Eq. (7).

$$Crest\ factor = \frac{Peak}{RMS} \quad (7)$$

The principle of this method shows impacts in the waveform. If the amplitude of waveform is sinusoidal, the crest factor will be close to 1.4 as shown in Fig5. On the other hand, if the machine with a bearing fault has more spiky waveform, the crest factor will be higher as illustrated in Fig6.




Fig5 Crest factor of sinusoidal waveform




Fig.6 Crest factor of waveform with bearing fault

3 Experiment Setup and Procedure

This experimental setup contains an actuator as linear DC motor, sensor and analyzer. The procedure presents fault condition of linear bearing in possible terms and operating speed of ACAM machine related to operational condition.

3.1 Experiment setup

In this research, the experimental setup was performed by using the linear DC Motor (SGL 100-AUM3-PS4J model). The clamping unit installing with load 7 kg on top of linear DC motor. The 3-axes acceleration sensor of PCB Piezotronics model 356A32 was used for vibration measurement. The sensor was placed follow by X-axis parallel to the motor direction and Z-axis perpendicular to the machine base. The sensitivity of the acceleration sensor was setup for all 3 axes as 99.2 mV/g, 98.1 mV/g and 101.1 mV/g for X, Y and Z axis respectively. The sampling rate frequency was set at 4000 Hz for data acquisition via IOTech and EZ analyzer software was used for analyze. The operation condition of the linear motor was setup referring to actual setting in production with acceleration 1.00 ms^{-2} , velocity of 0.5 m/s and clamping unit translation distance equal to 400 mm. The experimental setup is shown in Fig. 7.

3.2 Fault condition of linear bearing

This study considered the mechanical failure of linear bearing into six causes such as healthy bearing, one ball bearing damage, one ball bearing loss, starved lubricant bearing, one ball bearing damage with starved lubricant, and one ball bearing loss with starved lubricant.




Fig.7 Experiment setup

3.2.1 Healthy bearing

The healthy bearing is the perfect condition of linear bearing with proper lubricant and healthy ball bearing as shown in Fig.8.

3.2.2 One ball bearing damage

The ball bearing damage was performed by the grinding surface of the ball bearing with area 2.565 mm^2 as depicted in Fig. 9.

3.2.3 One ball bearing loss

The ball bearing loss condition was conducted by removing ball bearing from carriage cage to vary the distance randomly. This spectacle leads to random fluctuations of the time distribution of impacts depicted in Fig. 10.

3.2.4 Starved lubricant bearing

The lubricant was used for friction reduction and corrosion protection. The experiment was setup to remove lubricant from bearing by using isopropyl alcohol (IPA) cleaner with BRANSON (2510 model) digital ultrasonic cleaning machine as shown in Fig. 11.

3.2.5 One ball bearing damage with starved lubricant

This combined fault condition was conducted by removing lubricant of ball bearing damaged condition by ultrasonic cleaning as depicted in Fig 12.

3.2.6 One ball bearing loss with starved lubricant

The ball bearing loss with starved lubricant was conducted by remove lubricant with ultrasonic cleaning machine as depicted in Fig 13.




Fig 8 Healthy bearing



Fig 9 One ball bearing damage




Fig 10 One ball bearing loss



Fig 11 Lubricant removal from bearing using ultrasonic cleaning



Fig 12 Ball bearing damage in ultrasonic cleaning machine



Fig 13 One ball bearing loss in ultrasonic cleaning

3.3 Data acquisition procedure

Data acquisition by measuring vibration signal with FFT spectrum (dB), crest factor from time waveform and motor current (mA) as setting 50 data samples were collected for each condition per statistical requirement as shown in Fig 14.



Fig 14 Schematic of data collection

3.4 Classification of artificial neural network
ANN technique was used to classify root cause of linear bearing fault condition. Three types of input signals included FFT spectrum, motor current and crest factor. The ANN programs consisted of the three group of input parameter such as single, double and triple input parameter. The propose of this experiment was conducted to compare accuracy of the ANN program as shown in Fig15, Fig16, and Fig17 respectively. The experiment is simplifying procedure of all three program with the total 300 sample data sets of six conditions. ANN program classified linear motor fault conditions as follow by single, double, and triple parameter into input layers, 1 hidden layer 10 nodes and 6 output are showed as Fig 18. The ANN training used the scaled conjugate gradient algorithm by dividing the data set by 70% for training, 15% for validating and 15% for testing




Fig.17 Schematic of triple parameters ANN program




Fig.18 Schematic of Artificial Neural Network




Fig.15 Schematic of single parameter ANN program




Fig.16 Schematic of double parameters ANN program

4 Result and Discussion

The results of ANN program analyzed based on all three types of input parameter.

4.1 Data acquisition procedure

4.1.1 FFT spectrum analysis

The amplitude of FFT spectrum comparison for six conditions depicted as Fig19, result can be divided into two groups of data. First group includes healthy and starved lubricant condition shown significant different from the second group which includes four conditions. All four conditions show comparable vibration amplitude with 95% confidence interval (Table 1).




Fig.19 Boxplot of FFT spectrum

Table 1. 95% confidence interval of spectrum

Type	Condition	FFT spectrum (dB) of 95% Confidence Interval
single	Healthy bearing	-113.493 to -112.463
single	One ball bearing damage	-92.583 to -91.553
single	One ball bearing loss	-98.959 to -97.929
single	Starved lubricant bearing	-112.475 to -111.445
Combine	One ball bearing damage with starved lubricant	-100.384 to -99.354
Combine	One ball bearing loss with starved lubricant	-99.358 to -98.329

Table 2. Spectrum comparison with healthy bearing

Target	Fault bearing conditions	Delta	%
Healthy bearing	One ball bearing damage	20.909	18.51
Healthy bearing	One ball bearing loss	17.230	12.86
Healthy bearing	Starved lubricant bearing	1.018	0.90
Healthy bearing	One ball bearing damage with starved lubricant	13.109	11.60
Healthy bearing	One ball bearing loss with starved lubricant	19.113	12.51

The FFT spectrum compared between bearing fault conditions with healthy condition. One ball bearing damage showed 18.51% higher than healthy condition, while starved lubricant condition showed 0.9% delta compared to healthy bearing.

4.1.2 Motor current (mA) analysis

Motor current of six conditions was shown using boxplot in Fig.20. Moreover, the highest motor current value of 1286 mA or 21% higher than healthy bearing condition is one ball bearing loss with starved lubricant condition as shown in Table 3 and Table 4. The bearing fault condition with starved lubricant showed raising up trend of motor current, while other 2 fault conditions (ball bearing loss and damage) showed motor current value slightly higher than healthy bearing condition.




Fig.20 Boxplot of current (mA)

Table 3. Motor current of 95% confident interval

Type	Condition	Motor current (mA) of 95% Confidence Interval
single	Healthy bearing	1054.60 to 1066.52
single	One ball bearing damage	1098.52 to 1110.44
single	One ball bearing loss	1087.96 to 1099.88
single	Starved lubricant bearing	1091.94 to 1103.86
Combine	One ball bearing damage with starved lubricant	1138.82 to 1150.74
Combine	One ball bearing loss with starved lubricant	1280.12 to 1292.04

Table 4. Motor current (mA) comparison with healthy bearing

Target	Fault bearing conditions	Delta	%
Healthy bearing	One ball bearing damage	43.920	4.14
Healthy bearing	One ball bearing loss	33.360	3.15
Healthy bearing	Starved lubricant bearing	37.340	3.52
Healthy bearing	One ball bearing damage with starved lubricant	84.220	7.94
Healthy bearing	One ball bearing loss with starved lubricant	225.520	21.26

4.1.3 Crest factor analysis

The crest factor comparison using boxplot as Fig.21 demonstrate that both ball bearing loss and ball bearing loss with starved lubricated showed low crest factor value or 9.67% and 12.11% respectively compared to healthy condition.




Fig21 Boxplot of crest factor

Table 5. Crest factor of 95% confidence interval

Type	Condition	The crest factor of 95% Confidence Interval
single	Healthy bearing	4.3017 to 4.4996
single	One ball bearing damage	4.0680 to 4.2658
single	One ball bearing loss	3.8761 to 4.0739
single	Starved lubricant bearing	4.1213 to 4.3192
Combine	One ball bearing damage with starved lubricant	4.0700 to 4.2678
Combine	One ball bearing loss with starved lubricant	3.7699 to 3.9677

Table 6. Crest factor comparison with healthy bearing

Target	Fault bearing conditions	Delta	%
Healthy bearing	One ball bearing damage	0.234	5.31
Healthy bearing	One ball bearing loss	0.426	9.67
Healthy bearing	Starved lubricant bearing	0.180	4.10
Healthy bearing	One ball bearing damage with starved lubricant	0.232	5.27
Healthy bearing	One ball bearing loss with starved lubricant	0.533	12.11

4.2 Classification fault condition by Artificial Neural Network

4.2.1 Single parameter program

The ANN program of single parameter using confusion matrix is shown in Fig.22, Fig.23 and Fig.24. The accuracy of the model 58.7%, 54.7% and 43.3% for FFT spectrum, motor current and crest factor parameter respectively. The single parameter input program is not satisfy for predictive fault of linear bearing.

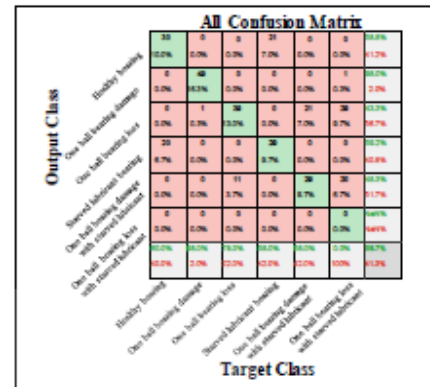


Fig22 Confusion matrix of FFT spectrum




Fig23 Confusion matrix of motor current

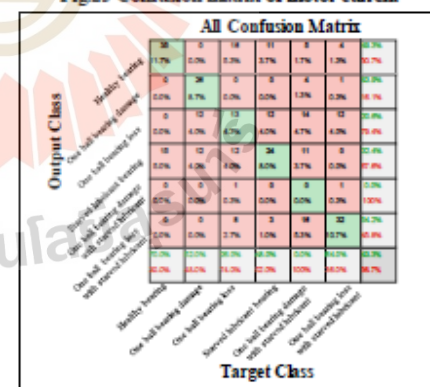


Fig24 Confusion matrix of crest factor

4.2.2 Double parameters program

The double input parameters program was setup by combining two input parameters. As follow by FFT spectrum plus motor current, FFT spectrum plus crest factor and the motor current plus crest factor showed as Fig.25, Fig.26, and Fig.27 respectively. The results of model accuracy are showed 89.7% for FFT spectrum with motor current. While FFT spectrum and crest factor showed 73.3%. And motor current with crest factor showed 68.0%. All result of double parameters program showed more accurate compared to single parameter program.

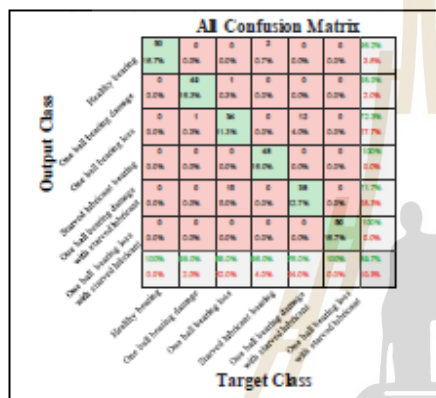


Fig.25 Confusion matrix of FFT spectrum and motor current

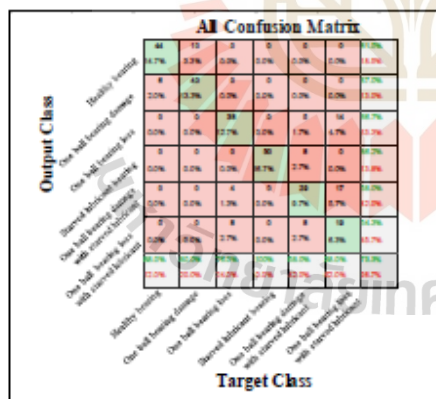


Fig.26 Confusion matrix of FFT spectrum and crest factor

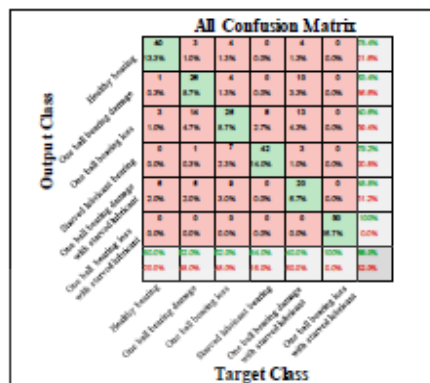


Fig.27 Confusion matrix of motor current and crest factor

4.2.3 Triple parameters program

Triple parameters (FFT spectrum, motor current and crest factor) were used for ANN program. The confusion matrix as Fig.28 showed result of the triple parameters program with accuracy equal to 93%, compared to single and double parameters program. Therefore the prediction by triple input parameters ensures the fault detection of linear bearing.




Fig.28 Confusion matrix of FFT spectrum, motor current and crest factor

Table 8. Summary of confusion matrices

1 st Parameter	2 nd Parameter	3 rd Parameter	%
FFT Spectrum	-	-	58.7%
Motor current	-	-	54.7%
Crest factor	-	-	43.3%
FFT Spectrum	Motor current	-	89.7%
Motor current	Crest factor	-	73.3%
Crest factor	Motor current	-	68.0%
FFT Spectrum	Crest factor	Motor current	93.0%




Fig.29 Comparison of the accuracy of ANN model

5 Conclusion

FDI method can be used for reliability improvement of the automation machine. The primary mechanical failure detection of the automation machine is very important in operational condition before the machine breaks down. This paper presents linear motor fault detection using FFT spectrum, motor current, and crest factor as input signal to detect the linear bearing condition. ANN was used to classify the linear bearing condition resulted from experiment shown increased parameter from single to tripple. The accuracy of model increased raise up to 93.0% as shown in Fig.29. The linear bearing fault can be correctly identified by the decision of ANN. The experimental results showed potential application of ANN as FDI tool for linear bearing fault detection performance.

Acknowledge

This research was supported by the Research and Researcher for Industry (RRI) under the Thailand Research Fund (TRF). It offers a scholarship for Ph.D.

Students, Suranaree University of Technology (SUT) agency through grant PHD60I0043.

References:

- [1] Deeying J., Asawarungsangkul K., Chutima P., Multi-objective optimization on laser solder jet bonding process in head gimbal assembly using the response surface methodology, *Optics & Laser Technology*, Vol.98, 2018, pp.158-168.
- [2] Jaouher A.B., Nader F., Brigitte C.M., Farhat F., Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signal, *Applied Acoustics*, Vol.89, 2015, pp.16-27.
- [3] Issam A., Nadir F., Nadir B., Brahim O., Adel D., A new time-frequency method for identification and classification of ball bearing faults, *Journal of Sound and Vibration*, Vol.397, 2017, pp.241-265.
- [4] Jian C., Robert R.B., Intelligent diagnosis of bearing knock faults in internal combustion engines using vibration simulation, *Mechanism and Machine Theory*, Vol.104, 2016, pp.161-176.
- [5] Han L., Jianzhong Z., Yang Z., Wei J., Yuncheng Z., Fault diagnosis of rolling bearing with recurrent neural network based autoencoders, *ISA Transactions*, Vol.77, 2018, pp.167-178.
- [6] Zhiqiang C., Shengcai D., Xudong C., Chuan L., René-Vinício S., Huaifeng Q., Deep neural networks-based rolling bearing fault diagnosis, *Microelectronics Reliability*, Vol.75, 2017, pp.327-333.
- [7] Claudio B., Fabio I., Marco C., Riccardo R., Alberto B., Fault Detection of Linear Bearing in Brushless AC Linear Motors by Vibration Analysis, *IEEE Transaction on Industrial Electronics*, Vol.58, No.5, 2011, pp.1684-1694.
- [8] Chen L., Zhenya W., Bo Z., Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification, *Advanced Engineering Informatics*, Vol.32, 2017, pp.139-151.
- [9] Chean Z., Zhipeng F., Xiukun W., Yong Q., Sparse classification based on dictionary learning for planet bearing fault identification, *Expert Systems with Applications*, Vol.108, 2018, pp.233-245.

- [10] Muhammad AZD, Shahab AN, Saeed AB, An Intelligent computing technique to analyse the vibrational dynamics of rotating electrical machine, *Neurocomputing*, Vol.219, 2017, pp. 280-299.
- [11] Bubathi M, Sanjith MA, Kishnakumar B, Satya Murty S.A.V., Roller element bearing fault diagnosis using singular spectrum analysis, *Neurocomputing*, Vol.35, 2013, pp. 150-166.
- [12] Salunkhe S, Rajamani D, Esakki B, Application of artificial neural network and adaptive neuro fuzzy inference systems for prediction of life of stripper, *International Journal of Modern Manufacturing Technologies*, Vol.10, 2018, pp.76-83.
- [13] Bettine F, Ameddah H, Manaa R, A neural network approach for predicting kinematic errors solutions for trochoidal machining in Matsuura MX-330 five-axis machine, *FME Transactions*, Vol.46, 2018, pp.453-462.
- [14] Kozjek D, Butala P., Knowledge elicitation for fault diagnostics in plastic injection moulding. A case for machine-to-machine communication, *CIRP Annals*, Vol.66, No.1, 2017, pp. 433-436.
- [15] Selak L, Butala P, Sluga A, Condition monitoring and fault diagnostics for hydropower plants. *Computers in Industry*, Vol.65, No.6, 2014, pp. 924

ประวัติผู้เขียน

นายสิวณู เหล่าบุตรสา เกิดเมื่อวันที่ 16 เมษายน พ.ศ. 2526 ที่อำเภอเขมราฐ จังหวัดอุบลราชธานี ได้รับการศึกษามัธยมที่โรงเรียนราชสีมาวิทยาลัย จบการศึกษาชั้นประกาศนียบัตรชั้นสูงที่มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน (ชื่อเดิมสถาบันเทคโนโลยีเทคโนโลยีราชมงคลวิทยาเขตภาคตะวันออกเฉียงเหนือ) จบการศึกษาระดับปริญญาตรี สาขาวิศวกรรมเมคคาทรอนิกส์ ที่มหาวิทยาลัยเทคโนโลยีสุรนารี หลังจากนั้นได้เข้ารับการศึกษาระดับวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมเครื่องกล (หลักสูตรวิศวกรรมเมคคาทรอนิกส์) ในปี พ.ศ. 2559 ขณะศึกษาได้ไปฝึกงานที่บริษัท เวสเทิร์น ดิจิตอล (ประเทศไทย) จำกัด เป็นระยะเวลา 2 ปี ในระหว่างศึกษาระดับปริญญาโทได้นำเสนอผลงานวิชาการจำนวน 2 เรื่อง รายละเอียดมีปรากฏดังภาคผนวก ค.

