

อัลกอริทึมการตรวจจับความผิดปกติในการทำงานของบอลเบริงด้วยวิธีวิเคราะห์
สัญญาณการสั่นสะเทือนอาศัยการถดถอยโลจิสติกแบบทวินาม

EARLY FAULT DETECTION ALGORITHM BASED ON BALL BEARING VIBRATION
ANALYSIS USING BINOMIAL LOGISTIC REGRESSION



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมระบบควบคุม

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2560

KMITL-2017-EN-M-080-077

อัลกอริทึมการตรวจจับความผิดปกติในการทำงานของบอลเบริงด้วยวิธีวิเคราะห์
สัญญาณการสั่นสะเทือนอาศัยการถดถอยโลจิสติกแบบทวินาม

EARLY FAULT DETECTION ALGORITHM BASED ON BALL BEARING VIBRATION
ANALYSIS USING BINOMIAL LOGISTIC REGRESSION



T148687



เลขหมู่.....**148687**
เลขทะเบียน.....
วันเดือนปี 14 พ.ย. 2560

b. 00267604
1.....

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมระบบควบคุม
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ.2560
KMITL-2017-EN-M-080-077

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

EARLY FAULT DETECTION ALGORITHM BASED ON BALL BEARING VIBRATION
ANALYSIS USING BINOMIAL LOGISTIC REGRESSION



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN CONTROL ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2017

KMITL-2017-EN-M-080-077

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2017

FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ อัลกอริทึมการตรวจจับความผิดปกติในการทำงานของบอลแบร์ริงด้วยวิธีวิเคราะห์สัญญาณ
การสั่นสะเทือนอาศัยการถดถอยโลจิสติกแบบทวินาม

Thesis Title Early Falut Detection Algorithm based on Ball Bearing Vibration Analysis
Using Binomial Logistic Regression

นักศึกษา นายชนเดช เกิดศิริ

รหัสประจำตัว 58601194

ปริญญา วิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชา วิศวกรรมระบบควบคุม

อาจารย์ที่ปรึกษาวิทยานิพนธ์ ดร.รัชนี กุลยานนท์

หมายเลขวิทยานิพนธ์ KMITL-2017-EN-M-080-077

คณะกรรมการสอบวิทยานิพนธ์		ลายมือชื่อ
รศ.ดร.จنگล	งามวิวิทย์	
รศ.ดร.ถาวร	เบญจนราสุทธิ	
ผศ.ดร.นพดล	มณีรัตน์	
ผศ.ดร.ดอน	อิศรากร	
ดร.รัชนี	กุลยานนท์	

วัน / เดือน/ ปี ที่สอบ วันอังคารที่ 18 กรกฎาคม พ.ศ. 2560 เวลา 15.00-17.00 น.
สถานที่สอบ ณ อาคารเฉลิมพระเกียรติ ห้อง HM-306

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

คณะวิศวกรรมศาสตร์ รับรองแล้ว



(รองศาสตราจารย์ ดร. คมสัน มาลีสี)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ฉบับนี้ คณะวิศวกรรมศาสตร์
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้
วันที่ 18 กรกฎาคม พ.ศ. 2560

หัวข้อวิทยานิพนธ์	อัลกอริทึมการตรวจจับความผิดปกติในการทำงานของบอล แบร์ริงด้วยวิธีวิเคราะห์สัญญาณการสั่นสะเทือนอาศัยการ ถดถอยโลจิสติกแบบทวินาม
นักศึกษา	นายธนเดช เกิดศิริ
รหัสนักศึกษา	58601194
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมระบบควบคุม
พ.ศ.	2560
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ดร. รัชณี กุลยานนท์

บทคัดย่อ

เครื่องจักรกลหมุนได้เข้ามามีบทบาทสำคัญต่อการขับเคลื่อนเศรษฐกิจ ทั้งในภาคขนส่ง ภาคอุตสาหกรรม และในการทหาร การบำรุงรักษาเครื่องจักรกลหมุนให้ทำงานได้อย่างต่อเนื่องเป็นสิ่งที่สำคัญอย่างยิ่ง โดยความพร้อมใช้งานของเครื่องจักรกลหมุนขึ้นอยู่กับความสมบูรณ์ของ Ball Bearing ซึ่งมีหลายปัจจัยด้วยกันที่ทำให้แบร์ริงเสียหาย เช่น สิ่งปนเปื้อนในสารหล่อลื่น การติดตั้งที่ไม่เหมาะสม เป็นต้น ซึ่งความผิดปกติทั้งหมดนี้สามารถตรวจจับได้ด้วยการวิเคราะห์สัญญาณการสั่นสะเทือน ดังนั้นวิทยานิพนธ์ฉบับนี้จึงได้เลือกใช้สัญญาณการสั่นสะเทือนในการพัฒนาระบบตรวจจับความผิดปกติของ Ball Bearing และเตือนผู้ปฏิบัติงานให้ทราบถึงความผิดปกติที่เกิดขึ้น วิทยานิพนธ์ฉบับนี้ได้นำเสนออัลกอริทึมตรวจจับความผิดปกติของบอลแบร์ริง โดยใช้การวิเคราะห์การถดถอยโลจิสติกแบบทวินาม (Binomial Logistic Regression) เพื่อประเมินความสมบูรณ์ของแบร์ริง โดยใช้ค่าคุณลักษณะสำคัญต่างๆ เช่น Wavelet Packet Decomposition Node Energy, Kurtosis และ Crest Factor โดยผลลัพธ์ที่ได้จะถูกทำให้ราบเรียบมากยิ่งขึ้นด้วยวิธีการเฉลี่ยของ Savitzky-Golay ก่อนที่จะถูกระบุช่วงเวลาในการเกิดความผิดปกติด้วยค่าขอบล่างของช่วงความเชื่อมั่นที่ 99% และวิธีที่ได้นำเสนอนี้ได้ถูกทดสอบด้วยข้อมูลการสั่นสะเทือนจริงของแบร์ริงที่เผยแพร่โดยสถาบัน FEMTO-ST ซึ่งแสดงให้เห็นว่าสามารถทำนายตำแหน่งเวลาการเกิดความผิดปกติได้อย่างแม่นยำเพียง 20 วินาทีก่อนที่จะเกิดความผิดปกติขึ้น และในกรณีที่อัลกอริทึมให้ผลการตรวจจับความผิดปกติที่ช้าที่สุด สามารถตรวจจับความผิดปกติที่เกิดขึ้นได้ประมาณ 15 นาที 10 วินาที หลังจากตำแหน่งที่ถูกระบุว่าเป็นตำแหน่งที่แบร์ริงเกิดความผิดปกติขึ้นจริง โดยสามารถสังเกตแนวโน้มการเพิ่มขึ้นของค่าความน่าจะเป็นที่ระบบจะเกิดความล้มเหลวได้ตั้งแต่วินาทีแรกของการเกิดความผิดปกติ ดังนั้นอัลกอริทึมที่ได้นำเสนอนี้จึงสามารถนำไปใช้ในการตรวจจับความผิดปกติที่เกิดขึ้นกับบอลแบร์ริงได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Thesis Title	Early Fault Detection Algorithm based on Ball Bearing Vibration Analysis using Binomial Logistic Regression
Student	Mr. Thanadat Kerdsiri
Student ID.	58601194
Degree	Master of Engineering
Program	Control Engineering
Year	2017
Thesis Advisor	Dr. Rutchanee Gullayanon

ABSTRACT

Rotating machines play an important role in several applications such as transportation, industry and military. Maintaining continuous operations of these machines is vital to these applications. The reliability of these rotating machines depends on ball bearing health. Bearing can fail from many factors, e.g., impurity of lubricant, improper installation, etc. All of these defects can be detected by vibration analysis. Therefore, vibration signals are utilized to develop early fault detection of ball bearing to warn operators of any anomalies in the system. This research presents a fault detection algorithm using a binomial logistic regression method to assess the health state of ball bearing. This regression utilizes the node energy of wavelet packet decomposition, kurtosis and crest factor as key features. The resulting signals are processed using the Savitzky-Golay smoothing algorithm before determining the time location where the defects occur with a confidence interval of 99%. The proposed method was tested with actual vibration data of bearing which were provided by the FEMTO-ST institute and showed that it is capable of accurately predicting defect time only 20 seconds before the actual defect occurred. The worst-case prediction of 15 minute 10 seconds after defect occurs also observed during experiment. Although the system did not set off alarm for fault detection after 15 minutes 10 seconds, one can observe an increase in the fault probability trends in early state. Therefore, the proposed algorithm can be utilized for early fault detection in ball bearing applications.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จขึ้นได้จากความกรุณาของ ดร. รัชณี กุลยานนท์ ผู้ซึ่งเป็นอาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่กรุณาให้คำแนะนำ ชี้แนะแนวทางในการทำวิจัยอย่างเป็นระบบระเบียบตลอดจนตรวจทานแก้ไขข้อบกพร่องที่เกิดขึ้นในการวิจัย และขอขอบพระคุณอาจารย์อีกหลายๆ ท่าน ที่กรุณาประสิทธิประสาทวิชาความรู้ รวมทั้งให้ข้อเสนอแนะในงานวิจัยอันทรงคุณค่าแก่ข้าพเจ้า

ขอขอบคุณ น.อ. ไพโรจน์ เกิดศิริ ร.น. และ จ.อ. ราชการ เกิดศิริ สำหรับการชี้แนะวิธีการวิเคราะห์ความผิดปกติของอุปกรณ์การบินที่สำคัญ โดยอาศัยข้อมูลที่ได้จากระบบตรวจวิเคราะห์ความผิดปกติในระบบการบินที่ถูกติดตั้งในอากาศยานเป็นข้อมูลในการซ่อมบำรุง

ขอขอบคุณสถาบัน FEMTO-ST แห่งประเทศฝรั่งเศส ที่เอื้อเพื่อสัญญาอนุญาตการสันเสที่อนที่ได้จากการทดสอบแบริงให้แกข้าพเจ้า ซึ่งได้ใช้เป็นข้อมูลหลักในการพัฒนาวิทยานิพนธ์ฉบับนี้ขึ้น

ท้ายที่สุดนี้ขอกราบขอบพระคุณบิดา มารดา และครอบครัว ซึ่งมีส่วนสำคัญอย่างยิ่งในการสนับสนุนการศึกษา ให้กำลังใจ และให้ข้อคิดอันมีค่าในการดำเนินชีวิต จนทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปด้วยดี

ธนเดช เกิดศิริ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VI
สารบัญรูปภาพ.....	VII
บทที่ 1 บทนำ.....	1
1.1 บทนำ.....	1
1.2 ความเป็นมาของงานวิจัย.....	1
1.3 วัตถุประสงค์การศึกษา.....	5
1.4 ขอบเขตการวิจัย.....	5
1.5 รายละเอียดของวิทยานิพนธ์.....	6
บทที่ 2 ทฤษฎีและหลักการ.....	7
2.1 บทนำ.....	7
2.2 ความผิดปกติที่เกิดขึ้นกับแบริ่งและวิธีการตรวจจับความผิดปกติ.....	7
2.3 ชุดทดสอบเร่งอายุการทำงานของแบริ่ง (PROGNOSTIA Platform).....	8
2.4 อัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง.....	11
2.5 การสกัดคุณลักษณะสำคัญ (Feature Extraction).....	12
2.5.1 คุณลักษณะบนโดเมนเวลา (Time Domain Features).....	12
2.5.1.1 ค่าตัวประกอบยอดคลื่น (Crest Factor).....	13
2.5.1.2 ความโด่งของการกระจายตัวความน่าจะเป็นของข้อมูล (Kurtosis).....	13
2.5.2 คุณลักษณะบนโดเมนความถี่ (Frequency Domain Features).....	13
2.5.2.1 การแปลงฟูเรียร์ไม่ต่อเนื่อง (Discrete Fourier Transform).....	14
2.5.3 คุณลักษณะบนโดเมนเวลา-ความถี่ (Time-Frequency Domain Features).....	15
2.5.3.1 การแปลงฟูเรียร์ช่วงสั้น (Short-Time Fourier Transform).....	15
2.5.3.2 การแปลงเวฟเลต (Wavelet Transform).....	17
2.5.3.3 การแยกส่วนประกอบเวฟเลตแพกเก็ต (Wavelet Packet Decomposition).....	19
2.5.3.4 พลังงานของโหนดส่วนประกอบเวฟเลตแพกเก็ต (Wavelet Packet Decomposition Node Energy).....	20
2.6 เครื่องมือคัดกรองความผิดปกติ (Classifier).....	20

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
2.1 ชุดข้อมูลการสั้นสะเทือน IEEE PHM 2012 Data Challenge	11
3.1 ช่วงเวลาที่แบริ่งเริ่มเกิดเกิดความผิดปกติ	27
3.2 ระยะห่างระหว่างขนาดขององค์ประกอบความถี่หลักที่น้อยที่สุดของสัญญาณการสั้นสะเทือนในแนวระดับ	28
3.3 ระยะห่างระหว่างขนาดขององค์ประกอบความถี่หลักที่น้อยที่สุดของสัญญาณการสั้นสะเทือนในแนวตั้ง	28
3.4 Maximum Energy to Shannon Entropy Ratio ของสัญญาณการสั้นสะเทือนในแนวระดับ	29
3.5 Maximum Energy to Shannon Entropy Ratio ของสัญญาณการสั้นสะเทือนในแนวตั้ง	30
3.6 พารามิเตอร์ของแบบจำลองการถดถอยโลจิสติกแบบทวินาม	32
3.7 ค่าเฉลี่ยของโอกาสที่แบริ่งจะทำงานผิดปกติของชุดข้อมูลที่ใช้พัฒนาอัลกอริทึม	35
3.8 ค่าขอบเขตล่างของช่วงความเชื่อมั่นที่ระดับความเชื่อมั่นต่างๆ	35
3.9 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 80%	37
3.10 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 85%	38
3.11 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 90%	38
3.12 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 95%	39
3.13 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 99%	39
3.14 แสดงค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์ของการเฉลี่ยด้วยวิธี Savitzky-Golay ที่พารามิเตอร์การเฉลี่ยค่าต่างๆ	41
4.1 ผลการทดสอบอัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของแบริ่ง	46
4.2 ผลการประเมินประสิทธิภาพของอัลกอริทึมด้วยตัวชี้วัดต่างๆ	49

สารบัญรูปภาพ

รูปที่	หน้า
1.1 แผนผังแสดงวิธีการซ่อมบำรุงเครื่องจักรกล.....	3
1.2 กระบวนการทำนายอายุการใช้งานคงเหลือของเครื่องจักรกล	3
1.3 ค่าโอกาสที่เครื่องจักรกลจะเกิดความผิดปกติในทางอุดมคติ	4
1.4 อัลกอริทึมการทำนายอายุการใช้งานคงเหลือและอัลกอริทึมในการตรวจจับความผิดปกติ ของเครื่องจักรกล.....	5
2.1 เพลลาและแบร์ริง.....	8
2.2 PROGNOSTIA Platform.....	9
2.3 วิธีการบันทึกข้อมูลการสั่นสะเทือนของชุดข้อมูล IEEE PHM 2012 Data Challenge.....	9
2.4 การบันทึกข้อมูลแบบ Run-to-Failure และแบบ Truncated.....	10
2.5 ระบบตรวจจับความผิดปกติ และระบบวิเคราะห์ความผิดปกติในการทำงานของแบร์ริง	12
2.6 สัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$ บนโดเมนเวลา	14
2.7 องค์ประกอบความถี่ของสัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$	15
2.8 ผลการแปลง STFT ของสัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$ โดยใช้หน้าต่างขนาด 200 จุดข้อมูล และมีส่วนซ้อนทับ 198 จุดข้อมูล	16
2.9 ผลการแปลง STFT ของสัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$ โดยใช้หน้าต่างขนาด 100 จุดข้อมูล และมีส่วนซ้อนทับ 96 จุดข้อมูล	17
2.10 ผลการแปลง STFT ของสัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$ โดยใช้หน้าต่างขนาด 50 จุดข้อมูล และมีส่วนซ้อนทับ 48 จุดข้อมูล	17
2.11 Wavelet Function.....	18
2.12 Wavelet Packet Decomposition Tree.....	19
3.1 วิธีการเก็บบันทึกข้อมูลการสั่นสะเทือนของ IEEE PHM2012 Data Challenge.....	25
3.2 ความถี่หลักที่ได้จากการแปลงฟูเรียร์ของสัญญาณการการสั่นสะเทือนของชุดข้อมูลที่ 4	26
3.3 ความถี่ที่ได้จากการแปลงฟูเรียร์ของสัญญาณการการสั่นสะเทือนของชุดข้อมูลที่ 15.....	26
3.4 ค่าโอกาสที่แบร์ริงจะทำงานในสภาวะที่เกิดความผิดปกติของชุดข้อมูลที่ 9	34
3.5 ค่าโอกาสที่แบร์ริงทำงานผิดปกติของชุดข้อมูลที่ 9 โดยแบ่งได้เป็น 2 กลุ่มข้อมูล คือ ค่า โอกาสที่แบร์ริงจะทำงานในสภาวะที่ผิดปกติก่อนและหลังจุดที่แบร์ริงทำงานผิดปกติแท้จริง.....	34
3.6 วิธีการคำนวณค่าความผิดพลาดของโอกาสที่แบร์ริงจะทำงานผิดปกติ	37
3.7 ค่าโอกาสที่แบร์ริงจะทำงานผิดปกติที่ได้จากแบบจำลองที่ได้พัฒนาขึ้น ที่ทดสอบด้วย ชุดข้อมูลที่ 1	40
3.8 ค่าโอกาสที่แบร์ริงทำงานผิดปกติของชุดข้อมูลที่ 4 ที่ผ่านการปรับความราบเรียบด้วยวิธี ของ Savitzky-Golay ด้วยขนาดความกว้างของหน้าต่างในการเฉลี่ยเท่ากับ 19 จุดข้อมูล และประมาณค่าเฉลี่ยด้วยพหุนามกำลัง 0	42

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูปภาพ(ต่อ)

รูปที่	หน้า
4.1 ขั้นตอนการทดสอบอัลกอริทึมสำหรับตรวจจับการทำงานที่ผิดปกติของแบรีจ	43
4.2 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบรีจ ด้วยชุดข้อมูลที่ 2.....	44
4.3 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบรีจ ด้วยชุดข้อมูลที่ 6.....	45
4.4 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบรีจ ด้วยชุดข้อมูลที่ 8.....	45
4.5 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบรีจ ด้วยชุดข้อมูลที่ 15 ...	46
5.1 ภาพรวมอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบรีจ	52



บทที่ 1

บทนำ

1.1 บทนำ

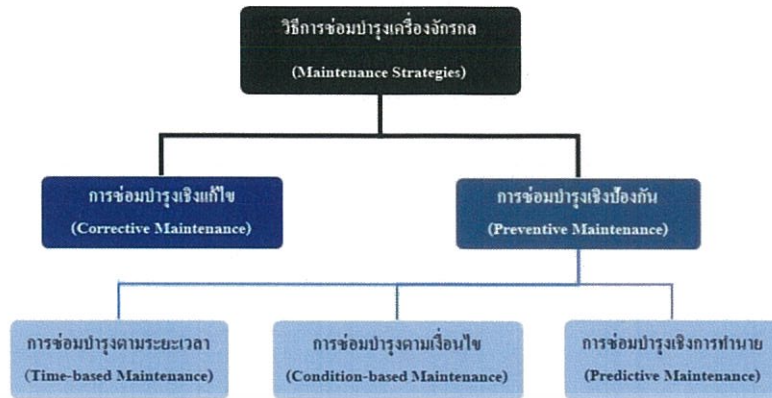
ในบทนี้กล่าวถึงความเป็นมาและวัตถุประสงค์ของงานวิจัยเพื่อพัฒนาอัลกอริทึมตรวจสอบความผิดปกติในการทำงานของแบริ่ง จากนั้นเป็นส่วนของขอบเขตงานวิจัยที่บรรยายถึงข้อจำกัดของการศึกษาวิจัยในบางประการ และส่วนสุดท้ายกล่าวถึงรายละเอียดของเนื้อหาวิทยานิพนธ์ในแต่ละบท

1.2 ความเป็นมาของงานวิจัย

ปัจจุบันเครื่องจักรกลมีบทบาทสำคัญยิ่งต่อการขับเคลื่อนเศรษฐกิจของประเทศ ทั้งในด้านอุตสาหกรรม การขนส่ง การทหาร หรือแม้แต่สิ่งอำนวยความสะดวกต่างๆ ในชีวิตประจำวัน ดังนั้นหลายๆ ภาคส่วนจึงให้ความสำคัญอย่างยิ่งในการพัฒนาเทคโนโลยีต่างๆ เพื่อให้เครื่องจักรกลสามารถทำงานได้แม่นยำมากยิ่งขึ้น และมีระยะเวลาในการทำงานมากยิ่งขึ้น (Life Time) เป็นผลให้เครื่องจักรกลในปัจจุบันมีกลไกการทำงานที่ซับซ้อนอย่างมาก ดังนั้นเพื่อให้เครื่องจักรกลสามารถทำงานได้อย่างเต็มประสิทธิภาพ และมีระยะเวลาที่ในการซ่อมบำรุงที่น้อยลง การเลือกกลยุทธ์ในการบำรุงรักษาเครื่องจักรกลให้เหมาะสมจึงมีความจำเป็นอย่างยิ่ง โดยเฉพาะกับงานที่มีความเสี่ยงต่อการเกิดอุบัติเหตุสูง ดังเช่น เครื่องจักรกลในอุตสาหกรรมปิโตรเคมี หรือการทหาร เป็นต้น สำหรับการเลือกกลยุทธ์ในการบำรุงรักษาเครื่องจักรกลนั้นขึ้นอยู่กับหลายๆ ปัจจัยด้วยกัน เช่น ทุนที่ใช้ในการบำรุงรักษาเครื่องจักรกล ความชำนาญของบุคลากร ผลกระทบของเครื่องจักรที่มีต่อกระบวนการผลิต รวมถึงความซับซ้อนของเครื่องจักรกล ดังนั้นวิธีการเลือกกลยุทธ์ในการซ่อมบำรุงรักษาเครื่องจักรกลด้วยวิธีการวิเคราะห์แบบหลายกฎเกณฑ์ (Multi - Criteria Decision Making Methods) เป็นวิธีหนึ่งซึ่งช่วยให้สามารถเลือกกลยุทธ์ในการซ่อมบำรุงเครื่องจักรกลได้อย่างเหมาะสม [1, 2]


กลยุทธ์ในการดูแลบำรุงรักษาเครื่องจักรกลได้รับการพัฒนาอย่างต่อเนื่องควบคู่ไปกับการพัฒนาเครื่องจักรกลตั้งแต่ยุคปฏิวัติอุตสาหกรรม ซึ่งเป็นยุคที่มีการริเริ่มที่จะนำเครื่องจักรกลเข้ามาเป็นเครื่องมือในกระบวนการผลิต เครื่องจักรกลในยุคแรกๆ นี้ยังไม่มี ความซับซ้อนมากนัก ดังนั้นวิธีการในการซ่อมบำรุงเครื่องจักรกลจึงเป็นการซ่อมบำรุงเมื่อเครื่องจักรกลชำรุด ซึ่งเป็นการซ่อมบำรุงในเชิงการแก้ไขปรับปรุง (Corrective Maintenance) จึงมีอาจป้องกันความเสียหายร้ายแรงที่อาจเกิดขึ้นได้ในกระบวนการผลิต ดังนั้นเพื่อเป็นการแก้ไขข้อด้อยดังกล่าว กลยุทธ์ในการซ่อมบำรุงเชิงป้องกัน (Preventive Maintenance) จึงได้ถูกพัฒนาขึ้น ซึ่งแนวทางการซ่อมบำรุงเชิงการป้องกันสามารถแยกย่อยได้อีก 2 วิธีการด้วยกันคือ การซ่อมบำรุงเชิงเวลา (Time-based Maintenance) และการซ่อมบำรุงตามเงื่อนไข (Condition-based Maintenance) โดยวิธีการซ่อมบำรุงเชิงเวลา เจ้าหน้าที่เอกสบำรุงรักษาเครื่องจักรกลจะดำเนินการซ่อมบำรุงหรือเปลี่ยนชิ้นส่วนของเครื่องจักรกลโดยการคำนวณว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พิจารณาตามอายุการทำงานของชิ้นส่วน หรือเครื่องจักร ทำให้ผู้ใช้งานอาจใช้งานชิ้นส่วนนั้นๆ ได้ไม่เต็มประสิทธิภาพ ในส่วนของการบำรุงรักษาตามเงื่อนไข เจ้าหน้าที่บำรุงรักษาอาศัยการวิเคราะห์ความสมบูรณ์ของเครื่องจักรกลโดยการติดตามสัญญาณหรือเงื่อนไขในการทำงานของเครื่องจักรกล เพื่อเป็นข้อมูลในการวางแผนการซ่อมบำรุง ซึ่งช่วยลดความเสี่ยงในการเกิดอุบัติเหตุร้ายแรงที่จะเกิดขึ้นได้ นอกจากกลยุทธ์การซ่อมบำรุงเชิงแก้ไขและการซ่อมบำรุงเชิงป้องกันแล้ว กลยุทธ์การซ่อมบำรุงเชิงการทำนาย (Predictive Maintenance) ยังเป็นอีกกลยุทธ์หนึ่งที่ได้รับการพัฒนาอย่างต่อเนื่อง โดยที่ผลลัพธ์ในการทำนายเป็นค่าอายุการใช้งานคงเหลือของเครื่องจักรกล (Remaining Useful Life, RUL) ซึ่งเป็นข้อมูลสำคัญที่ช่วยให้เจ้าหน้าที่ซ่อมบำรุงวางแผนการซ่อมบำรุงรักษาเครื่องจักรกล และจัดการอะไหล่คงคลังได้อย่างมีประสิทธิภาพมากยิ่งขึ้น นอกจากนี้ยังสามารถลดความเสี่ยงในการเกิดอุบัติเหตุร้ายแรงในกระบวนการผลิตลงได้ โดยแนวทางในการประมาณหาค่าระยะเวลาคงเหลือของเครื่องจักรกลสามารถแบ่งได้เป็น 3 แนวทางหลักๆ คือ การประมาณโดยอาศัยสมการทางคณิตศาสตร์ และข้อมูลจำเพาะของเครื่องจักรกล (Model-based Prognostic) [3], การประมาณโดยอาศัยข้อมูลความผิดปกติทางสถิติของเครื่องจักรกล (Experience-based Prognostic) และการประมาณโดยการเรียนรู้พฤติกรรมของเครื่องจักรกลผ่านข้อมูลสำคัญของเครื่องจักรกลที่เฝ้าติดตาม (Data-driven Prognostic) [4–6] จากทั้ง 3 แนวทางนี้ วิธีการประมาณระยะเวลาคงเหลือของเครื่องจักรกลด้วยแบบจำลองทางคณิตศาสตร์ (Model-based Prognostic) ให้ความแม่นยำในการทำนายมากที่สุด แต่ทว่าสามารถทำได้ยากยิ่งในทางปฏิบัติ เนื่องจากเครื่องจักรกลแต่ละชิ้นมีการทำงานที่เกี่ยวข้องกัน ทำให้แบบจำลองทางคณิตศาสตร์มีความซับซ้อนอย่างมาก ส่วนวิธีการประมาณอายุการใช้งานคงเหลือด้วยวิธีการวิเคราะห์ข้อมูลความผิดปกติของเครื่องจักรกลทางสถิติ (Experience-based Prognostic) เป็นวิธีที่มีความซับซ้อนน้อยที่สุด แต่มีความแม่นยำในการทำนายอยู่ในระดับต่ำ เนื่องจากความเชื่อถือได้ในการประมาณค่าระยะเวลาคงเหลือด้วยวิธีนี้จะขึ้นอยู่กับข้อมูลความผิดปกติของเครื่องจักรกลในอดีตเท่านั้น โดยวิธีการประมาณอายุการใช้งานคงเหลือของเครื่องจักรกลที่ถูกใช้งานอย่างแพร่หลายคือ วิธีการเรียนรู้ผ่านข้อมูลที่เฝ้าติดตาม เนื่องจากการหาแบบจำลองพฤติกรรมการทำงานของเครื่องจักรกลทำได้โดยอาศัยการเรียนรู้ผ่านข้อมูลสำคัญที่เฝ้าติดตามที่ได้จากเซนเซอร์ ด้วยอัลกอริทึมต่างๆ เช่น โครงข่ายประสาทเทียม (Artificial Neural Network, ANN), แบบจำลองมาร์คอฟซ่อนเร้น (Hidden Markov Model) หรือเครื่องมือจัดจำแนกต่างๆ (Classifier) เป็นต้น ด้วยขีดความสามารถการประมวลผลของหน่วยประมวลผลในปัจจุบัน ทำให้สามารถประมาณค่าพารามิเตอร์ต่างๆ ของแบบจำลองที่มีความซับซ้อนด้วยการเรียนรู้จากข้อมูลที่ได้บันทึกไว้ในปริมาณมากได้ด้วยระยะเวลาอันรวดเร็ว เป็นผลให้การทำนายอายุการใช้งานคงเหลือของเครื่องจักรกลด้วยวิธีการนี้เป็นที่นิยมอย่างมาก สำหรับกลยุทธ์ในการบำรุงรักษาเครื่องจักรกลดังกล่าวมาทั้งหมดนี้ สามารถสรุปเป็นแผนผังได้ดังรูปที่ 1.1



รูปที่ 1.1 แผนผังแสดงวิธีการซ่อมบำรุงเครื่องจักรกล

ในกระบวนการประมาณค่าระยะเวลาการทำงานคงเหลือของเครื่องจักรกล ในกลยุทธ์การซ่อมบำรุงเชิงการทำนาย สามารถจำแนกได้ทั้งหมด 5 ขั้นตอนหลักๆ ดังแสดงในรูปที่ 1.2 โดยเริ่มจากการประมวลผลข้อมูลขั้นต้นเพื่อกำจัดสัญญาณรบกวนที่รวมอยู่ในสัญญาณต้นฉบับที่ทำการบันทึกได้จากเซนเซอร์ รวมทั้งจัดเตรียมข้อมูลให้อยู่ในรูปแบบที่เหมาะสมต่อการประมวลผลในลำดับถัดไป จากนั้นเป็นขั้นตอนการสกัดคุณลักษณะสำคัญออกจากสัญญาณต้นฉบับ ในบางอัลกอริทึมจะใช้สัญญาณต้นฉบับในการสร้างแบบจำลองพฤติกรรมของเครื่องจักรกล จึงไม่จำเป็นต้องมีกระบวนการสกัดคุณลักษณะสำคัญออกจากสัญญาณแต่อย่างใด ต่อจากนั้นในกรณีที่ข้อมูลที่จะใช้ในการสร้างแบบจำลองพฤติกรรมมีมิติมากเกินไป สามารถลดมิติของข้อมูลได้โดยอาศัยเครื่องมือในการวิเคราะห์องค์ประกอบต่างๆ เช่น การวิเคราะห์องค์ประกอบสำคัญ (Principle Component Analysis) เป็นต้น ซึ่งสามารถช่วยลดขั้นตอนการประมวลผลของหน่วยประมวลผลลงได้ ในขั้นตอนต่อไปเป็นกระบวนการสร้างแบบจำลองพฤติกรรมการทำงานของเครื่องจักรกลซึ่งสามารถทำได้หลายแนวทางด้วยกัน ขึ้นอยู่กับความชำนาญของผู้วิจัย ทูนในการวิจัย และระดับความแม่นยำของการทำนายที่ต้องการ โดยผลลัพธ์ที่ได้จากแบบจำลองพฤติกรรมนั้นอาจเป็นค่าสถานะการทำงานของเครื่องจักรกลหรือโอกาสการเกิดความผิดปกติในการทำงานของเครื่องจักรกล เป็นต้น ซึ่งเป็นข้อมูลที่ใช้ในการประมาณค่าระยะเวลาการทำงานคงเหลือของเครื่องจักรกลต่อไป

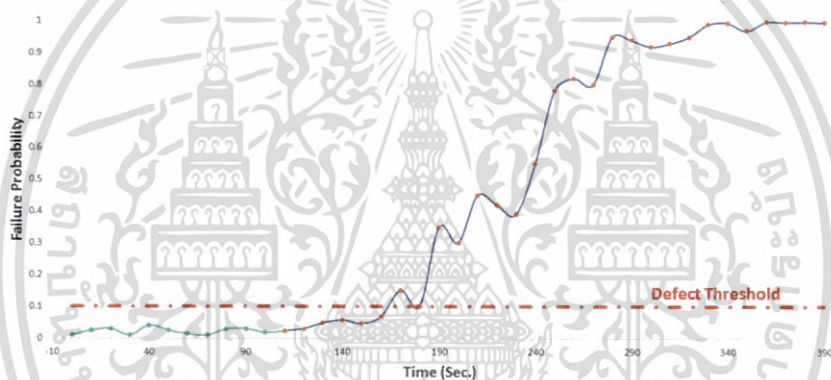


รูปที่ 1.2 กระบวนการทำนายอายุการใช้งานคงเหลือของเครื่องจักรกล

อัลกอริทึมการทำนายอายุการใช้งานคงเหลือของเครื่องจักรกล ส่วนใหญ่จะใช้ค่าผลลัพธ์การทำนายที่ได้จากอัลกอริทึมเดียว จึงทำให้อัลกอริทึมที่ได้มีความคงทน (Robustness) ต่อข้อมูลที่เปลี่ยนแปลงไปได้ต่ำ กล่าวคือ อัลกอริทึมที่ใช้ในการทำนายอายุการใช้งานคงเหลือให้ผลลัพธ์การทำนายที่ไม่มีความแม่นยำเพียงพอ หากข้อมูลที่ใช้ในการทำนายมีรูปแบบที่แตกต่างไปจากข้อมูลที่ใช้ในการเรียนรู้ของอัลกอริทึม เพื่อแก้ปัญหาดังกล่าววิธีการทำนายอายุการใช้งานคงเหลือแบบหลายอัลกอริทึมจึงได้ถูกพัฒนาขึ้น [7] โดยค่าอายุการใช้งานคงเหลือของเครื่องจักรกลที่ได้จากการทำนายด้วยวิธีการนี้จะอาศัยผลรวมถ่วงน้ำหนักของผลลัพธ์การทำนายที่ได้จากหลายๆ อัลกอริทึม ช่วยให้ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อัลกอริทึมที่ได้มีประสิทธิภาพมากยิ่งขึ้น แต่ทว่าการทำนายอายุการใช้งานคงเหลือแบบหลายอัลกอริทึมนี้ต้องการหน่วยประมวลผลที่มีประสิทธิภาพสูงกว่าการทำนายด้วยวิธีปกติ เนื่องจากต้องประมวลผลในหลายๆ อัลกอริทึมในคราวเดียว ดังนั้นการทำนายด้วยวิธีการดังกล่าวจึงมีต้นทุนในการพัฒนาที่สูงกว่าวิธีอื่นๆ

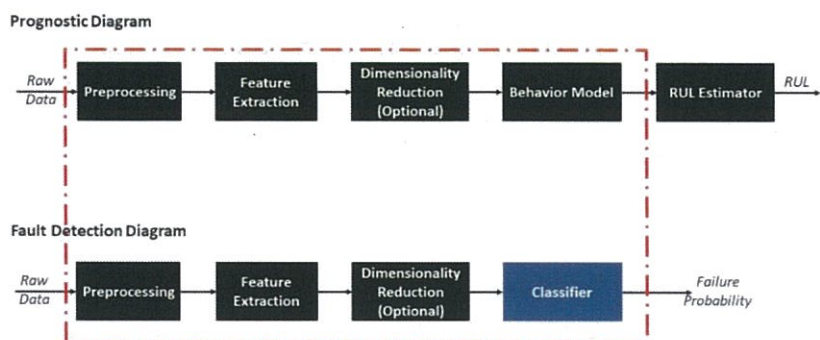
นอกจากระบบการทำนายอายุการใช้งานคงเหลือของเครื่องจักรกลแล้ว ระบบการตรวจจับความผิดปกติในการทำงานของเครื่องจักรกล เป็นอีกระบบหนึ่งที่ช่วยให้วิศวกรซ่อมบำรุงทราบถึงความสมบูรณ์ของเครื่องจักรกล ซึ่งเป็นข้อมูลที่เป็นประโยชน์อย่างยิ่งในการปรับแผนการซ่อมบำรุงให้มีประสิทธิภาพมากยิ่งขึ้น นอกจากนี้ระบบตรวจจับความผิดปกติในการทำงานของเครื่องจักรกลยังสามารถนำไปประยุกต์ใช้งานกับระบบทำนายอายุการใช้งานคงเหลือของเครื่องจักรกลแบบหลายอัลกอริทึมเพื่อลดการประมวลผลลงได้ เนื่องจากการเสื่อมสภาพของเครื่องจักรกลจะเพิ่มขึ้นอย่างรวดเร็วหลังจากที่เกิดความผิดปกติขึ้นดังแสดงในรูปที่ 1.3 ดังนั้นจึงสามารถละการประมวลผลค่าอายุการใช้งานคงเหลือแบบหลายอัลกอริทึมในช่วงที่เครื่องจักรกลยังทำงานในสภาวะปกติลงได้



รูปที่ 1.3 ค่าโอกาสที่เครื่องจักรกลจะเกิดความผิดปกติในทางอุดมคติ

เมื่อพิจารณาอัลกอริทึมการทำนายอายุการใช้งานคงเหลือของเครื่องจักรกลและอัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของเครื่องจักรกลแล้วพบว่ามีส่วนที่มีการทำงานคล้ายคลึงกันดังแสดงดังรูปที่ 1.4 ดังนั้นถ้าหากระบบตรวจจับความผิดปกติในการทำงานของเครื่องจักรกลให้ผลลัพธ์ในการตรวจจับที่ดี ก็สามารถนำข้อมูลความผิดปกติในการทำงานของเครื่องจักรกลมาใช้ในการปรับแผนการซ่อมบำรุงได้อย่างมีประสิทธิภาพมากยิ่งขึ้น นอกจากนี้ยังสามารถขยายแนวคิดไปสู่ระบบทำนายอายุการใช้งานคงเหลือของเครื่องจักรกลได้ในอนาคต

ในปัจจุบันระบบตรวจจับความผิดปกติในการทำงานของเครื่องจักรกลได้ถูกนำไปใช้กับอุปกรณ์สำคัญ (Critical Component) ที่มีผลกระทบต่อกระบวนการผลิตสูง เพื่อลดการประมวลผลที่ไม่จำเป็น และใช้ทรัพยากรได้อย่างคุ้มค่ามากที่สุด โดยพบว่าเครื่องจักรกลหมุน (Rotating Machine) เป็นเครื่องจักรกลพื้นฐานที่พบได้ทั่วไป ซึ่งความผิดปกติส่วนใหญ่ของเครื่องจักรกลหมุนเกิดจากความเสียหายที่เกิดจากแบริ่ง ดังนั้นในวิทยานิพนธ์นี้จึงเลือกใช้แบริ่งเป็นชิ้นส่วนสำคัญในการพัฒนาอัลกอริทึม



รูปที่ 1.4 อัลกอริทึมการทำนายอายุการใช้งานคงเหลือและอัลกอริทึมในการตรวจจับความผิดปกติของเครื่องจักรกล

1.3 วัตถุประสงค์การศึกษา

วัตถุประสงค์ของวิทยานิพนธ์นี้เพื่อพัฒนาอัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของแบริ่ง ซึ่งเป็นชิ้นส่วนสำคัญของเครื่องจักรกลหมุน เพื่อเป็นองค์ความรู้ที่สำคัญในการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของเครื่องจักรกลชนิดอื่นที่มีความซับซ้อนมากยิ่งขึ้น โดยครอบคลุมเนื้อหาตั้งแต่วิธีการเลือกสัญญาณในการเฝ้าติดตามตลอดจนการต่อยอดองค์ความรู้ไปสู่การพัฒนาอัลกอริทึมเพื่อทำนายอายุการใช้งานคงเหลือของเครื่องจักรกลจากอัลกอริทึมตรวจจับความผิดปกติในการทำงานของเครื่องจักรกลที่ได้พัฒนาขึ้น ดังนั้นวิทยานิพนธ์ฉบับนี้จึงมีวัตถุประสงค์

1. เพื่อเป็นองค์ความรู้ในการพัฒนาอัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของเครื่องจักรกล
2. เพื่อพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ตั้งแต่ระยะแรกเริ่มของการเกิดความผิดปกติ

1.4 ขอบเขตการวิจัย

วิทยานิพนธ์ฉบับนี้เป็นการพัฒนาอัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของแบริ่งตั้งแต่ระยะแรกเริ่มของการเกิดความผิดปกติ โดยอาศัยการวิเคราะห์ข้อมูลการสั่นสะเทือนของแบริ่งที่ได้จากการทดสอบด้วยชุดทดสอบเร่งอายุการใช้งานของแบริ่ง (PROGNOSTIA Platform) และเผยแพร่โดยสถาบัน FEMTO-ST แห่งประเทศฝรั่งเศสเท่านั้น ซึ่งชุดข้อมูลดังกล่าวมิได้ระบุถึงประเภทของความผิดปกติในการทำงานที่เกิดขึ้น ดังนั้นอัลกอริทึมที่ใช้ในการตรวจจับความผิดปกติในการทำงานของแบริ่งที่ได้พัฒนาขึ้นจึงไม่สามารถระบุสาเหตุของความผิดปกติที่เกิดขึ้นได้

1.5 รายละเอียดของวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้แบ่งเนื้อหาออกเป็น 5 บทด้วยกัน ดังนี้

บทที่ 1 เป็นการกล่าวถึงความจำเป็นมาของงานวิจัย วัตถุประสงค์การศึกษาและขอบเขตของงานวิจัย

บทที่ 2 กล่าวถึงทฤษฎี และหลักการสำคัญ ต่างๆ ที่ใช้ในการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ตั้งแต่ประเภทความผิดปกติที่เกิดขึ้นกับแบริ่ง วิธีการทดสอบแบริ่ง การสกัดคุณลักษณะสำคัญออกจากสัญญาณที่ใช้ในการวิเคราะห์ การเลือกใช้เครื่องมือในการตรวจจับความผิดปกติ วิธีการคัดกรองข้อมูลที่มีความแปรปรวนสูงออกจากข้อมูลที่ทำกรวิเคราะห์ ตลอดจนวิธีการปรับความราบเรียบของข้อมูลที่ใช้ในการวิเคราะห์

บทที่ 3 กล่าวถึงวิธีการในการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง โดยเริ่มจากแสดงให้เห็นถึงโครงสร้างของข้อมูลที่ใช้ในการวิเคราะห์ การสกัดคุณลักษณะสำคัญออกจากสัญญาณการสั่นสะเทือน กระบวนการเรียนรู้เพื่อประมาณค่าพารามิเตอร์สำคัญในระบบตรวจจับความผิดปกติ ตลอดจนการปรับปรุงอัลกอริทึมเพื่อให้ผลลัพธ์ของการตรวจจับที่เหมาะสมแก่การตีความมากยิ่งขึ้น

บทที่ 4 เป็นการทดสอบอัลกอริทึมด้วยชุดข้อมูลการสั่นสะเทือนที่ได้จากการทดสอบแบริ่ง พร้อมทั้งประเมินประสิทธิภาพในการตรวจจับความผิดปกติที่เกิดขึ้นกับแบริ่งด้วยอัลกอริทึมที่พัฒนาขึ้น

บทที่ 5 เป็นการสรุปผลงานวิจัย และข้อเสนอแนะที่สำคัญสำหรับการพัฒนางานวิจัยต่อไป

บทที่ 2

ทฤษฎีและหลักการ

2.1 บทนำ

เนื้อหาในบทนี้กล่าวถึงทฤษฎีและหลักการที่สำคัญที่ถูกนำมาใช้ในการวิจัยและพัฒนา อัลกอริทึมสำหรับตรวจจับความผิดปกติในการทำงานของแบริ่ง ในส่วนแรกกล่าวถึงประเภทของความผิดปกติที่เกิดขึ้นกับแบริ่งและวิธีการตรวจจับความผิดปกติที่เกิดขึ้น เมื่อได้แนวทางในการวิเคราะห์หาความผิดปกติของแบริ่งที่เหมาะสมแล้ว จะเป็นการบรรยายลักษณะของข้อมูลที่ถูกนำมาใช้ในการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ซึ่งได้จากการทดสอบแบริ่งด้วยชุดทดสอบเร่งอายุการทำงาน เพื่อจำลองการทำงานของแบริ่งที่ความเร็วและภาระงานในระดับต่างๆ ทำให้ข้อมูลที่ได้มีลักษณะใกล้เคียงกับข้อมูลที่ได้จากการใช้งานในความเป็นจริงมากที่สุด จากนั้นกล่าวถึงภาพรวมของอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งโดยอาศัยการวิเคราะห์สัญญาณการสั่นสะเทือนของแบริ่ง ช่วยให้เห็นถึงหลักการทำงานของอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งได้ชัดเจนยิ่งขึ้น จากนั้นเป็นวิธีการวิเคราะห์หาคุณลักษณะที่สำคัญของสัญญาณเพื่อใช้ในการตรวจจับความผิดปกติที่เกิดขึ้นกับแบริ่ง และในขั้นตอนต่อไปจะเป็นการเลือกใช้เครื่องมือในการจัดจำแนก (Classifier) เพื่อใช้ในการตรวจจับความผิดปกติของแบริ่ง ในส่วนสุดท้ายจะเป็นวิธีการในการปรับปรุงอัลกอริทึมให้มีประสิทธิภาพมากยิ่งขึ้น

2.2 ความผิดปกติที่เกิดขึ้นกับแบริ่งและวิธีการตรวจจับความผิดปกติ

แบริ่งเป็นชิ้นส่วนที่มีความสำคัญอย่างมากในเครื่องจักรกลหมุน ซึ่งมีหน้าที่ในการยึดชิ้นส่วนที่มีการหมุนของเครื่องจักรให้อยู่ในตำแหน่งที่เหมาะสม ดังแสดงในรูปที่ 2.1 จากการศึกษาพบว่าสาเหตุที่ทำให้แบริ่งชำรุดนั้นมีหลายปัจจัยด้วยกัน เช่น การใช้สารหล่อลื่นที่ไม่เหมาะสมหรือไม่เพียงพอ การติดตั้งที่ไม่เหมาะสม และการเลือกประเภทของแบริ่งไม่เหมาะสม เป็นต้น โดยตำแหน่งในการชำรุดของแบริ่งนั้นสามารถเกิดขึ้นได้ทุกชิ้นส่วนของแบริ่ง อาทิ แหวนวงนอก (Outer Race) แหวนวงใน (Inner Race) โครงแบริ่ง (Cage) หรือส่วนเคลื่อนที่ (Rolling Element) โดยวิธีการในการตรวจจับความผิดปกติที่เกิดขึ้นกับแบริ่งสามารถทำได้หลากหลายวิธีด้วยกัน เช่น การตรวจวิเคราะห์สัญญาณการสั่นสะเทือน (Vibration Analysis Approach) [8, 9] การวิเคราะห์ทางเสียง (Acoustic Analysis Approach) การวิเคราะห์อุณหภูมิ (Temperature Analysis Approach) เป็นต้น [10, 11]

การเลือกวิธีการในการตรวจจับความผิดปกติที่เกิดขึ้นกับแบริ่ง เป็นหนึ่งในขั้นตอนที่ผู้พัฒนาควรให้ความสำคัญอย่างยิ่ง เนื่องจากการเลือกวิธีการวิเคราะห์ที่เหมาะสม นอกจากจะช่วยลดเอกสารเป็นเอกสารที่ส่งงานไว้สำหรับการใช้งานเพื่อการศึกษาก็เป็นเหมือนญาติที่นำไปใช้ประโยชน์ในการคำนวณว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ระยะเวลาในการพัฒนาอัลกอริทึมลง ทำให้อัลกอริทึมในการตรวจจับความผิดปกติไม่ซับซ้อนจนเกินไปแล้ว ยังช่วยให้ระบบตรวจจับความผิดปกติที่พัฒนาขึ้นมีความแม่นยำ และครอบคลุมทุกประเภทของความผิดปกติอีกด้วย โดยพบว่า การตรวจจับความผิดปกติด้วยวิธีการวิเคราะห์การสั่นสะเทือน เป็นวิธีที่มีการใช้งานอย่างแพร่หลาย เนื่องจากการสั่นสะเทือนที่เกิดขึ้นเป็นปริมาณที่เกิดขึ้นจากการกระทบกันของพื้นผิวของชิ้นส่วนต่างๆ ในขณะที่แบริ่งเคลื่อนที่ ซึ่งสามารถตรวจจับการเปลี่ยนแปลงที่เกิดขึ้นได้อย่างรวดเร็วเมื่อเกิดความผิดปกติขึ้นที่แบริ่ง [12] ดังนั้นเมื่อแบริ่งเกิดความผิดปกติขึ้น ทำให้พื้นผิวสัมผัสในตำแหน่งที่เกิดความผิดปกตินั้นเปลี่ยนแปลงไป ส่งผลให้รูปแบบของการสั่นสะเทือนแตกต่างไปจากเดิม โดยรูปแบบการสั่นสะเทือนที่เกิดขึ้นมีองค์ประกอบความถี่ที่แตกต่างกันไป ขึ้นอยู่กับตำแหน่งที่เกิดความผิดปกติขึ้น [13–15] ดังนั้นวิศวกรจึงใช้ความแตกต่างที่เกิดขึ้นนี้เป็นเครื่องบ่งชี้ความผิดปกติแต่ละประเภทที่เกิดขึ้นกับแบริ่ง โดยพบว่าความผิดปกติทุกประเภทของแบริ่งสามารถตรวจจับได้ด้วยการวิเคราะห์สัญญาณการสั่นสะเทือน นอกจากนี้วิธีการตรวจจับความผิดปกติที่เกิดขึ้นด้วยวิธีการวิเคราะห์สัญญาณการสั่นสะเทือนยังให้ผลลัพธ์ที่แม่นยำ การติดตั้งเซนเซอร์ตรวจวัดทำได้โดยง่าย และเซนเซอร์ที่ใช้ตรวจวัดการสั่นสะเทือนยังมีราคาถูก [10]




รูปที่ 2.1 เฟลาและแบริ่ง [16]

2.3 ชุดทดสอบเร่งอายุการทำงานของแบริ่ง (PROGNOSTIA Platform)

ในการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง อาศัยข้อมูลการสั่นสะเทือนที่ได้จากการทดสอบด้วยชุดทดสอบเร่งอายุการทำงานของแบริ่ง (PROGNOSTIA Platform) ซึ่งได้ทดสอบและเผยแพร่ชุดข้อมูลโดยสถาบัน FEMTO-ST แห่งประเทศฝรั่งเศส โดยมีวัตถุประสงค์เพื่อเก็บข้อมูลการสั่นสะเทือนที่ได้จากการใช้งานจริงของแบริ่งและนำไปใช้เป็นข้อมูลในการแข่งขันพัฒนาอัลกอริทึมเพื่อประเมินอายุการใช้งานคงเหลือของแบริ่งในปี 2012 (IEEE PHM 2012 Data Challenge) [17]


PROGNOSTIA Platform ประกอบไปด้วย 3 ส่วนหลักคือ ส่วนต้นกำลัง ส่วนสร้างภาระงาน และส่วนตรวจวัด ดังแสดงในรูปที่ 2.2 ในส่วนต้นกำลังใช้ชิงโครนิสมอเตอร์ขนาด 250 วัตต์ ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เป็นต้นกำลัง โดยส่งผ่านการหมุนผ่านชุดเกียร์และเพลลาเพื่อไปขับแบร์ริง โดยผู้ทดสอบสามารถเลือกความเร็วในการหมุนสำหรับขับแบร์ริงได้ไม่เกิน 2,000 รอบต่อนาที ในส่วนสร้างภาระงานให้แก่แบร์ริงจะใช้แม่แรงลมที่สามารถปรับแรงดันลมได้ด้วยเครื่องควบคุมแรงดันลมไฟฟ้า ซึ่งเป็นการสร้างภาระงานให้แก่แบร์ริงที่แหวนวงนอกของแบร์ริง และในที่สุดท้ายเป็นส่วนตรวจวัดซึ่งประกอบไปด้วยเซนเซอร์วัดความเร็วในการหมุนของเพลลาที่ต่อกับแบร์ริง (Speed Sensor) เซนเซอร์ตรวจวัดภาระงาน (Load Sensor) เซนเซอร์ตรวจวัดอุณหภูมิที่แหวนวงนอกของแบร์ริง และเซนเซอร์วัดการสั่นสะเทือนของแบร์ริงซึ่งถูกติดตั้งที่แหวนวงนอกของแบร์ริงจำนวน 2 ตัว ในทิศทางตั้งฉากซึ่งกันและกัน (แนวตั้งและแนวระดับ) โดยในการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการของแบร์ริงนี้จะใช้เพียงข้อมูลการสั่นสะเทือนของแบร์ริงเป็นข้อมูลในการวิเคราะห์และพัฒนาอัลกอริทึมเท่านั้น



รูปที่ 2.2 PROGNOSTIA Platform [17]

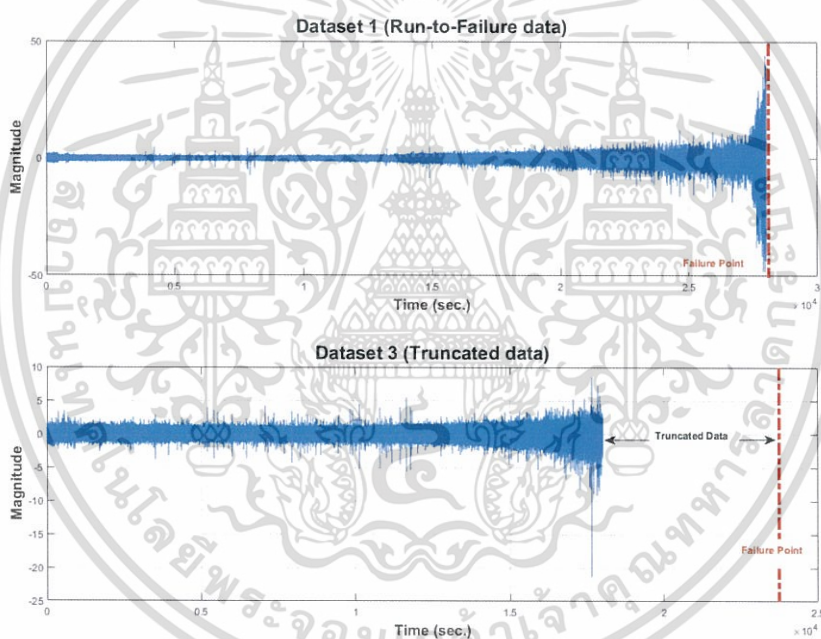
ข้อมูลการสั่นสะเทือนแบบอนาล็อกที่วัดได้จากเซนเซอร์จะถูกซิกตัวอย่างที่ความถี่ 25.6 kHz และมีคาบการบันทึกข้อมูลเท่ากับ 10 วินาที โดยในแต่ละครั้งที่บันทึกข้อมูลจะทำการบันทึกข้อมูลเป็นระยะเวลา 0.1 วินาที ดังแสดงในรูปที่ 2.3



รูปที่ 2.3 วิธีการบันทึกข้อมูลการสั่นสะเทือนของชุดข้อมูล IEEE PHM 2012 Data Challenge [17]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ชุดข้อมูลการสั่นสะเทือนของแบริ่ง IEEE PHM 2012 Data Challenge ประกอบไปด้วย 17 ชุดข้อมูลด้วยกัน ซึ่งทำการทดสอบด้วยเงื่อนไขในการทำงานคงที่ (ความเร็วในการหมุนและภาระงาน) จำนวน 3 เงื่อนไขการทำงานด้วยกัน คือ ที่ความเร็วในการหมุน 1,800 รอบต่อนาที ภาระงาน 4,000 นิวตัน จำนวน 7 ชุดข้อมูล (ชุดข้อมูลที่ 1-7), ความเร็วในการหมุน 1,650 รอบต่อนาที ภาระงาน 4,200 นิวตัน จำนวน 7 ชุดข้อมูล (ชุดข้อมูลที่ 8-14) และความเร็วในการหมุน 1,500 รอบต่อนาที ภาระงาน 5,000 นิวตัน จำนวน 3 ชุดข้อมูล (ชุดข้อมูลที่ 15-17) โดยสองชุดข้อมูลแรกในแต่ละเงื่อนไขการทำงานจะเป็นข้อมูลการสั่นสะเทือนของแบริ่งที่ถูกบันทึกตั้งแต่เริ่มทำการทดสอบ จนกระทั่งแบริ่งเกิดความเสียหายและไม่สามารถทำงานต่อไปได้อย่างปลอดภัย (Run-to-Failure Datasets) ส่วนในชุดข้อมูลอื่นๆ จะเป็นการบันทึกข้อมูลการสั่นสะเทือนตั้งแต่เริ่มทำการทดสอบ จนถึงช่วงระยะเวลาใดเวลาหนึ่งเท่านั้น (Truncated Datasets) มิได้บันทึกข้อมูลจนถึงช่วงระยะเวลาที่แบริ่งเกิดความเสียหายจนไม่สามารถทำงานต่อไปได้ดังแสดงในรูปที่ 2.4 และ ตารางที่ 2.1



รูปที่ 2.4 การบันทึกข้อมูลแบบ Run-to-Failure และแบบ Truncated

ตารางที่ 2.1 ชุดข้อมูลการสั่นสะเทือน IEEE PHM 2012 Data Challenge

ชุดข้อมูลที่	เงื่อนไขการทดสอบ	การทดสอบที่	ประเภทข้อมูล
1	1,800 rpm, 4,000 N	1	Run-to-Failure
2	1,800 rpm, 4,000 N	2	Run-to-Failure
3	1,800 rpm, 4,000 N	3	Truncated
4	1,800 rpm, 4,000 N	4	Truncated
5	1,800 rpm, 4,000 N	5	Truncated
6	1,800 rpm, 4,000 N	6	Truncated
7	1,800 rpm, 4,000 N	7	Truncated
8	1,650 rpm, 4,200 N	1	Run-to-Failure
9	1,650 rpm, 4,200 N	2	Run-to-Failure
10	1,650 rpm, 4,200 N	3	Truncated
11	1,650 rpm, 4,200 N	4	Truncated
12	1,650 rpm, 4,200 N	5	Truncated
13	1,650 rpm, 4,200 N	6	Truncated
14	1,650 rpm, 4,200 N	7	Truncated
15	1,500 rpm, 5,000 N	1	Run-to-Failure
16	1,500 rpm, 5,000 N	2	Run-to-Failure
17	1,500 rpm, 5,000 N	3	Truncated

2.4 อัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง

ระบบตรวจจับความผิดปกติในการทำงานของแบริ่งด้วยวิธีการวิเคราะห์สัญญาณการสั่นสะเทือนของแบริ่ง เป็นหนึ่งในวิธีการที่ถูกใช้ในการวิเคราะห์หาความผิดปกติของแบริ่งอย่างแพร่หลาย ซึ่งอาจทำได้โดยวิธีการวิเคราะห์หาค่าประกอบความถี่หลักที่เปลี่ยนไปจากองค์ประกอบความถี่ของการทำงานของแบริ่งในสภาวะปกติ หรืออาจใช้วิธีการสร้างอัลกอริทึมให้หน่วยประมวลผลสามารถเรียนรู้รูปแบบเอกลักษณ์ของการทำงานของแบริ่ง (Machine Learning) และใช้แบบจำลองพฤติกรรมที่ได้จากการเรียนรู้เป็นเครื่องมือในการตรวจจับความผิดปกติที่เกิดขึ้น เป็นต้น จากการศึกษาอัลกอริทึมตรวจจับความผิดปกติในการทำงานหรืออัลกอริทึมวิเคราะห์ความผิดปกติที่เกิดขึ้นกับแบริ่ง (Bearing Fault Detection และ Bearing Fault Diagnostic) [18–20] สามารถแบ่งขั้นตอนการทำงานออกเป็น 4 ขั้นตอนหลักๆ คือ การบวกรวมการประมวลผลขั้นต้น (Preprocessing) เป็นกระบวนการปรับปรุงคุณภาพของข้อมูลขั้นต้น อาจทำการลดผลของสัญญาณรบกวนที่บดบังสัญญาณที่ต้องการวิเคราะห์ด้วยการเพิ่มส่วนคัดกรองสัญญาณรบกวน (Noise Filter) รวมทั้งเป็นการ

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จัดเตรียมข้อมูลต่างๆ ให้เหมาะสมต่อการประมวลผลในลำดับถัดไป ต่อจากนั้นจะเป็นกระบวนการสกัดคุณลักษณะสำคัญออกจากสัญญาณที่เฝ้าติดตาม (Feature Extraction) เพื่อใช้เป็นข้อมูลในการวิเคราะห์ ในบางงานวิจัยอาจมีการลดมิติของคุณลักษณะสำคัญก่อนนำไปใช้เป็นข้อมูลในการสร้างแบบจำลองเพื่อจัดจำแนกข้อมูล ซึ่งสามารถลดกระบวนการประมวลผลที่ไม่จำเป็นลงได้ จากนั้นจะเป็นในส่วนของการตรวจจับความผิดปกติที่เกิดขึ้น (Fault Detection) หรือเป็นขั้นตอนในการคัดแยกประเภทของความผิดปกติที่เกิดขึ้น (Fault Diagnosis) โดยในส่วนนี้อาจเลือกใช้แบบจำลองทางคณิตศาสตร์ในการจัดจำแนกความผิดปกติ หรืออาจใช้ระบบรู้จำรูปแบบของข้อมูล (Pattern Recognition) เป็นเครื่องมือในการจัดจำแนก ซึ่งกระบวนการทั้งหมดสามารถแสดงเป็นแผนภาพได้ดังรูปที่ 2.5



รูปที่ 2.5 ระบบตรวจจับความผิดปกติ และระบบวิเคราะห์ความผิดปกติในการทำงานของแบริ่ง

2.5 การสกัดคุณลักษณะสำคัญ (Feature Extraction)

สัญญาณการสั่นสะเทือนที่ใช้ในการวิเคราะห์ และพัฒนาอัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของแบริ่ง สามารถแบ่งออกได้เป็น 2 กลุ่มข้อมูลด้วยกันคือ สัญญาณการสั่นสะเทือนของแบริ่งที่ตรวจวัดได้ขณะที่แบริ่งทำงานในสภาวะปกติ (Normal Mode) และสัญญาณการสั่นสะเทือนของแบริ่งที่ตรวจวัดได้เมื่อแบริ่งเกิดความผิดปกติขึ้น (Defect Mode) โดยในการจัดจำแนกสัญญาณในแต่ละกลุ่มจะอาศัยค่าคุณลักษณะสำคัญต่างๆ ที่เป็นปริมาณบ่งชี้เอกลักษณ์ของสัญญาณการสั่นสะเทือน ซึ่งมีปริมาณที่แตกต่างกันไปในการทำงานแต่ละสภาวะ ในการสกัดคุณลักษณะสำคัญของสัญญาณสำหรับการพัฒนาระบบตรวจจับความผิดปกติในการทำงานของแบริ่งสามารถทำได้หลายวิธีด้วยกัน [21, 22] จำแนกได้เป็น 3 กลุ่มหลักๆ ดังนี้

2.5.1 คุณลักษณะบนโดเมนเวลา (Time Domain Features)

โดยทั่วไปแล้วสัญญาณเฝ้าติดตาม (Monitoring Data) ที่ได้จากเซนเซอร์จะเป็นสัญญาณขึ้นอยู่กัเวลา (Time Domain Signal) ซึ่งการสกัดคุณลักษณะออกจากสัญญาณที่เฝ้าติดตามบนโดเมนเวลาเป็นการสกัดคุณลักษณะประเภทแรกๆ ที่ถูกเลือกใช้เพื่อสังเกตพฤติกรรมของสัญญาณที่ทำการวิเคราะห์ เนื่องจากการสกัดคุณลักษณะสำคัญบนโดเมนเวลามีวิธีการที่ไม่ซับซ้อนและง่ายแก่การตีความหมาย เช่น RMS Value, Kurtosis, Crest Factor และ Probability Density เป็นต้น จากคุณลักษณะทั้งหมดนี้ Kurtosis เป็นคุณลักษณะมีประสิทธิภาพมากที่สุดในการตรวจจับความผิดปกติในการทำงานของแบริ่ง [10] นอกจากค่า Kurtosis แล้วค่า Crest Factor ยังเป็นอีกหนึ่งคุณลักษณะสำคัญที่ใช้ในการตรวจจับการเปลี่ยนแปลงชั่วขณะที่เกิดขึ้นกับสัญญาณได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5.1.1 ค่าตัวประกอบยอดคลื่น (Crest Factor)

ค่า Crest Factor เป็นอัตราส่วนระหว่างค่าสูงสุดของสัญญาณต่อค่าเฉลี่ยกำลังสองของสัญญาณดังสมการที่ 2.1 ค่า Crest Factor เป็นตัวบ่งบอกถึงความรุนแรงของสัญญาณชั่วขณะที่เกิดขึ้นในแต่ละช่วงเวลาทำการวิเคราะห์ ซึ่งสามารถใช้เป็นคุณลักษณะสำคัญอย่างหนึ่งในการตรวจจับความผิดปกติที่เกิดขึ้นกับแบริ่งได้

$$C = \frac{|\text{Peak}|}{\text{RMS}} \quad (2.1)$$

2.5.1.2 ความโด่งของการกระจายตัวความน่าจะเป็นของข้อมูล (Kurtosis)

ในการวิเคราะห์ข้อมูลจากเส้นโค้งการแจกแจงความน่าจะเป็นของข้อมูล (Distribution Curve) ช่วยให้ทราบถึงรูปแบบการกระจายตัวของข้อมูลได้ชัดเจนยิ่งขึ้น ซึ่งนิยมใช้ค่าสัมประสิทธิ์ต่างๆ เป็นปริมาณในการอธิบายลักษณะของการกระจายตัวของข้อมูล เช่น สัมประสิทธิ์ความโด่ง (Kurtosis) และสัมประสิทธิ์ความเบ้ (Skewness) ทำให้สามารถคัดแยกข้อมูลในแต่ละประเภทได้โดยการวิเคราะห์รูปแบบการกระจายตัวของข้อมูล ดังเช่น ในสภาวะการทำงานปกติของแบริ่งจะมีรูปแบบการกระจายตัวของสัญญาณการสั่นสะเทือนรูปแบบหนึ่ง ซึ่งใช้รูปแบบการกระจายตัวดังกล่าวเป็นรูปแบบอ้างอิงของชุดข้อมูลการสั่นสะเทือนที่ทำงานในสภาวะปกติ และเมื่อใดก็ตามที่การทำงานของแบริ่งเกิดความผิดปกติขึ้น รูปแบบการกระจายตัวของข้อมูลการสั่นสะเทือนก็ย่อมที่จะมีรูปแบบที่แตกต่างไปจากรูปแบบอ้างอิงที่ได้ทำการตรวจวัดไว้ก่อนหน้านี้ โดยค่าสัมประสิทธิ์ความโด่งสามารถคำนวณได้จากสมการที่ 2.2

$$K = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^2} \quad (2.2)$$

2.5.2 คุณลักษณะบนโดเมนความถี่ (Frequency Domain Features)

การวิเคราะห์สัญญาณบนโดเมนความถี่ เป็นการสกัดองค์ประกอบสำคัญของสัญญาณเพื่อนำมาเปรียบเทียบกับช่วงความถี่ต่างๆ ซึ่งมีประโยชน์อย่างมากในการวิเคราะห์สัญญาณที่มีการเกิดแบบซ้ำคาบ เช่น สัญญาณการสั่นสะเทือนของแบริ่ง เมื่อใดก็ตามที่ชิ้นส่วนต่างๆ ของแบริ่งเคลื่อนที่ผ่านจุดที่เกิดความผิดปกติขึ้น จะทำให้เกิดการสั่นสะเทือนอันเนื่องมาจากความไม่สมบูรณ์ของพื้นผิวสัมผัส ซึ่งมีองค์ประกอบความถี่ของการสั่นสะเทือนที่แตกต่างกันไป ตามประเภทของความผิดปกติที่เกิดขึ้น ทำให้วิศวกรสามารถระบุประเภทของความผิดปกติที่เกิดขึ้นได้ตามรูปแบบองค์ประกอบความถี่ที่เปลี่ยนไป โดยการสกัดคุณลักษณะบนโดเมนความถี่ที่นิยมใช้กันในปัจจุบันจะอาศัยการแปลงฟูเรียร์เป็นหลัก เนื่องจากเป็นการแปลงที่ง่าย ไม่ซับซ้อน และให้รายละเอียดบนโดเมนความถี่ที่ดี โดยการแปลงฟูเรียร์ในแต่ละประเภทมีคุณสมบัติและวิธีการแปลงที่แตกต่างกันไปดังต่อไปนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

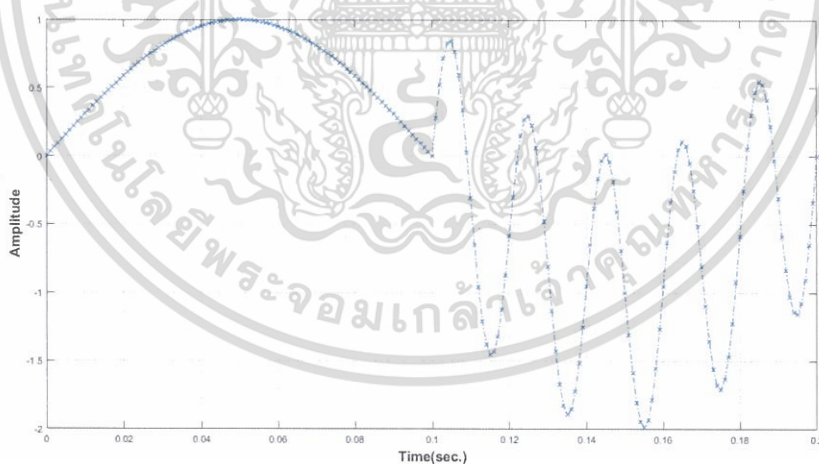
2.5.2.1 การแปลงฟูเรียร์ไม่ต่อเนื่อง (Discrete Fourier Transform)

เนื่องจากข้อมูลเฝ้าติดตามที่ได้เป็นข้อมูลแบบจุดไม่ต่อเนื่อง (Sampling Data) ดังนั้นในการสกัดองค์ประกอบความถี่ออกจากสัญญาณต้นฉบับจะเลือกใช้การแปลงฟูเรียร์แบบไม่ต่อเนื่อง ซึ่งมีแนวคิดที่ว่าสัญญาณไม่เป็นรายคาบใดๆ สามารถประมาณได้ด้วยผลรวมของฟังก์ชันไซน์และโคไซน์ที่องค์ประกอบความถี่ต่างๆ โดยสัมประสิทธิ์แต่ละองค์ประกอบความถี่สามารถคำนวณได้จากสมการที่ 2.3

$$X(\omega) = \sum_{n=0}^{N-1} x(n)(\cos(\omega n) - j\sin(\omega n)) \quad (2.3)$$

โดยที่	$X(\omega)$	คือ สัมประสิทธิ์องค์ประกอบความถี่
	$x(n)$	คือ สัญญาณต้นฉบับบนโดเมนเวลาที่มีการชักตัวอย่างครั้งที่ n
	N	คือ จำนวนจุดข้อมูลทั้งหมดที่ใช้ในการแปลง


ในรูปที่ 2.6 เป็นสัญญาณสังเคราะห์ที่มีองค์ประกอบความถี่ 2 ความถี่ โดยในช่วง 0.1 วินาทีแรก จะมีเพียงองค์ประกอบความถี่เดียวเท่านั้นที่ 5 Hz และหลังจากวินาทีที่ 0.1 เป็นต้นไป องค์ประกอบความถี่ที่ 2 ที่ความถี่ 50 Hz ก็กำเนิดขึ้น



รูปที่ 2.6 สัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$ บนโดเมนเวลา

รูปที่ 2.7 เป็นการสกัดองค์ประกอบความถี่ของสัญญาณต้นฉบับ (สัญญาณเดียวกันกับในรูปที่ 2.6) โดยอาศัยการแปลงฟูเรียร์แบบไม่ต่อเนื่อง จะเห็นได้ว่าการแปลงฟูเรียร์ช่วยให้สามารถสังเกตองค์ประกอบความถี่ของสัญญาณที่ต้องการวิเคราะห์ได้อย่างครบถ้วนที่ 5 Hz และ 50 Hz

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.7 องค์ประกอบความถี่ของสัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$

ถึงแม้ว่าการแปลงฟูเรียร์จะให้รายละเอียดทางความถี่ที่ดี ซึ่งเป็นข้อมูลสำคัญที่ใช้ในการจัดจำแนกข้อมูลการสั่นสะเทือนของเครื่องจักรในสภาวะการทำงานปกติและสภาวะที่เกิดความผิดปกติขึ้น แต่การแปลงฟูเรียร์ยังขาดรายละเอียดบนโดเมนเวลา ซึ่งเป็นข้อมูลสำคัญที่ใช้ในการระบุช่วงเวลาที่เกิดความผิดปกติขึ้น ดังจะเห็นจากตัวอย่างข้างต้นของการแปลงฟูเรียร์แบบไม่ต่อเนื่องทางเวลาไม่สามารถที่จะระบุช่วงเวลาที่เกิดองค์ประกอบความถี่ที่ 2 (50Hz) ขึ้นในสัญญาณได้ ดังนั้นการแปลงฟูเรียร์จึงไม่เหมาะสมที่จะนำไปใช้เป็นตัววิเคราะห์สัญญาณที่ผันแปรตามเวลา (Time-Varying Signal)

2.5.3 คุณลักษณะบนโดเมนเวลา-ความถี่ (Time-Frequency Domain Features)

คุณลักษณะบนโดเมนเวลา-ความถี่ เป็นคุณลักษณะที่ถูกใช้งานอย่างแพร่หลายในการวิเคราะห์สัญญาณการสั่นสะเทือนเพื่อระบุความผิดปกติของเครื่องจักรกล เนื่องจากคุณลักษณะประเภทนี้ให้รายละเอียดของสัญญาณได้อย่างครบถ้วนทั้งด้านเวลา และความถี่ การสกัดคุณลักษณะบนโดเมนเวลา-ความถี่ สามารถทำได้หลายวิธีด้วยกันต่อไปนี้

2.5.3.1 การแปลงฟูเรียร์ช่วงสั้น (Short-Time Fourier Transform)

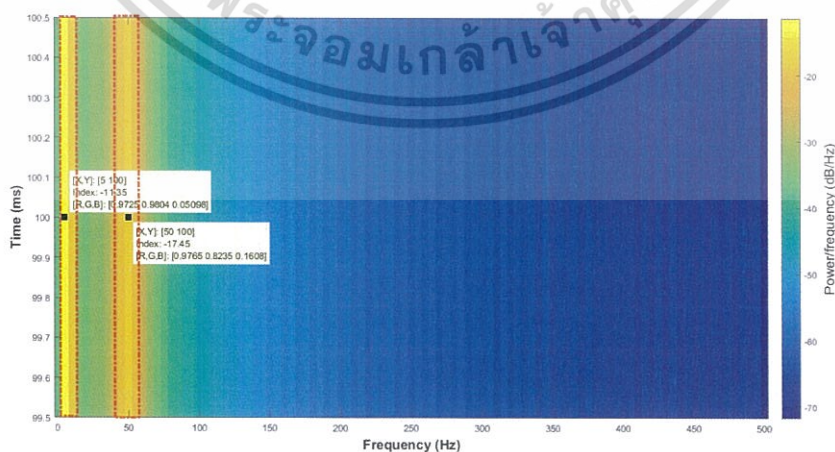
เนื่องจากการแปลงฟูเรียร์เป็นการสกัดคุณลักษณะทางความถี่ของสัญญาณที่ต้องการวิเคราะห์ในคราวเดียวตลอดช่วงเวลาของสัญญาณที่ทำการวิเคราะห์ ซึ่งไม่สามารถสังเกตการเปลี่ยนแปลงรายละเอียดความถี่ของสัญญาณที่เกิดขึ้นได้ ดังนั้นวิธีการที่ง่ายที่สุดที่ทำให้เห็นการเปลี่ยนแปลงดังกล่าว คือการแบ่งสัญญาณที่ต้องการวิเคราะห์ออกเป็นช่วงย่อยๆ จากนั้นจึงทำการแปลงฟูเรียร์ในทุกๆ ช่วงย่อย ซึ่งช่วยให้ผู้วิเคราะห์สามารถสังเกตการเปลี่ยนแปลงองค์ประกอบของความถี่จากช่วงเวลาหนึ่งไปยังอีกช่วงเวลาหนึ่งที่เกิดการเปลี่ยนแปลงขึ้นได้ ซึ่งเป็นแนวคิดของการแปลงฟูเรียร์ช่วงสั้น โดยสามารถเขียนให้อยู่ในรูปของสมการได้ดังสมการที่ 2.4

$$X(n, \omega) = \sum_{m=-\infty}^{\infty} x[m]w[n-m](\cos(\omega n) - j\sin(\omega n)) \quad (2.4)$$

โดยที่	$X(n, \omega)$	คือ สัมประสิทธิ์องค์ประกอบความถี่ ω ที่เวลา n
	$x[m]$	คือ สัญญาณต้นฉบับที่ต้องการวิเคราะห์
	$w[n-m]$	คือ ฟังก์ชันหน้าต่าง (Windows Function)


ดังจะเห็นว่าในสมการที่ 2.4 มีลักษณะการแปลงคล้ายคลึงกันมากกับการแปลงฟูเรียร์ไม่ต่อเนื่องในสมการที่ 2.3 เพียงแต่มีการเพิ่มในส่วนของฟังก์ชันหน้าต่างเข้ามาเพื่อทำหน้าที่แบ่งสัญญาณต้นฉบับออกเป็นส่วนย่อยๆ เท่านั้น ซึ่งเป็นการปรับปรุงการแปลงฟูเรียร์ไม่ต่อเนื่องให้สามารถให้รายละเอียดในเชิงเวลาได้ โดยในรูปที่ 2.8 – 2.1 เป็นผลการแปลงฟูเรียร์ช่วงสั้นของสัญญาณ $x(n) = \sin(10n\pi) + u(n-0.1)\sin(100n\pi)$ ซึ่งเป็นสัญญาณเดียวกันกับในตัวอย่างของการแปลงฟูเรียร์ไม่ต่อเนื่องทางเวลา จะเห็นได้ว่าการแปลงฟูเรียร์ช่วงสั้นสามารถใช้ในการสกัดคุณลักษณะบนโดเมนเวลา และโดเมนความถี่ออกจากสัญญาณต้นฉบับที่ทำการวิเคราะห์ได้

ในการแปลงฟูเรียร์ช่วงสั้นนั้น จำเป็นอย่างยิ่งที่จะต้องเลือกขนาดของหน้าต่างให้เหมาะสมกับสัญญาณที่นำมาวิเคราะห์ ซึ่งขนาดหน้าต่างในการแปลงมีผลโดยตรงกับความละเอียดของข้อมูลเชิงเวลาและความถี่ที่สกัดได้ ดังเช่นในรูปที่ 2.8 มีขนาดหน้าต่างในการแปลงฟูเรียร์ช่วงสั้นเท่ากับ 200 จุดข้อมูล ซึ่งมีขนาดเท่ากับช่วงเวลาทั้งหมดของสัญญาณต้นฉบับ ทำให้ผลลัพธ์ที่ได้จากการแปลงนี้ไม่สามารถสังเกตการเปลี่ยนแปลงองค์ประกอบความถี่ที่ 2 (100 Hz) ที่วินาทีที่ 0.1 ได้ แต่จะเห็นว่าการแปลงนี้ให้ความละเอียดเชิงความถี่ที่แม่นยำ เมื่อเทียบกับผลลัพธ์ที่ได้จากการแปลงฟูเรียร์ช่วงสั้นที่เลือกใช้ขนาดหน้าต่างในการแปลงเท่ากับ 50 จุดข้อมูล ดังรูปที่ 2.10 แต่ทว่าในรูปที่ 2.10 นั้นสามารถให้รายละเอียดในเชิงเวลาได้เป็นอย่างดี ซึ่งสามารถตีความได้ว่าองค์ประกอบความถี่ที่ 2 (100 Hz) เกิดขึ้นในสัญญาณประมาณช่วงเวลา 0.09 วินาทีเป็นต้นไป




รูปที่ 2.8 ผลการแปลง STFT ของสัญญาณ $x(n) = \sin(10n\pi) + u(n-0.1)\sin(100n\pi)$ โดยใช้หน้าต่างขนาด 200 จุดข้อมูล และมีส่วนซ้อนทับ 198 จุดข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.9 ผลการแปลง STFT ของสัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$ โดยใช้หน้าต่างขนาด 100 จุดข้อมูล และมีส่วนซ้อนทับ 96 จุดข้อมูล



รูปที่ 2.10 ผลการแปลง STFT ของสัญญาณ $x(n) = \sin(10n\pi) + u(n - 0.1)\sin(100n\pi)$ โดยใช้หน้าต่างขนาด 50 จุดข้อมูล และมีส่วนซ้อนทับ 48 จุดข้อมูล

2.5.3.2 การแปลงเวฟเล็ต (Wavelet Transform)

การแปลงเวฟเล็ตเป็นการสกัดคุณลักษณะของสัญญาณบนโดเมนเวลา-ความถี่ ที่ถูกใช้งานอย่างแพร่หลาย เนื่องจากการแปลง Wavelet สามารถปรับเปลี่ยนระดับความละเอียดในการแปลงได้ นอกจากนี้ยังสามารถเปลี่ยนเบสิสในการแปลง (Wavelet Basis) ได้หลากหลาย มิได้จำกัดเพียงสัญญาณ Sinusoid เพียงอย่างเดียวดังเช่นการแปลงฟูรีเยร์ ทำให้การแปลงเวฟเล็ตมีความยืดหยุ่นสูง และให้ผลลัพธ์การแปลงที่ดีโดยเฉพาะกับสัญญาณที่แปรตามเวลา

ในการสกัดคุณลักษณะโดยการแปลงเวฟเล็ตแบบไม่ต่อเนื่องทางเวลา (Discrete Wavelet Transform) ถูกนิยามโดยสมการที่ 2.5 จะเห็นว่ามึรูปแบบฟังก์ชันการแปลงคล้ายคลึงกันกับการแปลงฟูรีเยร์ช่วงสั้นดังที่กล่าวไปข้างต้น โดยที่ตัวแปร $\psi'_{m,n}(t)$ ในสมการที่ 2.5 คือเบสิสฟังก์ชันของการแปลง (Sinusoid function ในกรณีของการแปลงฟูรีเยร์ช่วงสั้น) นอกจากนี้เบสิสฟังก์ชันของการแปลงเวฟเล็ตยังสามารถบีบอัด/ขยายตัว (Scaling) และสามารถเลื่อนเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

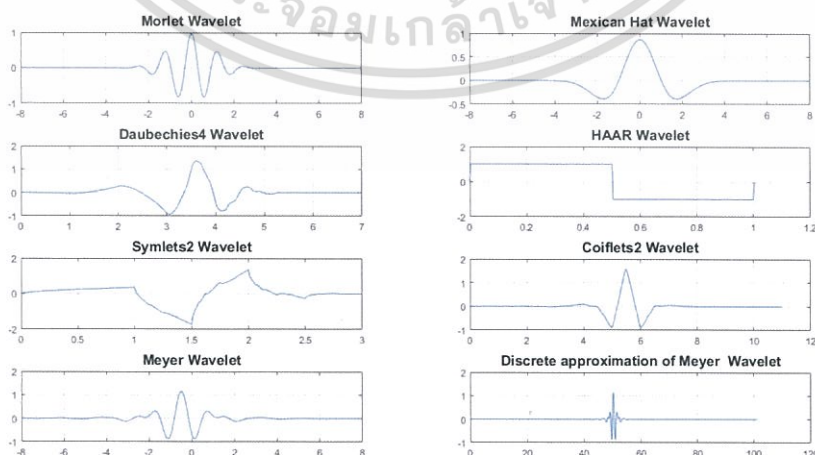
ตำแหน่ง (Translation) ได้ ทำให้การแปลงเวฟเล็ตมีความยืดหยุ่นสูงกว่าการแปลงฟูเรียร์ช่วงสั้นอย่างมาก

$$S(m, n) = \int_{-\infty}^{\infty} \psi'_{m,n}(t)x(t)dt \quad (2.5)$$

โดยที่	$S(m, n)$	คือ สัมประสิทธิ์การแปลงเวฟเล็ต
	$\psi'_{m,n}(t)$	คือ เวฟเล็ตฟังก์ชัน
	$x(t)$	คือ สัญญาณต้นฉบับที่ต้องการวิเคราะห์

ในการสกัดคุณลักษณะของสัญญาณด้วยการแปลงเวฟเล็ตจำเป็นต้องเลือกเวฟเล็ตเบสิส ให้เหมาะสมกับสัญญาณที่ต้องการวิเคราะห์ เพราะการสกัดคุณลักษณะสำคัญออกจากสัญญาณต้นฉบับด้วยการแปลงเวฟเล็ตโดยใช้เวฟเล็ตเบสิสที่แตกต่างกัน ย่อมให้ผลลัพธ์ที่ต่างกันได้ และในกรณีที่เลือกเวฟเล็ตเบสิสที่ไม่มีความสัมพันธ์กับสัญญาณที่วิเคราะห์ จะทำให้การแปลงเวฟเล็ตนี้ให้คุณสมบัติที่ได้สื่อความหมายใดๆ หรือไม่สามารถใช้เป็นตัวแทนเพื่อระบุเอกลักษณ์ของสัญญาณที่วิเคราะห์ได้ โดยฟังก์ชันเวฟเล็ตที่นิยมใช้ในปัจจุบันได้แสดงดังรูปที่ 2.11

สำหรับวิธีการในการเลือกเวฟเล็ตเบสิสให้เหมาะสมสำหรับการแปลงเวฟเล็ต ในปัจจุบันสามารถทำได้หลากหลายวิธี และยังไม่มียุทธวิธีใดที่ได้รับการยืนยันให้ใช้เป็นวิธีมาตรฐาน [23] ดังเช่น Kumar, H.S. และคณะวิจัยได้ทำการนำเสนอวิธีการในการเลือกใช้เบสิสการแปลงเวฟเล็ตสำหรับสัญญาณการสั่นสะเทือนของแบริ่ง โดยนำเสนอเกณฑ์การเลือก 2 หลักเกณฑ์ด้วยกัน คือ Maximum Energy to Shannon Entropy Ratio (MESER) และ Minimum Shannon Entropy Criteria [24] โดยในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้เบสิสในการแปลงเวฟเล็ตโดยใช้ค่า Maximum Energy to Shannon Entropy Ratio (MESER) เป็นเกณฑ์ ซึ่งถูกนิยามดังสมการที่ 2.6



รูปที่ 2.11 Wavelet Function

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$MESER = \frac{E_{energy}}{E_{entropy}} \tag{2.6}$$

$$E_{energy} = \iint |wt(s, \tau)|^2 dsd\tau \tag{2.7}$$

โดยที่ E_{energy} คือ ค่าพลังงานรวมทั้งหมดที่สะสมอยู่ในสัญญาณ
 $wt(s, \tau)$ คือ ค่าสัมประสิทธิ์การแปลงเวฟเล็ตในโหนด τ


$$E_{entropy} = - \sum_{i=1}^N p_i \cdot \log_2 p_i \tag{2.8}$$

$$p_i = \frac{|wt(i)|^2}{E_{energy}} \tag{2.9}$$

โดยที่ $E_{entropy}$ คือ ค่าเอนโทรปีรวมของสัญญาณ
 p_i คือ ค่าการกระจายตัวความน่าจะเป็นของพลังงานที่โหนด i
 N คือ จำนวนโหนดทั้งหมด

2.5.3.3 การแยกส่วนประกอบเวฟเล็ตแพกเก็ต (Wavelet Packet Decomposition)

การแยกส่วนประกอบเวฟเล็ตแพกเก็ตเป็นการแปลงเวฟเล็ตเพื่อสกัดสัมประสิทธิ์เวฟเล็ตออกจากสัญญาณที่วิเคราะห์เช่นเดียวกับการแยกส่วนประกอบเวฟเล็ต (Wavelet Decomposition) เพียงแต่การแยกส่วนประกอบเวฟเล็ตแพกเก็ตเป็นการแปลงเวฟเล็ตแบบสองฝั่งทั้งในด้านความถี่ต่ำและด้านความถี่สูง ทำให้สามารถเก็บรายละเอียดความถี่ได้ครอบคลุมยิ่งขึ้น โดยโครงสร้างการแยกส่วนประกอบเวฟเล็ตแพกเก็ตได้แสดงในรูปที่ 2.12 และความถี่ในแต่ละโหนดของเวฟเล็ตแพกเก็ตสามารถคำนวณหาได้จากสมการที่ 2.10



รูปที่ 2.12 Wavelet Packet Decomposition Tree [25]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\text{level} = \log_2 \left(\frac{F_s}{\text{DiffDomFreq}_{\min}} \right) - 1 \quad (2.10)$$

โดยที่	level	คือ ระดับความละเอียดในการแปลงเวฟเล็ตแพกเกต
	F_s	คือ ความถี่ในการซีกตัวอย่าง (Hz)
	$\text{DiffDomFreq}_{\min}$	คือ ผลต่างความถี่โดเด่นที่น้อยที่สุด (Hz)

2.5.3.4 พลังงานของโหนดส่วนประกอบเวฟเล็ตแพกเกต (Wavelet Packet Decomposition Node Energy)

พลังงานของสัญญาณที่วิเคราะห์ที่กระจายอยู่ในแต่ละโหนดของการแยกส่วนประกอบเวฟเล็ตแพกเกต สามารถคำนวณได้จากสมการที่ 2.11

$$E_{\text{energy}}(i) = |\text{wt}(i)|^2 \quad (2.11)$$

โดยที่	$E_{\text{energy}}(i)$	คือ ค่าพลังงานที่สะสมในโหนดที่ i
	$\text{wt}(i)$	คือ ค่าสัมประสิทธิ์การแปลงเวฟเล็ตในโหนด i

2.6 เครื่องมือคัดกรองความผิดปกติ (Classifier)

วิธีการคัดกรองความผิดปกติของเครื่องจักรกลจากข้อมูลคุณลักษณะสำคัญของเครื่องจักรกลสามารถทำได้หลากหลายวิธีด้วยกัน เช่น ใช้โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) [18–20], แบบจำลองมาร์คอฟซ่อนเร้น (Hidden Markov Models, HMM), ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) [18] และการวิเคราะห์การถดถอยโลจิสติก (Logistic Regression) เป็นต้น สำหรับวิธีการในการตรวจจับความผิดปกติด้วยโครงข่ายประสาทเทียมจำเป็นต้องกำหนดจำนวนเลเยอร์ จำนวนนิวรอน รวมทั้งฟังก์ชันถ่ายโอนให้เหมาะสม ซึ่งอาจใช้วิธีการทดสอบโดยการแปรค่าพารามิเตอร์ต่างๆ ในช่วงที่กำหนด เพื่อหาค่าที่เหมาะสมที่สุด โดยที่ให้ค่าความแม่นยำในการทำนายในช่วงที่สามารถยอมรับได้ และโครงข่ายที่ได้จะต้องไม่มีความซับซ้อนจนเกินไป ซึ่งใช้เวลาอย่างมากในการทดสอบเพื่อหาค่าพารามิเตอร์ที่เหมาะสมทั้งหมด โดยเฉพาะกับการเรียนรู้กับชุดข้อมูลที่มีขนาดใหญ่ นอกจากนี้วิธีการคัดกรองความผิดปกติด้วยแบบจำลองมาร์คอฟซ่อนเร้นก็เป็นอีกวิธีหนึ่งที่ถูกนำไปใช้ แต่ทว่าการคัดกรองความผิดปกติด้วยวิธีการแบบจำลองมาร์คอฟซ่อนเร้นต้องการการประมวลผลที่สูง ทำให้การตรวจจับความผิดปกติด้วยวิธีดังกล่าวไม่เหมาะสมที่จะนำไปใช้ในการทำงานกับข้อมูลที่ประมวลผลตามเวลาจริง (Real Time Processing) ซึ่งความเร็วในการประมวลผลเป็นปัจจัยหนึ่งที่สำคัญยิ่งที่จะทำให้ระบบสามารถประมวลผลได้อย่างทันที่

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นอกจากนี้ซัพพอร์ตเวกเตอร์แมชชีนและการวิเคราะห์การถดถอยโลจิสติกเป็นเครื่องมือที่มักถูกใช้ในการวิเคราะห์และตรวจจับความผิดปกติที่เกิดขึ้นกับเครื่องจักรกล ดังเช่นในงานวิจัยของ Habib M.R. และคณะ ได้ทำการทดสอบอัลกอริทึมในการจัดจำแนก 6 อัลกอริทึม ประกอบไปด้วย Naïve Bayes, Linear Discriminant, Quadratic Discriminant, Support Vector Machine, Logistic Regression และ Neural Network เพื่อใช้สำหรับจำแนกประเภทการทำงานที่ผิดปกติของเพลทขับเคลื่อนโรเตอร์หางของเฮลิคอปเตอร์ AH-64D โดยพบว่าการจัดจำแนกด้วยการวิเคราะห์การถดถอยโลจิสติกส์ให้ผลลัพธ์ที่ดีที่สุด [26] ดังนั้นในวิทยานิพนธ์ฉบับนี้จึงเลือกใช้วิธีการวิเคราะห์การถดถอยโลจิสติกในการตรวจจับการทำงานที่ผิดปกติของแบร์ริง

การถดถอยโลจิสติกแบบทวินาม (Binomial Logistic Regression) เป็นเครื่องมือที่ใช้ในการแบ่งกลุ่มของข้อมูลที่มีจำนวนกลุ่มไม่เกิน 2 กลุ่มข้อมูล โดยการประมาณความสัมพันธ์ระหว่างตัวแปรต้น (Predict Variables) ซึ่งอาจมีมากกว่า 1 ตัวแปร กับตัวแปรตอบสนอง (Response Variables) ซึ่งอยู่ในรูปของความน่าจะเป็นที่ตัวแปรต้นชุดดังกล่าวจะอยู่ในกลุ่มข้อมูลที่สนใจ ซึ่งถูกประมาณด้วย Sigmoid Function ดังสมการที่ 2.12 เช่น ในการหาโอกาสที่แบร์ริงจะเกิดความผิดปกติขึ้น โดยอาศัยค่าคุณลักษณะสำคัญ (Fea) ที่สกัดได้จากสัญญาณการสั่นสะเทือนทั้งหมด n คุณลักษณะ จำนวน 100 ตัวอย่าง ($i = 100$) และกำหนดให้ $y_i = 1$ แทนกลุ่มตัวอย่างที่แบร์ริงทำงานปกติ และ $y_i = 2$ แทนกลุ่มตัวอย่างที่แบร์ริงทำงานผิดปกติ สามารถเขียนในรูปของสมการเพื่อแทนความสัมพันธ์ข้างต้นได้ดังสมการที่ 2.13 – 2.15

$$P(Y = y_i | x_i) = \frac{e^{x_i}}{1 + e^{x_i}} \quad (2.12)$$

โดยที่ i คือ ลำดับชุดข้อมูล มีค่าอยู่ในช่วง $i \in [1, \infty)$
 y_i คือ กลุ่มข้อมูล ณ ชุดข้อมูลที่ i (มีเพียง 2 กลุ่มข้อมูล
 ในกรณีของ Binomial Logistic Regression)
 x_i คือ ตัวแปรต้น ณ ชุดข้อมูลที่ i

$$P(Y = 1 | Fea) = \frac{e^{b_0 + b_1 Fea_1 + \dots + b_n Fea_n}}{1 + e^{b_0 + b_1 Fea_1 + \dots + b_n Fea_n}} \quad (2.13)$$

$$P(Y = 2 | Fea) = 1 - \frac{e^{b_0 + b_1 Fea_1 + \dots + b_n Fea_n}}{1 + e^{b_0 + b_1 Fea_1 + \dots + b_n Fea_n}} \quad (2.14)$$

$$P(Y = 2 | Fea) = \frac{1}{1 + e^{b_0 + b_1 Fea_1 + \dots + b_n Fea_n}} \quad (2.15)$$

จากสมการที่ 2.13 และ 2.15 ทำให้สามารถหาค่าโอกาสที่แบร์ริงทำงานในสภาวะปกติ และโอกาสที่แบร์ริงทำงานในสภาวะผิดปกติได้ การหาค่าพารามิเตอร์ของแบบจำลองการถดถอยโลจิสติก

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้เผยแพร่โดยไม่ได้รับอนุญาต
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(b_0, b_1, \dots, b_n) จะใช้วิธีการหาค่า Maximum Log-likelihood ของฟังก์ชันแอดัมต่อ (Odds Function) ในการประมาณค่าพารามิเตอร์ของแบบจำลอง ซึ่งฟังก์ชันแอดัมต่อสามารถเขียนได้ดังสมการที่ 2.16 โดยการจัดรูปสมการใหม่ ได้ดังสมการที่ 2.18

$$\text{Odds} = \frac{P(Y = 1|Fea)}{P(Y = 0|Fea)} \quad (2.16)$$

$$\text{Odds} = \frac{e^{b_0+b_1Fea_1+\dots+b_nFea_n}}{1 + e^{b_0+b_1Fea_1+\dots+b_nFea_n}} \times \frac{1 + e^{b_0+b_1Fea_1+\dots+b_nFea_n}}{1} \quad (2.17)$$

$$\text{Odds} = e^{b_0+b_1Fea_1+\dots+b_nFea_n} \quad (2.18)$$

จากสมการที่ 2.18 สามารถเขียนให้อยู่ในรูปแบบของฟังก์ชันลอการิทึมธรรมชาติได้ดังสมการที่ 2.19 ซึ่งช่วยให้หาค่าพารามิเตอร์ของแบบจำลองได้สะดวกยิ่งขึ้น ต่อจากนั้นจึงประมาณค่าพารามิเตอร์ของแบบจำลองจากสมการที่ 2.19 ด้วยวิธีการ Maximum Likelihood Estimation

$$\ln(\text{Odds}) = b_0 + b_1Fea_1 + \dots + b_nFea_n \quad (2.19)$$

2.7 ช่วงความเชื่อมั่น (Confidence Intervals)

ในการวิเคราะห์ข้อมูลที่มีการกระจายตัวสูง อาจใช้ช่วงความเชื่อมั่นเป็นปริมาณที่บ่งบอกถึงขอบเขตการกระจายตัวของข้อมูลที่ยอมรับได้ เพื่อคัดกรองข้อมูลที่มีการกระจายตัวรอบๆ ค่าเฉลี่ยภายในช่วงที่กำหนด ซึ่งถูกกำหนดโดยค่าพารามิเตอร์ความเชื่อมั่น (α) ที่มีค่าตั้งแต่ 0 ถึง 1 เช่น สามารถยอมรับข้อมูลที่มีการกระจายตัวรอบๆ ค่าเฉลี่ยได้ไม่เกิน 95% ($\alpha = 0.01(100 - 95)$) ทำให้การวิเคราะห์ข้อมูลมีประสิทธิภาพมากยิ่งขึ้น โดยที่ขอบเขตความเชื่อมั่นคำนวณได้จากสมการที่ 2.20

$$CI = \bar{x} \pm \left(Z_{0.5 - \frac{\alpha}{2}} \right) \left(\frac{\sigma}{\sqrt{n}} \right) \quad (2.20)$$

โดยที่	\bar{x}	คือ ค่าเฉลี่ยเลขคณิต
	Z	คือ ค่า Z Score
	α	คือ ค่าพารามิเตอร์ช่วงความเชื่อมั่น $\alpha \in (0,1]$
	σ	คือ ค่าเบี่ยงเบนมาตรฐาน
	n	คือ จำนวนข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.8 การปรับความราบเรียบด้วยวิธีซาวิตซ์กี-โกลีย์ (Savitzky-Golay Smoothing)

ผลลัพธ์ที่ได้จากการจัดจำแนกส่วนใหญ่มักมีความแปรปรวนรวมอยู่ด้วย อันเนื่องมาจากหลายสาเหตุด้วยกัน เช่น การเลือกคุณลักษณะสำคัญที่ใช้เป็นข้อมูลในการจัดจำแนกได้ไม่เหมาะสม ข้อมูลที่นำมาวิเคราะห์ถูกบดบังด้วยสัญญาณรบกวน เป็นต้น ทำให้ยากแก่การวิเคราะห์หาช่วงเวลาที่แท้จริงเกิดความผิดพลาดขึ้น

ในการลดความแปรปรวนที่เกิดขึ้นสามารถทำได้หลากหลายวิธีด้วยกัน ขึ้นอยู่กับเงินทุนของผู้พัฒนา ระยะเวลาในการวิเคราะห์ และความเชื่อถือได้ในการทำนายที่ต้องการ เช่น การเพิ่มตัวกรองสัญญาณรบกวนที่ส่วนการประมวลผลสัญญาณขั้นต้น ก่อนที่จะนำสัญญาณที่จัดเก็บได้มาทำการวิเคราะห์ ซึ่งต้องออกแบบตัวกรองสัญญาณรบกวนให้เหมาะสม โดยไม่ทำให้ข้อมูลสำคัญของสัญญาณที่ต้องการวิเคราะห์สูญหายไป นอกจากนี้วิธีการเพิ่มตัวกรองสัญญาณรบกวนแล้ว วิธีการเฉลี่ยค่าผลลัพธ์ที่ได้จากการจัดจำแนก ก็เป็นอีกวิธีหนึ่งที่ใช้ในการลดความแปรปรวนของผลลัพธ์ได้ เช่น การเฉลี่ยแบบเคลื่อนที่อย่างง่าย (Simple Moving Average), การเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียล (Exponential Moving Average) และการเฉลี่ยด้วยวิธีของ Savitzky-Golay (Savitzky – Golay Smoothing) เป็นต้น

ในปีคริสต์ศักราช 1964 Savitzky และ Golay ได้นำเสนออัลกอริทึมในการปรับสัญญาณที่มีความแปรปรวนให้ราบเรียบด้วยวิธีการใช้ค่าเฉลี่ย โดยการประมาณด้วยค่ากำลังสองที่น้อยที่สุด [27] ซึ่งวิธีการเฉลี่ยด้วยวิธีของ Savitzky-Golay มีข้อดีหลายประการด้วยกัน เช่น เป็นการเฉลี่ยโดยการถ่วงน้ำหนักของข้อมูลรอบๆ จุดที่ทำการเฉลี่ยด้วยน้ำหนักการเฉลี่ยที่แตกต่างกันไป ทำให้ผลลัพธ์ที่ได้สามารถจัดสัญญาณรบกวนได้ดี ในขณะที่ยังคงรายละเอียดของสัญญาณต้นฉบับที่มีความถี่สูงไว้ได้ เป็นต้น ซึ่งการปรับความราบเรียบด้วยวิธีของ Savitzky-Golay สามารถแสดงได้ดังสมการที่ 2.21 ต่อมาวิธีการปรับความราบเรียบของ Savitzky-Golay ก็ได้รับความนิยมอย่างกว้างขวาง เนื่องจากเป็นวิธีการที่มีประสิทธิภาพอย่างมาก ซึ่งถูกนำไปใช้ในหลายด้านด้วยกัน เช่น ทีมนักวิจัยของ Kaneko ได้ใช้ค่าของตัวแปรบางตัวแปรที่สามารถวัดได้จากระบบในการประมาณค่าตัวแปรอื่นที่ไม่ทราบค่า โดยใช้ Support Vector Machine ในการประมาณค่าตัวแปรที่ไม่ทราบค่า โดยพบว่าผลลัพธ์ที่ได้มีความแปรปรวนรวมอยู่มาก ดังนั้นจึงใช้วิธีการปรับความราบเรียบของ Savitzky-Golay เพื่อลดผลของความแปรปรวนที่เกิดขึ้น ซึ่งช่วยเพิ่มความแม่นยำในการทำนายได้ [28]

$$S_i = \sum_{n=-\frac{w-1}{2}}^{\frac{w-1}{2}} C_n x_{i+n} \quad (2.21)$$

โดยที่	S_i	คือ ค่าเฉลี่ยที่จุด i
	w	คือ ขนาดของหน้าต่างที่ใช้ในการเฉลี่ย (จำนวนคี่)
	C_n	คือ ค่าสัมประสิทธิ์การถ่วงน้ำหนัก
	x_{i+n}	คือ ข้อมูลต้นฉบับ ที่ตำแหน่ง $i + n$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

การพัฒนาอัลกอริทึมตรวจสอบความผิดปกติของแบริ่ง

3.1 บทนำ

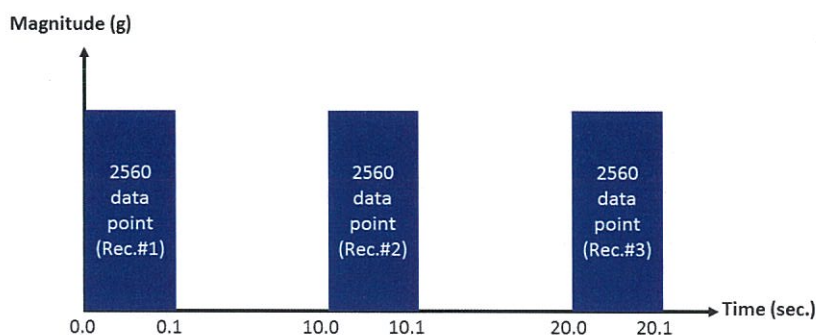
ในบทนี้เป็นการนำเสนอขั้นตอนและวิธีการในการพัฒนาอัลกอริทึมตรวจสอบความผิดปกติในการทำงานของแบริ่ง โดยเริ่มจากขั้นตอนการเตรียมข้อมูลการสั่นสะเทือนของแบริ่งที่นำมาวิเคราะห์ให้อยู่ในรูปแบบที่เหมาะสมแก่การประมวลผลในลำดับถัดไป ต่อจากนั้นเป็นขั้นตอนการระบุตำแหน่งที่แบริ่งเกิดความผิดปกติอาศัยวิเคราะห์จากสัญญาณการสั่นสะเทือนของแบริ่ง ต่อจากนั้นเป็นการสกัดคุณลักษณะสำคัญออกจากสัญญาณการสั่นสะเทือนที่เป็นเอกลักษณ์ของการทำงานของแบริ่ง ซึ่งใช้เป็นข้อมูลในการประมาณค่าพารามิเตอร์ของแบบจำลองการถดถอยโลจิสติกแบบทวินาม ต่อจากนั้นเป็นขั้นตอนการประมาณค่าขอบเขตโอกาสที่แบริ่งทำงานผิดปกติซึ่งถูกใช้เป็นค่าขอบเขตในการตรวจสอบความผิดปกติของแบบจำลองการถดถอยโลจิสติกแบบทวินาม และในขั้นตอนสุดท้ายเป็นการเพิ่มประสิทธิภาพให้กับอัลกอริทึมตรวจสอบความผิดปกติในการทำงานของแบริ่ง โดยการเพิ่มส่วนปรับความราบเรียบด้วยวิธีการของซาวีจกี-โกเลย์ ซึ่งช่วยลดความแปรปรวนของผลการทำนายที่ได้จากอัลกอริทึม ทำให้ผลการตรวจสอบความผิดปกติในการทำงานของแบริ่งมีประสิทธิภาพมากยิ่งขึ้น

3.2 การเตรียมข้อมูลเบื้องต้นเพื่อทำการวิเคราะห์ (Data Preprocessing)

เนื่องจากชุดข้อมูลการสั่นสะเทือนที่ได้จากการทดสอบด้วยชุดทดสอบเร่งอายุการใช้งานของแบริ่ง ที่ทำการทดสอบและเผยแพร่โดยสถาบัน FEMTO-ST นั้น ใช้ความถี่ในการซิกตัวอย่างเท่ากับ 25.6 kHz โดยบันทึกค่าทุกๆ 10 วินาที เป็นระยะเวลา 0.1 วินาที ในแต่ละครั้งที่ทำการบันทึกการสั่นสะเทือน ดังนั้นข้อมูลการสั่นสะเทือนจึงมีมิติเท่ากับ $1 \times (2560 \times \text{Rec} \#n)$ ดังแสดงในรูปที่ 3.1 ซึ่งยากแก่การวิเคราะห์เพื่อหาตำแหน่งช่วงเวลาที่เกิดความผิดปกติขึ้น ดังนั้นจึงเตรียมข้อมูลในแต่ละช่วงการบันทึกข้อมูลให้อยู่ในรูปแบบของคอลัมน์เมทริกซ์ ดังสมการที่ 3.1

$$\text{Vibration} = \begin{bmatrix} \text{Vbr}_1(1) & \dots & \text{Vbr}_1(\text{Rec. \#n}) \\ \vdots & \ddots & \vdots \\ \text{Vbr}_{2560}(1) & \dots & \text{Vbr}_{2560}(\text{Rec. \#n}) \end{bmatrix} \quad (3.1)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.1 วิธีการเก็บบันทึกข้อมูลการสั่นสะเทือนของ IEEE PHM2012 Data Challenge

3.3 การระบุช่วงเวลาที่แท้จริงเกิดความผิดปกติ (Define Actual Defect Point)

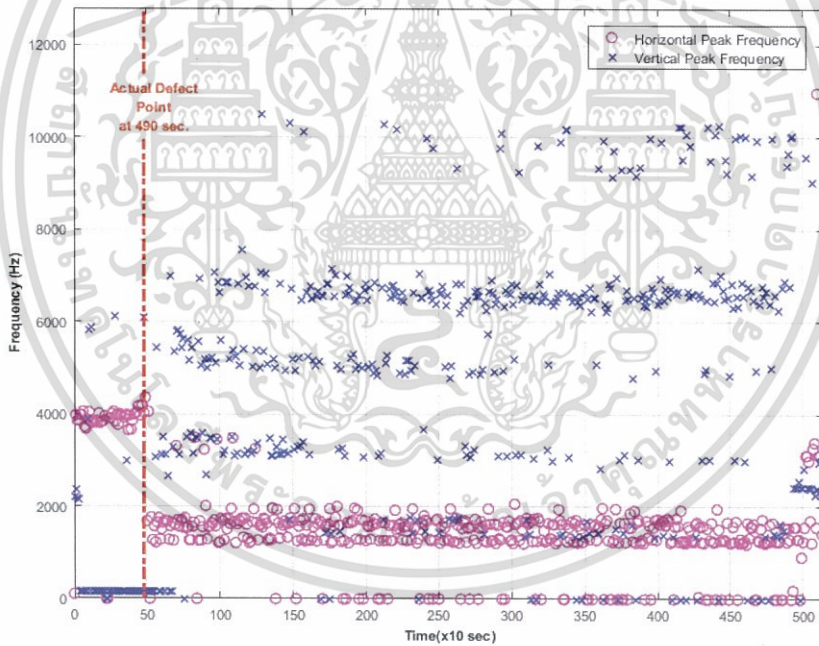
ในการระบุช่วงเวลาที่แท้จริงเกิดความผิดปกติขึ้น จะใช้วิธีการวิเคราะห์ขนาดขององค์ประกอบความถี่ที่มีขนาดมากที่สุด (องค์ประกอบความถี่หลัก) ของสัญญาณการสั่นสะเทือนทั้งในแนวดิ่งและแนวระดับที่ได้จากการแปลงฟูเรียร์ไม่ต่อเนื่องทางเวลา (Discrete Time Fourier Transform) เป็นปริมาณในการจัดจำแนกสัญญาณการสั่นสะเทือนของแบริ่งในสภาวะการทำงานปกติออกจากสัญญาณการสั่นสะเทือนในสภาวะการทำงานที่เกิดความผิดปกติขึ้น โดยพิจารณาจากการเปลี่ยนแปลงขนาดขององค์ประกอบความถี่หลัก ดังแสดงในรูปที่ 3.2-3.3

จากรูปที่ 3.2 และรูปที่ 3.3 แสดงให้เห็นถึงการเปลี่ยนแปลงองค์ประกอบความถี่หลักอย่างชัดเจน ทั้งองค์ประกอบความถี่ของสัญญาณการสั่นสะเทือนในแนวดิ่ง และแนวระดับ ซึ่งมีใช้การเปลี่ยนแปลงเพียงชั่วขณะ จึงสามารถสรุปได้ว่าเงื่อนไขในการทำงานของแบริ่งได้เปลี่ยนไปอย่างสิ้นเชิง หรือกล่าวอีกนัยหนึ่งคือ แบริ่งได้เปลี่ยนจากสภาวะการทำงานปกติไปเป็นสภาวะที่ทำงานด้วยความบกพร่องบางประการ ดังนั้นจึงสามารถระบุช่วงเวลาที่แท้จริงเริ่มเกิดความผิดปกติ (Actual Defect Point) กับทุกชุดข้อมูลการสั่นสะเทือนของแบริ่งได้ดังตารางที่ 3.1

จากข้อมูลการสั่นสะเทือนของแบริ่งทั้งหมด 17 ชุดข้อมูล ถูกนำไปใช้ในการเรียนรู้เพื่อพัฒนาอัลกอริทึมจำนวน 13 ชุดข้อมูล (ชุดข้อมูลที่ 1, 3, 4, 5, 7, 9, 10, 11, 12, 13, 14, 16 และ 17) และเลือกใช้ 4 ชุดข้อมูล (ชุดข้อมูลที่ 2, 6, 8 และ 15) ที่ครอบคลุมทุกเงื่อนไขการทดสอบที่มีการเปลี่ยนแปลงองค์ประกอบความถี่หลักอย่างชัดเจนสำหรับเป็นข้อมูลในการทดสอบอัลกอริทึมที่ได้พัฒนาขึ้น



รูปที่ 3.2 ความถี่หลักที่ได้จากการแปลงฟูเรียร์ของสัญญาณการการสั่นสะเทือนของชุดข้อมูลที่ 4



รูปที่ 3.3 ความถี่ที่ได้จากการแปลงฟูเรียร์ของสัญญาณการการสั่นสะเทือนของชุดข้อมูลที่ 15

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 ช่วงเวลาที่แบริ่งเริ่มเกิดเกิดความผิดปกติ

ชุดข้อมูลที่	เงื่อนไขการทำงาน	การทดสอบที่	ช่วงเวลาที่แบริ่งเริ่มเกิด ความผิดปกติ (วินาที)
1	1,800 rpm, 4,000 N	1	540
2	1,800 rpm, 4,000 N	2	1,340
3	1,800 rpm, 4,000 N	3	8,590
4	1,800 rpm, 4,000 N	4	2,750
5	1,800 rpm, 4,000 N	5	980
6	1,800 rpm, 4,000 N	6	1,530
7	1,800 rpm, 4,000 N	7	2,110
8	1,650 rpm, 4,200 N	1	630
9	1,650 rpm, 4,200 N	2	890
10	1,650 rpm, 4,200 N	3	470
11	1,650 rpm, 4,200 N	4	1,290
12	1,650 rpm, 4,200 N	5	540
13	1,650 rpm, 4,200 N	6	2,120
14	1,650 rpm, 4,200 N	7	210
15	1,500 rpm, 5,000 N	1	500
16	1,500 rpm, 5,000 N	2	600
17	1,500 rpm, 5,000 N	3	770

3.4 การสกัดคุณลักษณะสำคัญ (Feature Extraction)

ในการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งนี้ใช้ค่าคุณลักษณะทั้งบนโดเมนเวลา และคุณลักษณะบนโดเมนเวลา - ความถี่ ซึ่งถูกสกัดออกจากสัญญาณการสั่นสะเทือนทั้งในแนวตั้ง และแนวระดับ ทั้งหมด 3 ชนิดด้วยกันคือ Crest Factor, Kurtosis และ Wavelet Packet Decomposition Node Energy โดยที่ค่า Crest Factor และ Kurtosis ทำการแปลงได้โดยการอาศัยสมการที่ 2.1 และ 2.2 ส่วนการสกัดคุณลักษณะ Wavelet Packet Decomposition Node Energy จำเป็นที่จะต้องเลือกระดับความละเอียดในการแปลง และเวฟเล็ตเบสิสที่เหมาะสมกับสัญญาณการสั่นสะเทือนของแบริ่งที่จะทำการวิเคราะห์

ในการพิจารณาระดับความละเอียดในการแปลงเวฟเล็ต สามารถประมาณได้จากระยะห่างที่น้อยที่สุดของขนาดองค์ประกอบความถี่หลักที่ได้ในขั้นตอนการวิเคราะห์สัญญาณการสั่นสะเทือนเพื่อระบุตำแหน่งที่แบริ่งเกิดความผิดปกติขึ้น โดยระยะห่างระหว่างขนาดขององค์ประกอบหลักที่น้อยที่สุดในแต่ละชุดข้อมูลที่ใช้ในการสร้างอัลกอริทึมได้แสดงในตารางที่ 3.2 และตารางที่ 3.3 พบว่าระยะห่างที่น้อยที่สุดของขนาดองค์ประกอบความถี่หลักคือ 0.34 kHz จากนั้นคำนวณหาระดับความละเอียดในการแปลงเวฟเล็ตแพ็คเกจที่เหมาะสมด้วยสมการที่ 2.10 พบว่าระดับความละเอียดที่เอ็กเหมาะสมในการแปลงเวฟเล็ตแพ็คเกจคือความละเอียดในการแปลงในระดับที่ 5 ไปใช้ประโยชน์ด้านการคำนวณว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.2 ระยะห่างระหว่างขนาดขององค์ประกอบความถี่หลักที่น้อยที่สุดของสัญญาณการสั่นสะเทือนในแนวระดับ

ชุดข้อมูลที่	ความถี่หลักที่น้อยที่สุด (kHz)	ระยะห่างระหว่างความถี่หลักที่น้อยที่สุด (kHz)
1	0.35, 1.12, 2.83,	0.77
3	0.00, 0.34, 1.05, 2.64, 4.77	0.34
4	0.00, 1.11, 3.03, 4.90, 12.00	1.11
5	0.00, 1.45, 3.49, 5.43	1.45
7	0.17, 1.45, 3.48, 5.21, 12.60	1.28
9	0.00, 1.21, 1.76, 3.56, 10.45, 11.90, 12.74	0.55
10	0.16, 1.24, 3.39, 4.00, 5.18	0.61
11	0.00, 1.25, 3.60	1.25
12	0.16, 1.10, 3.63, 4.14	0.51
13	0.00, 1.32, 3.95	1.32
14	0.00, 1.19, 3.59, 5.41	1.19
16	0.14, 1.24, 3.60, 12.07	1.10
17	0.00, 1.21, 5.96, 12.13	1.21

ตารางที่ 3.3 ระยะห่างระหว่างขนาดขององค์ประกอบความถี่หลักที่น้อยที่สุดของสัญญาณการสั่นสะเทือนในแนวตั้ง

ชุดข้อมูลที่	ความถี่หลักที่น้อยที่สุด (kHz)	ระยะห่างระหว่างความถี่หลักที่น้อยที่สุด (kHz)
1	0.00, 1.71, 5.47, 7.63, 10.00	1.71
3	0.00, 5.26, 7.45	2.19
4	0.00, 2.38, 7.97, 9.63	1.66
5	0.00, 3.55, 4.91, 6.84, 8.90, 9.84	0.94
7	0.00, 3.73, 4.97, 6.86, 9.01, 10.12	1.10
9	0.00, 2.11, 2.98, 3.59, 5.77, 10.37, 11.64	0.61
10	0.16, 2.97, 3.59, 4.19, 6.22, 8.21, 10.59	0.60
11	0.16, 2.85, 3.59, 6.35, 10.45	0.74
12	0.16, 3.72, 5.90, 11.07	2.18
13	2.93, 3.95, 5.25, 6.96, 10.66	1.02
14	3.62, 5.93, 10.40	2.31
16	0.00, 2.89, 6.03, 9.96	2.89
17	0.00, 3.66, 4.94, 6.66, 9.06, 10.08	1.02

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อทราบระดับความละเอียดที่เหมาะสมสำหรับการแปลงเวฟเล็ตแพ็กเก็ตแล้ว ขั้นตอนต่อไปเป็นการเลือกเวฟเล็ตเบสิสโดยใช้ MESER เป็นเกณฑ์ในการเลือก ซึ่งคำนวณได้จากสมการที่ 2.6 โดยผลการทดสอบได้แสดงในตารางที่ 3.4 และตารางที่ 3.5

ตารางที่ 3.4 Maximum Energy to Shannon Entropy Ratio ของสัญญาณการสั่นสะเทือนในแนวระดับ

Condition	Maximum Energy to Shannon Entropy Ratio, R(s) ($\times 10^2$)					
	1800-rpm 4000-N		1650-rpm 400-N		1500-rpm 5000-N	
	Dataset 1	Dataset 2	Dataset 8	Dataset 9	Dataset 15	Dataset 16
SYM2	6.1966	1.2388	2.9464	2.6585	0.9300	0.8291
SYM3	6.5842	1.2860	3.0783	2.7755	0.9807	0.8706
SYM4	6.8376	1.2991	3.1209	2.7768	1.0191	0.8889
SYM5	6.9777	1.3383	3.1930	2.8586	1.0471	0.9099
SYM6	7.2737	1.3657	3.3113	2.9100	1.0788	0.9331
SYM7	7.4851	1.3934	3.3320	2.9571	1.1033	0.9565
SYM8	7.8358	1.4433	3.5195	3.0720	1.1370	0.9800
SYM10	8.2493	1.5139	3.6724	3.2198	1.1918	1.0280
COIF1	6.3277	1.2479	2.9420	2.6480	0.9488	0.8420
COIF2	7.2539	1.3714	3.2478	2.9141	1.0702	0.9339
COIF3	7.9341	1.4748	3.5601	3.1338	1.1580	1.0034
COIF4	8.7345	1.5636	3.7952	3.3160	1.2265	1.0640
COIF5	9.4341	1.6602	4.0356	3.5443	1.3016	1.1289
DB1	5.4389	1.1520	2.6935	2.4426	0.8462	0.7574
DB2	6.1966	1.2388	2.9464	2.6585	0.9300	0.8291
DB3	6.5842	1.2860	3.0783	2.7755	0.9807	0.8706
DB4	6.9044	1.3320	3.2013	2.8904	1.0127	0.9004
DB5	7.2634	1.3748	3.2680	2.9606	1.0541	0.9381
DB6	7.4838	1.3967	3.3223	3.0003	1.0732	0.9517
DB7	7.6414	1.4340	3.4244	3.0857	1.0947	0.9757
DB8	7.8651	1.4632	3.5198	3.1547	1.1254	0.9996
DB9	8.1147	1.4981	3.5843	3.2178	1.1526	1.0244
DB10	8.3365	1.5240	3.6748	3.3036	1.1804	1.0462
DB20	10.2568	1.8374	4.4341	3.9349	1.4148	1.2598
DB30	11.9813	2.1635	5.2638	4.6037	1.6695	1.4827
DB40	13.3250	2.4401	6.0023	5.2350	1.9083	1.7000

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.5 Maximum Energy to Shannon Entropy Ratio ของสัญญาณการสั่นสะเทือนในแนวตั้ง

Condition	Maximum Energy to Shannon Entropy Ratio, R(s) ($\times 10^2$)					
	1800-rpm 4000-N		1650-rpm 400-N		1500-rpm 5000-N	
Wavelet Basis	Dataset 1	Dataset 2	Dataset 8	Dataset 9	Dataset 15	Dataset 16
SYM2	1.9493	3.4055	4.4512	6.1043	1.0234	0.7376
SYM3	2.0138	3.5136	4.6403	6.3950	1.0486	0.7564
SYM4	2.0353	3.5561	4.6867	6.5175	1.0563	0.7593
SYM5	2.1072	3.7126	4.8901	6.7691	1.0894	0.7830
SYM6	2.1507	3.8093	4.9442	6.9142	1.1118	0.7985
SYM7	2.1804	3.8341	5.0101	7.0247	1.1266	0.8123
SYM8	2.2491	4.0372	5.2445	7.3013	1.1643	0.8338
SYM10	2.3292	4.2527	5.4949	7.6082	1.2079	0.8657
COIF1	1.9676	3.4228	4.4300	6.1269	1.0310	0.7409
COIF2	2.1240	3.7232	4.9134	6.8097	1.1044	0.7945
COIF3	2.3002	4.0651	5.3260	7.4133	1.1857	0.8531
COIF4	2.4248	4.2953	5.6466	7.8400	1.2463	0.8996
COIF5	2.5684	4.6377	6.0165	8.3441	1.3187	0.9555
DB1	1.8225	3.1550	4.0366	5.5125	0.9708	0.7005
DB2	1.9493	3.4055	4.4512	6.1043	1.0234	0.7376
DB3	2.0138	3.5136	4.6403	6.3950	1.0486	0.7564
DB4	2.0564	3.6096	4.8265	6.6136	1.0688	0.7720
DB5	2.1428	3.7119	4.9500	6.8798	1.1029	0.7974
DB6	2.1699	3.7375	5.0194	6.9410	1.1082	0.8021
DB7	2.2191	3.8598	5.1726	7.1825	1.1429	0.8251
DB8	2.2699	3.9710	5.3070	7.3506	1.1676	0.8433
DB9	2.3243	4.0558	5.4499	7.5684	1.1957	0.8644
DB10	2.3776	4.1273	5.5739	7.7458	1.2195	0.8854
DB20	2.8040	5.0245	6.6369	9.2732	1.4410	1.0434
DB30	3.3588	5.9147	7.8276	10.9546	1.6916	1.2277
DB40	3.8341	6.8556	8.9459	12.5272	1.9297	1.4006

จากตารางที่ 3.4 และตารางที่ 3.5 พบว่าการแปลงเวฟเล็ตด้วยเวฟเล็ตเบสิส Daubechies40 ให้ค่า MESER ที่มากที่สุด ดังนั้นในการสกัดคุณลักษณะ Wavelet Packet Decomposition Node Energy จึงเลือกใช้ Daubechies40 เป็นเบสิสในการแปลงเวฟเล็ต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่าคุณลักษณะสำคัญของสัญญาณทั้งสามชนิด (Crest Factor, Kurtosis และ Wavelet Packet Decomposition Node Energy) ที่ถูกสกัดออกจากสัญญาณการสั่นสะเทือนของแบริ่งทั้งในแนวตั้งและแนวระดับ จะเก็บอยู่รูปแบบของเมทริกซ์ที่มีโครงสร้างดังสมการที่ 3.2

$$\text{FeaMat} = \begin{bmatrix} h\text{WPDNdEn}_{\text{Node1}}(1) & \dots & h\text{WPDNdEn}_{\text{Node1}}(\text{Rec}\#n) \\ \vdots & \vdots & \vdots \\ h\text{WPDNdEn}_{\text{Node32}}(1) & \dots & h\text{WPDNdEn}_{\text{Node32}}(\text{Rec}\#n) \\ v\text{WPDNdEn}_{\text{Node1}}(1) & \dots & v\text{WPDNdEn}_{\text{Node1}}(\text{Rec}\#n) \\ \vdots & \vdots & \vdots \\ v\text{WPDNdEn}_{\text{Node32}}(1) & \dots & v\text{WPDNdEn}_{\text{Node32}}(\text{Rec}\#n) \\ h\text{Kurtosis}(1) & \dots & h\text{Kurtosis}(\text{Rec}\#n) \\ h\text{CrestFactor}(1) & \dots & h\text{CrestFactor}(\text{Rec}\#n) \\ v\text{Kurtosis}(1) & \dots & v\text{Kurtosis}(\text{Rec}\#n) \\ v\text{CrestFactor}(1) & \dots & v\text{CrestFactor}(\text{Rec}\#n) \end{bmatrix} \quad (3.2)$$

3.5 การสร้างแบบจำลองสำหรับตรวจจับความผิดปกติในการทำงานของแบริ่ง

ในส่วน of แบบจำลองสำหรับตรวจจับความผิดปกติในการทำงานของแบริ่ง จะอาศัยการวิเคราะห์การถดถอยโลจิสติกแบบทวินามเป็นเครื่องมือในการตรวจจับความผิดปกติที่เกิดขึ้น โดยใช้ค่าคุณลักษณะสำคัญทั้งสามชนิด (Crest Factor, Kurtosis และ Wavelet Packet Decomposition Node Energy) ที่ถูกสกัดออกจากสัญญาณการสั่นสะเทือนในขั้นตอนก่อนหน้านี้เป็นข้อมูลในการเรียนรู้และพัฒนาอัลกอริทึม ในส่วนของกลุ่มเป้าหมายในการเรียนรู้เพื่อสร้างแบบจำลองการถดถอยโลจิสติกแบบทวินาม คือ กลุ่มเป้าหมายในกรณีที่แบริ่งทำงานในสภาวะปกติ และกลุ่มเป้าหมายในกรณีที่แบริ่งทำงานในสภาวะผิดปกติ โดยพิจารณาจากช่วงเวลาที่เกิดความผิดปกติขึ้น ในกระบวนการหาค่าพารามิเตอร์ของแบบจำลองการถดถอยโลจิสติกเพื่อใช้ในการตรวจจับความผิดปกติที่เกิดขึ้น จะใช้วิธีการหาค่าความน่าจะเป็นที่มากที่สุด ทำให้ได้ค่าพารามิเตอร์ของแบบจำลองการถดถอยโลจิสติกดังตารางที่ 3.6 และเมื่อนำค่าพารามิเตอร์ของแบบจำลองจากตารางที่ 3.6 แทนลงในสมการที่ 2.13 และ 2.15 ซึ่งให้ผลลัพธ์ดังสมการที่ 3.3 และ 3.5 โดยในสมการที่ 3.3 เป็นการหาค่าโอกาสที่คุณลักษณะสำคัญ (Fea) จะเป็นคุณลักษณะสำคัญที่ได้จากแบริ่งขณะที่ทำงานในสภาวะปกติ ส่วนในสมการที่ 3.5 เป็นการหาค่าโอกาสที่จะเป็นคุณลักษณะสำคัญที่ได้จากแบริ่งขณะที่ทำงานในสภาวะที่เกิดความผิดปกติ

ตารางที่ 3.6 พารามิเตอร์ของแบบจำลองการถดถอยโลจิสติกแบบทวินาม

พารามิเตอร์	ขนาด ($\times 10^{-4}$)	พารามิเตอร์	ขนาด ($\times 10^{-4}$)	พารามิเตอร์	ขนาด ($\times 10^{-4}$)
β_0	-21,541.6887	β_{23}	192.8279	β_{46}	76.2603
β_1	1.6517	β_{24}	12.7284	β_{47}	-80.3902
β_2	-7.8528	β_{25}	167.5271	β_{48}	37.5884
β_3	4.6174	β_{26}	725.5733	β_{49}	33.8011
β_4	-3.6443	β_{27}	-477.7126	β_{50}	70.8993
β_5	122.2142	β_{28}	-351.8188	β_{51}	-0.4963
β_6	60.8701	β_{29}	-1,624.4975	β_{52}	19.5867
β_7	-30.3782	β_{30}	-170.2782	β_{53}	-38.3451
β_8	31.0610	β_{31}	-1,642.9630	β_{54}	-14.8854
β_9	338.6499	β_{32}	564.3955	β_{55}	-102.6355
β_{10}	-93.7185	β_{33}	0.3362	β_{56}	4.9139
β_{11}	-1.2062	β_{34}	4.8790	β_{57}	-3.5859
β_{12}	17.2887	β_{35}	-35.0217	β_{58}	16.2121
β_{13}	60.1928	β_{36}	14.3660	β_{59}	41.7552
β_{14}	58.5189	β_{37}	-69.9900	β_{60}	62.7913
β_{15}	183.7204	β_{38}	-183.0563	β_{61}	-14.3445
β_{16}	-57.3179	β_{39}	-274.7737	β_{62}	-96.3656
β_{17}	25.4112	β_{40}	40.1407	β_{63}	51.1698
β_{18}	-60.1105	β_{41}	-3.2332	β_{64}	-16.0824
β_{19}	-70.1453	β_{42}	-2.6494	β_{65}	-362.9909
β_{20}	21.1419	β_{43}	127.8052	β_{66}	-265.7188
β_{21}	-429.0693	β_{44}	53.4003	β_{67}	49.9907
β_{22}	153.3486	β_{45}	-5.2045	β_{68}	-238.3706

$$P(Y = \text{NormalMode}|\text{Fea}) = \frac{e^{-21,541.6887+\dots-238.3706v\text{CrestFactor}}}{1 + e^{-21,541.6887+\dots-238.3706v\text{CrestFactor}}} \quad (3.3)$$

$$P(Y = \text{DefectMode}|\text{Fea}) = \frac{1}{1 + e^{-21,541.6887+\dots-238.3706v\text{CrestFactor}}} \quad (3.4)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.6 การกำหนดขอบเขตของโอกาสที่แปร่งทำงานผิดปกติ (Defect Threshold)

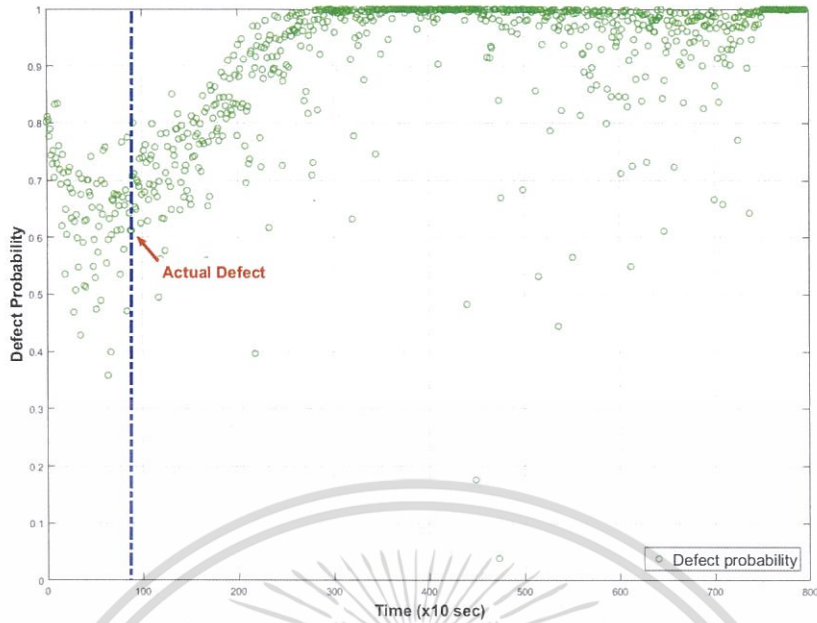
อัลกอริทึมตรวจสอบความผิดปกติในการทำงานของแปร่งที่พัฒนาขึ้น ใช้การวิเคราะห์การถดถอยโลจิสติกแบบทวินามเป็นเครื่องมือในการคัดกรองคุณลักษณะการทำงานของแปร่ง โดยมีเป้าหมายในการคัดกรองสองกลุ่มเป้าหมายคือ สภาวะที่แปร่งทำงานปกติ และสภาวะที่แปร่งเกิดความผิดปกติขึ้น โดยอาศัยค่าคุณลักษณะที่สกัดได้เป็นปริมาณในการจัดจำแนก

เนื่องจากผลลัพธ์ที่ได้จากแบบจำลองโลจิสติกแบบทวินามเป็นค่าโอกาสที่แปร่งทำงานในสภาวะปกติ และค่าโอกาสที่แปร่งทำงานในสภาวะที่เกิดความผิดปกติขึ้น โดยจะต้องเลือกขอบเขตของความน่าจะเป็นที่เหมาะสม เพื่อใช้เป็นปริมาณในการจัดจำแนกประเภทของแบบจำลองการถดถอยโลจิสติก โดยทั่วไปแล้วการจัดจำแนกข้อมูลด้วยการวิเคราะห์การถดถอยโลจิสติกจะใช้ค่าความน่าจะเป็นเท่ากับ 0.5 เป็นค่าขอบเขตในการจัดจำแนกประเภทของข้อมูล เช่น เมื่อวิเคราะห์คุณลักษณะสำคัญที่สกัดได้จากสัญญาณการสั่นสะเทือนของแปร่งด้วยการวิเคราะห์ด้วยแบบจำลองการถดถอยโลจิสติกแบบทวินามแล้วพบว่า มีค่าโอกาสที่แปร่งจะทำงานในสภาวะปกติเป็น 0.45 และโอกาสที่แปร่งจะทำงานในสภาวะที่เกิดความผิดปกติเป็น 0.55 ดังนั้นจึงสามารถตีความได้ว่าค่าคุณลักษณะสำคัญนี้เป็นค่าคุณลักษณะสำคัญที่ได้จากการทำงานของแปร่งในสภาวะที่เกิดความผิดปกติขึ้น เป็นต้น

ในขั้นตอนการกำหนดขอบเขตความน่าจะเป็นในการเกิดความผิดปกตินี้ เป็นขั้นตอนการหาค่าโอกาสที่เหมาะสมกับระบบตรวจสอบความผิดปกติในการทำงานของแปร่ง เพื่อใช้เป็นขอบเขตในการคัดแยกกลุ่มข้อมูลด้วยแบบจำลองการถดถอยโลจิสติกแบบทวินามสำหรับตรวจสอบความผิดปกติในการทำงานของแปร่งที่ได้พัฒนาขึ้น โดยอาศัยค่าขอบเขตล่างของช่วงความเชื่อมั่นของค่าเฉลี่ยโอกาสที่แปร่งทำงานในสภาวะผิดปกติที่ระดับความเชื่อมั่นต่างๆ เป็นปริมาณกำหนดขอบเขตในการจัดจำแนกกลุ่มของผลการทำนาย ซึ่งประกอบไปด้วย 3 ขั้นตอนหลักดังต่อไปนี้

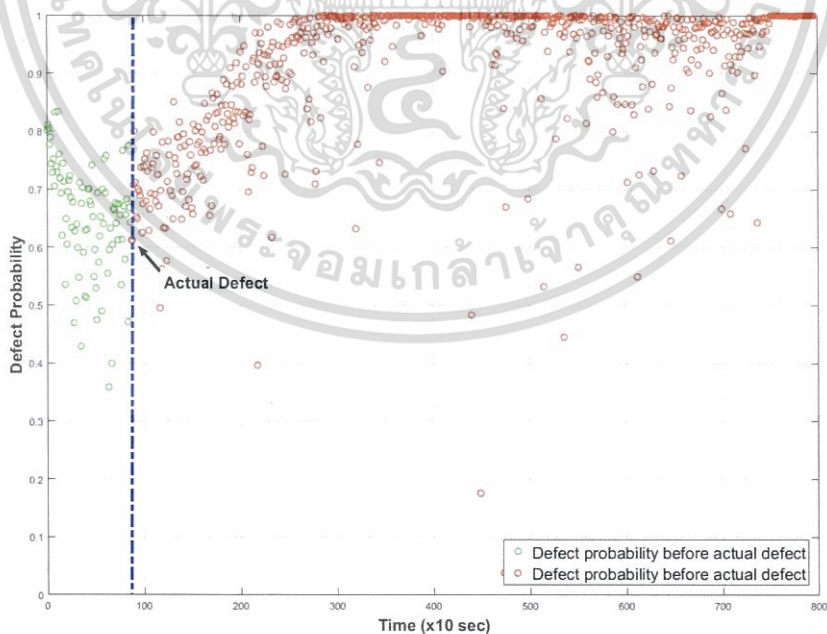
3.6.1 การหาค่าเฉลี่ยของโอกาสที่แปร่งทำงานผิดปกติ

ค่าโอกาสที่แปร่งทำงานในสภาวะที่ผิดปกติสามารถคำนวณได้จากสมการที่ 3.4 โดยการใช้ค่าคุณลักษณะสำคัญที่สกัดได้ทั้งสามชนิดของทุกชุดข้อมูลสำหรับเรียนรู้เพื่อสร้างอัลกอริทึม (Training Dataset) เป็นข้อมูลในการทำนาย โดยค่าโอกาสที่ได้จากการทำนายด้วยชุดข้อมูลที่ 9 ได้แสดงดังรูปที่ 3.4



รูปที่ 3.4 ค่าโอกาสที่แท้จริงจะทำงานในสถานะที่เกิดความผิดปกติของชุดข้อมูลที่ 9

การหาค่าเฉลี่ยของโอกาสที่แท้จริงทำงานผิดปกติ จะใช้ค่าโอกาสที่แท้จริงทำงานผิดปกติหลังจากจุดที่ถูกระบุว่าเป็นตำแหน่งที่แท้จริงเริ่มทำงานผิดปกติเป็นข้อมูลในการคำนวณ ดังข้อมูลที่แสดงด้วยวงกลมสีแดงในรูปที่ 3.5 โดยค่าเฉลี่ยของโอกาสในแต่ละชุดข้อมูลที่ใช้สำหรับเรียนรู้ เพื่อสร้างอัลกอริทึมได้แสดงในตารางที่ 3.7



รูปที่ 3.5 ค่าโอกาสที่แท้จริงทำงานผิดปกติของชุดข้อมูลที่ 9 โดยแบ่งได้เป็น 2 กลุ่มข้อมูล คือ ค่าโอกาสที่แท้จริงจะทำงานในสถานะที่ผิดปกติก่อนและหลังจุดที่แท้จริงทำงานผิดปกติแท้จริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.7 ค่าเฉลี่ยของโอกาสที่แบรีริงจะทำงานผิดปกติของชุดข้อมูลที่ใช้พัฒนาอัลกอริทึม

ชุดข้อมูลที่	เงื่อนไขการทดสอบ	ค่าเฉลี่ยของโอกาสที่แบรีริงทำงานผิดปกติ
1	1800-rpm 4000-N #1	0.9166
3	1800-rpm 4000-N #3	0.6413
4	1800-rpm 4000-N #4	0.7272
5	1800-rpm 4000-N #5	0.9484
7	1800-rpm 4000-N #7	0.8747
9	1650-rpm 4200-N #2	0.9063
10	1650-rpm 4200-N #3	0.8786
11	1650-rpm 4200-N #4	0.7136
12	1650-rpm 4200-N #5	0.9382
13	1650-rpm 4200-N #6	0.8312
14	1650-rpm 4200-N #7	0.8764
16	1500-rpm 5000-N #2	0.9175
17	1500-rpm 5000-N #3	0.9357

3.6.2 การคำนวณหาขอบเขตล่างของช่วงความเชื่อมั่นที่ระดับต่างๆ

ในการคำนวณหาขอบเขตล่างของช่วงความเชื่อมั่นที่ระดับต่างๆ จะใช้ค่าเฉลี่ยของโอกาสที่แบรีริงจะทำงานผิดปกติในแต่ละชุดข้อมูลดังที่แสดงในตารางที่ 3.7 เป็นข้อมูลในการคำนวณที่ระดับความเชื่อมั่นที่ 80%, 85%, 90%, 95% และ 99% โดยอาศัยสมการที่ 2.20 ซึ่งให้ค่าขอบล่างของช่วงความเชื่อมั่นที่ระดับต่างๆ ดังตารางที่ 3.8

ตารางที่ 3.8 ค่าขอบเขตล่างของช่วงความเชื่อมั่นที่ระดับความเชื่อมั่นต่างๆ

ระดับความมั่นใจ (%)	ขอบเขตล่างของช่วงความเชื่อมั่น
80	0.8172
85	0.8123
90	0.8056
95	0.7948
99	0.7708

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.6.3 การกำหนดโอกาสความผิดพลาดที่น้อยที่สุดที่แท้จริงเริ่มจะทำงานผิดพลาด

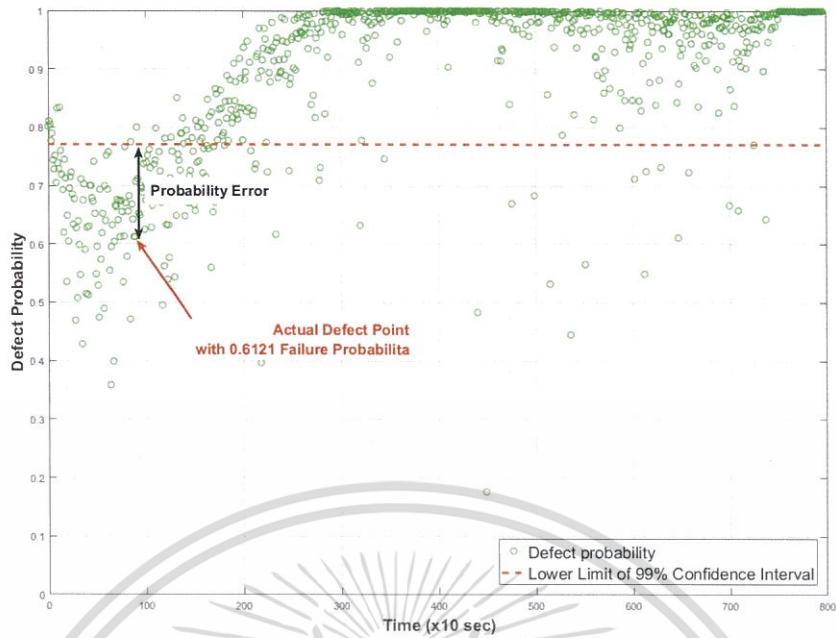
การเลือกค่าขอบเขตล่างของช่วงความเชื่อมั่นของโอกาสที่แท้จริงทำงานผิดพลาด เพื่อใช้เป็นขอบเขตในการตรวจจับความผิดพลาดในการทำงานของแท้จริงด้วยการวิเคราะห์การถดถอยโลจิสติกแบบทวินาม สามารถประมาณได้โดยการคำนวณหาค่าความคลาดเคลื่อนสมบูรณ์ของโอกาสที่แท้จริงทำงานผิดพลาด ณ ตำแหน่งที่แท้จริงเกิดความผิดพลาด (Absolute Error at Actual Defect Point, AEADP) ของแต่ละชุดข้อมูลที่ใช้ในการเรียนรู้ ดังแสดงในรูปที่ 3.6 ซึ่งสามารถคำนวณได้จากสมการที่ 3.5 จากนั้นหาค่าเฉลี่ยของความคลาดเคลื่อนสมบูรณ์ (Mean Absolute Error at Actual Defect Point, MAEADP) ของแต่ละชุดข้อมูลที่ใช้ในการเรียนรู้ด้วยสมการที่ 3.6 โดยที่ค่าขอบเขตล่างของโอกาสที่แท้จริงทำงานผิดพลาดที่ระดับความเชื่อมั่นใด ให้ผลการเฉลี่ยของความคลาดเคลื่อนสมบูรณ์ที่มีค่าน้อยที่สุดจะถูกเลือกใช้เป็นค่าขอบเขตในการจัดจำแนกประเภทของข้อมูลของแบบจำลองการถดถอยโลจิสติกแบบทวินาม เพื่อใช้ในการตรวจจับความผิดพลาดในการทำงานของแท้จริง

$$AEADP_i = |CiLL(CiLv) - DefProb(actDefPoint_i)| \quad (3.5)$$

$$MAEADP(CiLv) = \frac{\sum_{i=1}^N CAEADP_i}{N} \quad (3.6)$$

โดยที่	i	คือ จำนวนชุดข้อมูลที่ใช้ในการสร้างอัลกอริทึมทั้งหมด ซึ่งมีค่าเท่ากับ 13
	CiLL	คือ ค่าขอบเขตล่างของช่วงความเชื่อมั่น
	CiLv	คือ ค่าระดับความเชื่อมั่น
	actDefPoint	คือ ตำแหน่งที่แท้จริงเกิดความผิดพลาดขึ้น (Actual Defect Point)

จากตารางที่ 3.9-3.13 ได้แสดงค่าเฉลี่ยของความคลาดเคลื่อนสมบูรณ์ในแต่ละระดับความเชื่อมั่น ซึ่งคำนวณได้จากสมการที่ 3.6 โดยพบว่า การเลือกใช้ค่าขอบล่างของช่วงความเชื่อมั่นที่ระดับความเชื่อมั่นที่ 99% (0.7708) เป็นค่าขอบเขตในการจัดจำแนกข้อมูล ให้ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่น้อยที่สุดที่ 0.1540 ดังนั้นจึงเลือกใช้ค่าดังกล่าวเป็นค่าขอบเขตในการจัดจำแนกข้อมูลของแบบจำลองการถดถอยโลจิสติกแบบทวินามเพื่อใช้ในการตรวจจับการทำงานที่ผิดพลาดของแท้จริง



รูปที่ 3.6 วิธีการคำนวณหาค่าความผิดพลาดของโอกาสที่แท้จริงจะทำงานผิดพลาด

ตารางที่ 3.9 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 80%

ชุดข้อมูลที่ (i)	โอกาสที่แท้จริงจะทำงานผิดพลาด ณ ตำแหน่งที่ผิดพลาดแท้จริง (ActDProb)	AEADP _i (ActDProb - 0.8172)
1	0.7124	0.1048
3	0.6228	0.1944
4	0.7225	0.0947
5	0.7111	0.1061
7	0.4255	0.3917
9	0.6126	0.2046
10	0.6507	0.1665
11	0.3475	0.4697
12	0.9377	0.1205
13	0.7959	0.0213
14	0.8044	0.0128
16	0.4535	0.3637
17	0.8684	0.0512
MAEADP		0.1771

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.10 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 85%

ชุดข้อมูลที่ (i)	โอกาสที่แท้จริงจะทำงานผิดปกติ ณ ตำแหน่งที่ผิดปกติแท้จริง (ActDProb)	AEADP _i (ActDProb - 0.8123)
1	0.7124	0.0997
3	0.6228	0.1895
4	0.7225	0.0898
5	0.7111	0.1012
7	0.4255	0.3868
9	0.6126	0.1997
10	0.6507	0.1616
11	0.3475	0.4648
12	0.9377	0.1254
13	0.7959	0.0164
14	0.8044	0.0079
16	0.4535	0.3588
17	0.8684	0.0561
MAEADP		0.1737

ตารางที่ 3.11 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 90%

ชุดข้อมูลที่ (i)	โอกาสที่แท้จริงจะทำงานผิดปกติ ณ ตำแหน่งที่ผิดปกติแท้จริง (ActDProb)	AEADP _i (ActDProb - 0.8056)
1	0.7124	0.0932
3	0.6228	0.1828
4	0.7225	0.0831
5	0.7111	0.0945
7	0.4255	0.3801
9	0.6126	0.1930
10	0.6507	0.1549
11	0.3475	0.4581
12	0.9377	0.1321
13	0.7959	0.0097
14	0.8044	0.0012
16	0.4535	0.3521
17	0.8684	0.0628
MAEADP		0.1690

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.12 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 95%

ชุดข้อมูลที่ (i)	โอกาสที่แท้จริงจะทำงานผิดปกติ ณ ตำแหน่งที่ผิดปกติแท้จริง (ActDProb)	AEADP _i (ActDProb – 0.7948)
1	0.7124	0.0824
3	0.6228	0.1720
4	0.7225	0.0723
5	0.7111	0.0837
7	0.4255	0.3693
9	0.6126	0.1822
10	0.6507	0.1441
11	0.3475	0.4473
12	0.9377	0.1429
13	0.7959	0.0011
14	0.8044	0.0096
16	0.4535	0.3413
17	0.8684	0.0736
MAEADP		0.1632

ตารางที่ 3.13 ค่าเฉลี่ยสมบูรณ์ของความคลาดเคลื่อนของโอกาสที่ระดับความเชื่อมั่นที่ 99%

ชุดข้อมูลที่ (i)	โอกาสที่แท้จริงจะทำงานผิดปกติ ณ ตำแหน่งที่ผิดปกติแท้จริง (ActDProb)	AEADP _i (ActDProb – 0.7708)
1	0.7124	0.0584
3	0.6228	0.1480
4	0.7225	0.0483
5	0.7111	0.0597
7	0.4255	0.3453
9	0.6126	0.1582
10	0.6507	0.1201
11	0.3475	0.4233
12	0.9377	0.1669
13	0.7959	0.0251
14	0.8044	0.0336
16	0.4535	0.3173
17	0.8684	0.0976
MAEADP		0.1540

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.7 การลดความแปรปรวนของผลการตรวจจับความผิดปกติในการทำนาย

เมื่อกำหนดขอบเขตของโอกาสที่แปร็งจะทำงานผิดปกติได้แล้ว จะเป็นขั้นตอนการทดสอบแบบจำลองที่ได้พัฒนาขึ้น เพื่อสังเกตความแปรปรวนของผลการทำนายที่ได้จากแบบจำลอง ด้วยชุดข้อมูลทดสอบที่ 1 ซึ่งสามารถแสดงได้ดังรูปที่ 3.7 จะเห็นว่าค่าโอกาสที่แปร็งทำงานผิดปกติที่ได้จากแบบจำลองยังมีความความแปรปรวนอยู่มาก ทำให้ยากแก่การการตีความหมาย ดังนั้นเพื่อลดความแปรปรวนที่เกิดขึ้นจึงใช้วิธีการเฉลี่ยค่าของโอกาสที่แปร็งจะทำงานผิดปกติ ด้วยวิธีการปรับความราบเรียบของ Savitzky-Golay ซึ่งคำนวณได้จากสมการที่ 2.21



รูปที่ 3.7 ค่าโอกาสที่แปร็งจะทำงานผิดปกติที่ได้จากแบบจำลองที่ได้พัฒนาขึ้น ที่ทดสอบด้วยชุดข้อมูลที่ 1

สำหรับการเลือกช่วงขนาดของหน้าต่างในการเฉลี่ย จะการพิจารณาจากช่วงเวลาที่ยาวที่สุดที่เกิดความผิดปกติขึ้นดังแสดงในตารางที่ 3.1 โดยขนาดของหน้าต่างในการเฉลี่ยไม่ควรมีความกว้างกว่าช่วงเวลาน้อยที่สุดที่ยาวที่สุดที่เกิดความผิดปกติ ซึ่งชุดข้อมูลที่ 14 มีค่าช่วงเวลาที่แปร็งเริ่มเกิดความผิดปกติที่น้อยที่สุดที่ 210 วินาที (21 จุดข้อมูล) หลังจากเริ่มบันทึกข้อมูล ดังนั้นจึงเลือกช่วงของขนาดหน้าต่างในการเฉลี่ยสำหรับทดสอบตั้งแต่ 3-19 จุดข้อมูล และเลือกใช้การประมาณด้วยพหุนามกำลัง 0-5 เพื่อไม่ให้เกิดการเฉลี่ยมีความซับซ้อนเกินไป โดยที่การเฉลี่ยด้วยชุดพารามิเตอร์การเฉลี่ยใดให้ค่าผลรวมความคลาดเคลื่อนสมบูรณ์ระหว่างค่าเฉลี่ย กับค่าโอกาสที่แปร็งทำงานผิดปกติที่ได้จากแบบจำลองที่มีค่ามากที่สุด จะถูกเลือกใช้เป็นการปรับความราบเรียบด้วยวิธีของ Savitzky-Golay ให้กับอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแปร็งที่ได้พัฒนาขึ้น โดยผลการทดสอบได้แสดงดังตารางที่ 3.14 ซึ่งพบว่าการเฉลี่ยค่าโอกาสที่แปร็งจะทำงานผิดปกติด้วยขนาดหน้าต่างในการเฉลี่ยเท่ากับ 19 จุดข้อมูล และใช้การประมาณค่าเฉลี่ยด้วยพหุนามกำลัง 0 ให้ค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์ในการเฉลี่ยที่มากที่สุด ดังนั้นจึงเลือกใช้ค่าพารามิเตอร์ดังกล่าวเป็นเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต

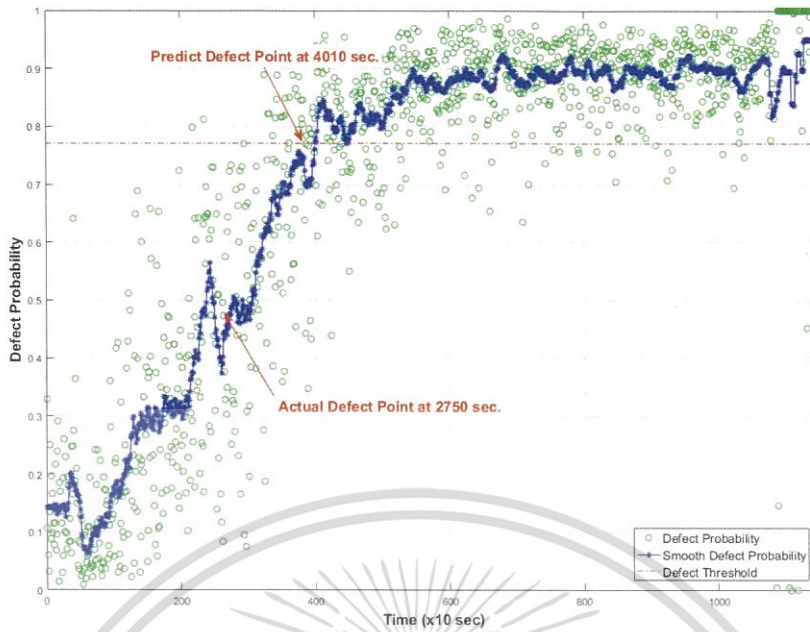
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พารามิเตอร์ในการปรับความราบเรียบของอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งที่ได้พัฒนาขึ้น ซึ่งผลลัพธ์ที่ได้จากการเฉลี่ยด้วยพารามิเตอร์การเฉลี่ยชุดดังกล่าวที่ทดสอบด้วยชุดข้อมูลที่ 4 ได้แสดงดังรูปที่ 3.8

ตารางที่ 3.14 แสดงค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์ของการเฉลี่ยด้วยวิธี Savitzky-Golay ที่พารามิเตอร์การเฉลี่ยค่าต่างๆ

พหุนามกำลัง	ขนาดหน้าต่าง	ค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์	พหุนามกำลัง	ขนาดหน้าต่าง	ค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์
0	3	0.035043	3	5	0.030771
	5	0.037104		7	0.033340
	7	0.038184		9	0.034794
	9	0.038942		11	0.035803
	11	0.039536		13	0.036599
	13	0.040009		15	0.037225
	15	0.040397		17	0.037746
	17	0.040712		19	0.038195
		19		0.040970	5
1	3	0.034957	4	7	0.014163
	5	0.037045		9	0.020635
	7	0.038126		11	0.024446
	9	0.038880		13	0.026975
	11	0.039472		15	0.028842
	13	0.039932		17	0.030273
	15	0.040305		19	0.031411
	17	0.040609		7	0.028289
		19		0.040866	9
2	3	0.000000	5	11	0.032539
	5	0.015408		13	0.033674
	7	0.022263		15	0.034552
	9	0.026167		17	0.035249
	11	0.028711		19	0.035826
	13	0.030557			
	15	0.031958			
	17	0.033083			
		19		0.034010	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่บนสื่อออนไลน์
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.8 ค่าโอกาสที่แท้จริงทำงานผิดปกติของชุดข้อมูลที่ 4 ที่ผ่านการปรับความราบเรียบด้วยวิธีของ Savitzky-Golay ด้วยขนาดความกว้างของหน้าต่างในการเฉลี่ยเท่ากับ 19 จุดข้อมูล และประมาณค่าเฉลี่ยด้วยพหุนามกำลัง 0

บทที่ 4


ทดสอบระบบตรวจจับความผิดปกติในการทำงานของแบริ่ง

4.1 บทนำ

ในบทนี้กล่าวขั้นตอนการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งที่ได้พัฒนาขึ้น ด้วยชุดข้อมูลการสั่นสะเทือนชุดที่ 2, 6, 8 และชุดที่ 15 ซึ่งครอบคลุมเงื่อนไขในการทำงานทั้ง 3 เงื่อนไข (ความเร็วในการหมุน 1,800 rpm ภาระงาน 4,000 N, ความเร็วในการหมุน 1,650 rpm ภาระงาน 4,200 N และที่ความเร็วในการหมุน 1,500 rpm ภาระงาน 5,000 N) โดยที่ช่วงเวลาที่แบริ่งเริ่มเกิดความผิดปกติของทั้ง 4 ชุดข้อมูลที่ใช้ในการทดสอบอยู่ในช่วง 500 วินาที จนถึง 1,530 วินาที ทำให้การตรวจจับเป็นไปได้ยากยิ่งขึ้น และในการทดสอบประสิทธิภาพการตรวจจับความผิดปกติของอัลกอริทึมจะพิจารณาจากดัชนีชี้วัดประสิทธิภาพในการตรวจจับความผิดปกติในการทำงานของแบริ่งต่างๆ ที่กำหนดขึ้น และในส่วนท้ายของบทนี้ เป็นส่วนการสรุปผลการทดสอบอัลกอริทึมสำหรับตรวจจับความผิดปกติในการทำงานของแบริ่ง

4.2 การทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง

กระบวนการในการทดสอบอัลกอริทึมสำหรับตรวจจับความผิดปกติในการทำงานของแบริ่ง (Early Fault Detection Model, EFD) แบ่งได้เป็น 4 ขั้นตอนหลัก ดังแสดงในรูปที่ 4.1 โดยเริ่มจากนำข้อมูลการสั่นสะเทือนที่บันทึกได้มาทำการจัดเตรียมให้อยู่ในรูปแบบที่เหมาะสม ในกระบวนการประมวลผลสัญญาณขั้นต้น จากนั้นสกัดคุณลักษณะสำคัญทั้ง 3 ชนิด (Wavelet Packet Decomposition Node Energy, Crest Factor และ Kurtosis) ออกจากสัญญาณการสั่นสะเทือนที่ใช้ในการทดสอบอัลกอริทึม ต่อจากนั้นใช้ค่าคุณลักษณะสำคัญที่สกัดได้เป็นข้อมูลในการตรวจจับความผิดปกติในการทำงานของแบริ่ง และในขั้นตอนสุดท้ายจะเป็นส่วนในการประเมินประสิทธิภาพในการตรวจจับความผิดปกติของอัลกอริทึม โดยพิจารณาจากดัชนีชี้วัดประสิทธิภาพในการตรวจจับความผิดปกติในการทำงานของแบริ่ง ซึ่งจะได้กล่าวถึงในลำดับถัดไป

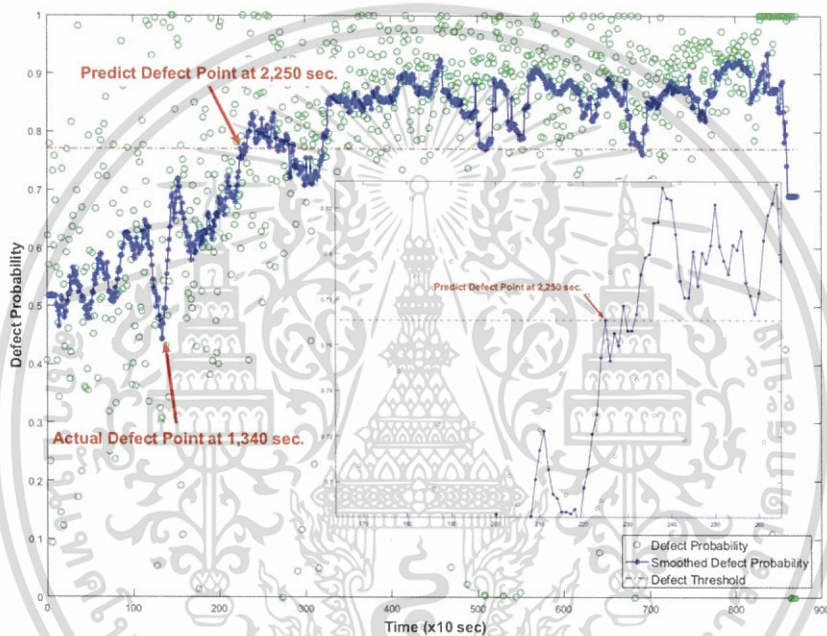


รูปที่ 4.1 ขั้นตอนการทดสอบอัลกอริทึมสำหรับตรวจจับการทำงานที่ผิดปกติของแบริ่ง

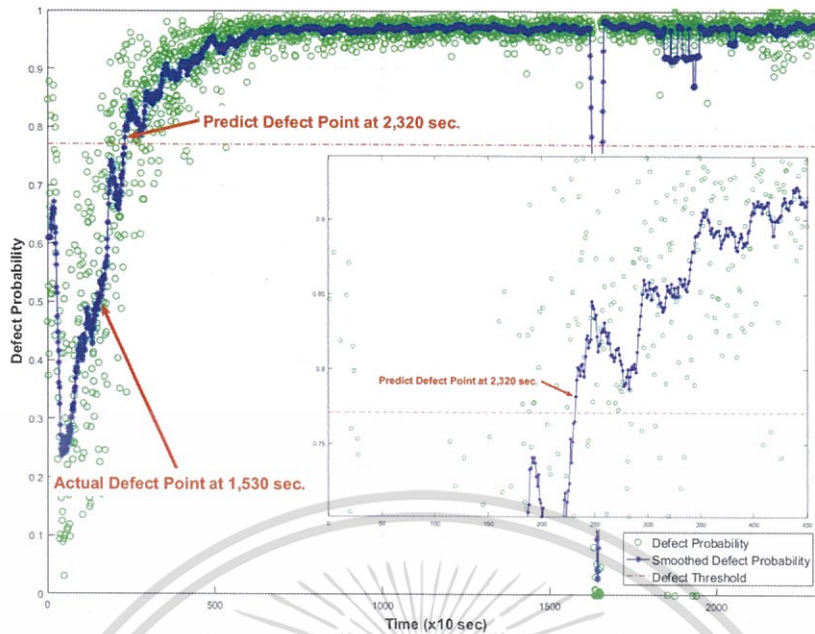
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.1 การประเมินสภาพความสมบูรณ์ของแบริ่ง

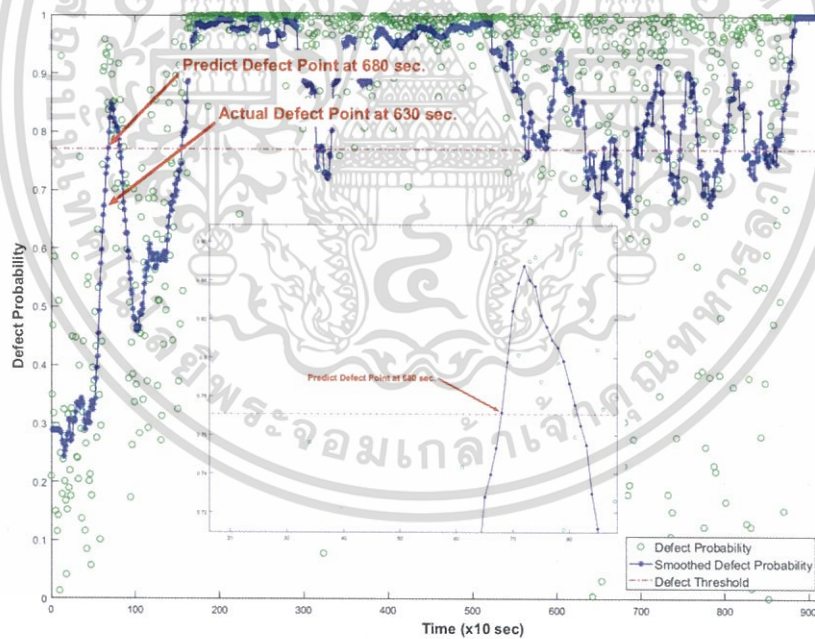
ในการประเมินสภาพความสมบูรณ์ของแบริ่ง จะอาศัยค่าคุณลักษณะสำคัญทั้ง 3 ชนิดเป็นข้อมูลในการทำนายโอกาสที่แบริ่งจะทำงานผิดปกติ จากนั้นจะใช้ค่าโอกาสดังกล่าวในการประเมินสภาพความสมบูรณ์ของแบริ่ง โดยค่าเฉลี่ยของโอกาสที่แบริ่งทำงานผิดปกติตำแหน่งแรกที่มีค่าสูงกว่าค่าขอบเขตที่ใช้ในการจัดจำแนกประเภทข้อมูลหรือขอบเขตที่แบริ่งทำงานในสถานะที่ผิดปกติ ณ ตำแหน่งเวลาดังกล่าวจะถูกระบุให้สภาพความสมบูรณ์ของแบริ่งอยู่ในสถานะที่แบริ่งทำงานผิดปกติ จากรูปที่ 4.2 - 4.5 เป็นผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ด้วยชุดข้อมูลทดสอบที่ 2, 6, 8 และชุดข้อมูลที่ 15 โดยตำแหน่งเวลาที่อัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งที่เกิดขึ้น (Predict Defect Point) ได้แสดงในตารางที่ 4.1



รูปที่ 4.2 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ด้วยชุดข้อมูลที่ 2

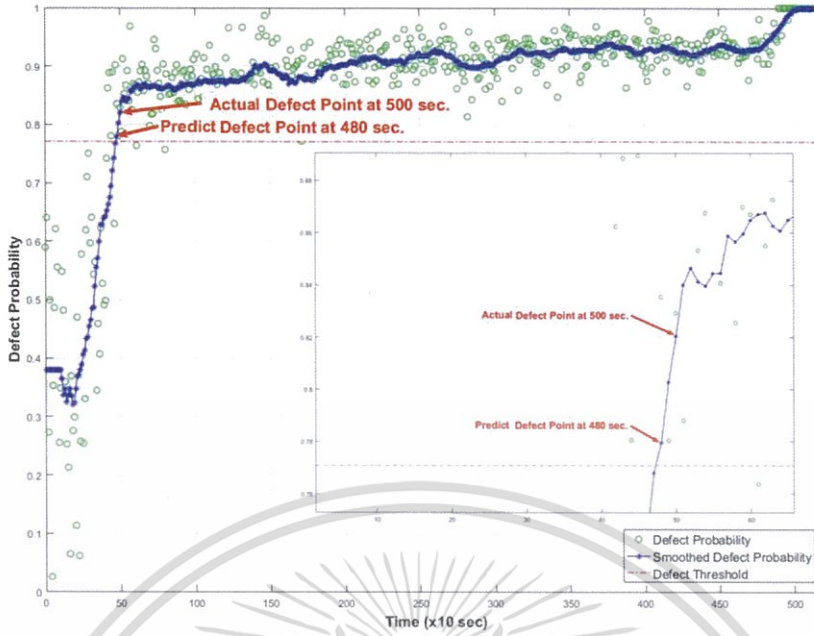


รูปที่ 4.3 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ด้วยชุดข้อมูลที่ 6



รูปที่ 4.4 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ด้วยชุดข้อมูลที่ 8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.5 ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบร็ง ด้วยชุดข้อมูลที่ 15

ตารางที่ 4.1 ผลการทดสอบอัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของแบร็ง

ชุดข้อมูลที่	อายุการทำงาน (Life Time)	ช่วงเวลาที่แบร็งเกิดความผิดปกติแท้จริง (Actual Defect Point)	ช่วงเวลาที่ระบบตรวจจับความผิดปกติได้ (Predict Defect Point)
2	8,710 sec.	1,340 sec.	2,250 sec.
6	24,480 sec.	1,530 sec.	2,320 sec.
8	9,110 sec.	630 sec.	680 sec.
15	5,150 sec.	500 sec.	480 sec.

4.2.2 ค่าเปอร์เซ็นต์ความถูกต้องของการจัดจำแนก

ค่าเปอร์เซ็นต์ความถูกต้องของการจัดจำแนก (Percentage Classification Accuracy, PCA) เป็นค่าที่บ่งชี้ถึงความถูกต้องในการจัดจำแนกข้อมูล โดยที่ค่าโอกาสที่แบร็งทำงานผิดปกติค่าใดที่มีค่าเกินกว่าค่าขอบเขตที่แบร็งทำงานผิดปกติ จะถูกกำหนดให้ตำแหน่งดังกล่าวเป็นตำแหน่งที่แบร็งทำงานผิดปกติ ซึ่งสามารถแสดงเป็นสมการทางคณิตศาสตร์ได้ดังสมการที่ 4.1

$$PCA = \left(1 - \left(\frac{1}{N} \left(\sum_{i=1}^N |y_i - T_i| \right) \right) \right) \times 100\% \quad (4.1)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่	PCA	คือ ค่าเปอร์เซ็นต์ความถูกต้องของการจัดจำแนก
	N	คือ จำนวนข้อมูล
	y_i	คือ ค่าโอกาสที่แท้จริงจะทำงานผิดพลาด มีค่าเท่ากับ 1 เมื่อ y_i มีค่ามากกว่าขอบเขตที่แท้จริงจะทำงานผิดพลาด และมีค่าเท่ากับ 0 เมื่อ y_i มีค่าน้อยกว่าค่าขอบเขตที่แท้จริงจะทำงานผิดพลาด
	T_i	คือ ค่าโอกาสจริงที่แท้จริงจะทำงานผิดพลาด มีค่าเท่ากับ 1 เมื่อแท้จริงทำงานผิดพลาด และเท่ากับ 0 เมื่อแท้จริงทำงานปกติ

4.2.3 ความคลาดเคลื่อนสมบูรณ์และค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์

ค่าความคลาดเคลื่อนสมบูรณ์ (Absolute Error, AE) เป็นปริมาณที่บ่งบอกถึงความคลาดเคลื่อนในการจัดจำแนกข้อมูล โดยใช้ค่าโอกาสที่แท้จริงทำงานผิดพลาดเทียบกับค่าโอกาสที่แท้จริงจะทำงานผิดพลาด ณ ตำแหน่งที่ถูกระบุว่าเป็นตำแหน่งที่แท้จริงเริ่มเกิดความผิดพลาดขึ้น สามารถแสดงได้ดังสมการที่ 4.2 และค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์ (Mean Absolute Error, MAE) สามารถแสดงได้ดังสมการที่ 4.3

$$AE_i = |DP_i - T_i| \quad (4.2)$$

$$MAE = \frac{1}{N} \left(\sum_{i=1}^N AE_i \right) \quad (4.3)$$

โดยที่	AE_i	คือ ค่าความคลาดเคลื่อนสมบูรณ์ ณ ข้อมูลที่ i
	DP_i	คือ ค่าโอกาสที่แท้จริงทำงานผิดพลาด ณ ข้อมูลที่ i
	T_i	คือ ค่าโอกาสที่แท้จริงทำงานผิดพลาด ณ ตำแหน่งที่ถูกระบุให้เป็นตำแหน่งที่แท้จริงเริ่มเกิดความผิดพลาดของชุดข้อมูลที่ i
	MAE	คือ ค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์
	N	คือ จำนวนข้อมูล

4.2.4 ความเบี่ยงเบนมาตรฐานของความคลาดเคลื่อนสมบูรณ์

ค่าเบี่ยงเบนมาตรฐานของความคลาดเคลื่อนสมบูรณ์ (Standard Deviation of Absolute Error, SDAE) เป็นปริมาณที่บ่งบอกถึงการกระจายตัวของความคลาดเคลื่อนสมบูรณ์รอบๆ ค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์ สามารถแสดงได้ดังสมการที่ 4.4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$SDAE = \sqrt{\frac{1}{N-1} \left(\sum_{i=1}^N (AE_i - MAE)^2 \right)} \quad (4.4)$$

โดยที่	SDAE	คือ ค่าเบี่ยงเบนมาตรฐานของความคลาดเคลื่อนสมบูรณ์
	AE_i	คือ ค่าความคลาดเคลื่อนสมบูรณ์ ณ ข้อมูลที่ i
	MAE	คือ ค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์
	N	คือ จำนวนข้อมูล

4.2.5 ความเชื่อถือได้ในการตรวจจับความผิดปกติในการทำงานของแบริ่ง

ความเชื่อถือได้ในการตรวจจับความผิดปกติในการทำงานของแบริ่งเป็นปัจจัยที่มีความสำคัญอย่างยิ่ง โดยอัลกอริทึมตรวจจับความผิดปกติที่ดีจะต้องสามารถตรวจจับความผิดปกติที่เกิดขึ้นใกล้เคียงกันกับตำแหน่งที่ถูกระบุว่าเป็นตำแหน่งที่เกิดความผิดปกติขึ้น ช่วยให้ผู้ปฏิบัติงานสามารถเตรียมพร้อมรับมือกับปัญหาที่จะเกิดขึ้นในอนาคตได้ ความเชื่อถือได้ของการตรวจจับจะใช้ดัชนีชี้วัดประสิทธิภาพในการทำนาย (Prediction Performance Index, PPI) เป็นปริมาณในการพิจารณาประสิทธิภาพของอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ซึ่งสามารถคำนวณได้จากสมการที่ 4.5

$$PPI = \left(1 - \frac{(LT - \text{ActualDefP}) - (LT - \text{PredictDefP})}{LT - \text{ActualDefP}} \right) \times 100\% \quad (4.5)$$

โดยที่	PPI	คือ ดัชนีชี้วัดประสิทธิภาพในการทำนาย
	LT	คือ ระยะเวลาในการทำงานทั้งหมดของแบริ่ง (Lift Time)
	ActualDefP	คือ ช่วงเวลาที่แบริ่งเกิดความผิดปกติขึ้น (Actual Defect Point)
	PredictDefP	คือ อัลกอริทึมสามารถตรวจจับความผิดปกติที่เกิดขึ้นได้ (Predict Defect Point)

จากสมการที่ 4.5 ค่าดัชนีชี้วัดที่มุ่งหวังคือ 100% ซึ่งจะเกิดขึ้นได้ก็ต่อเมื่ออัลกอริทึมตรวจจับความผิดปกติที่เกิดขึ้นสามารถตรวจจับความผิดปกติที่เกิดขึ้นได้ ณ ตำแหน่งเวลาเดียวกันกับตำแหน่งเวลาที่ถูกระบุว่าเป็นจุดที่แบริ่งเริ่มเกิดความผิดปกติขึ้น (Predict Defect Point มีตำแหน่งเดียวกันกับ Actual Defect Point) ในกรณีที่อัลกอริทึมสามารถตรวจจับความผิดปกติได้ก่อนที่จะถึงจุดที่เกิดความผิดปกติขึ้น (Predict Defect Point ก่อนตำแหน่ง Actual Defect Point) ค่าดัชนีชี้วัดประสิทธิภาพในการตรวจจับความผิดปกติจะมีค่ามากกว่า 100% และในกรณีที่อัลกอริทึมสามารถเฝ้าระวังเป็นเอกสารที่ส่งมอบไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตรวจจับความผิดปกติที่เกิดขึ้นได้หลังจากที่ผ่านตำแหน่งที่ถูกระบุว่าเป็นตำแหน่งที่แบร์ริงเริ่มเกิดความผิดปกติขึ้น ค่าดัชนีชี้วัดประสิทธิภาพในการตรวจจับความผิดปกติจะมีค่าน้อยกว่า 100%

หลังจากทำการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบร์ริงที่ได้พัฒนาขึ้นด้วยชุดข้อมูลที่ 2, 4, 6, 8 และชุดข้อมูลที่ 15 ซึ่งสามารถแสดงผลของโอกาสที่แบร์ริงจะทำงานผิดปกติได้ดังที่แสดงในรูปที่ 4.2-4.5 จากนั้นทำการประเมินประสิทธิภาพของอัลกอริทึมด้วยตัวชี้วัดต่างๆ ซึ่งผลการประเมินประสิทธิภาพการตรวจจับความผิดปกติด้วยดัชนีชี้วัดต่างๆ สามารถแสดงได้ดังตารางที่ 4.2

ตารางที่ 4.2 ผลการประเมินประสิทธิภาพของอัลกอริทึมด้วยตัวชี้วัดต่างๆ

ชุดข้อมูลที่	PCA (%)	MAE	SDAE	PPI (%)
2	82.4340	0.2372	0.1534	87.6526
6	95.1781	0.0905	0.1372	96.5577
8	74.9726	0.1573	0.1319	99.4104
15	99.6117	0.1264	0.1270	100.0043

4.3 สรุปผลการทดสอบ

จากผลการทดสอบข้างต้นแสดงให้เห็นถึงประสิทธิภาพในการทำงานของอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบร์ริง ซึ่งการทดสอบอัลกอริทึมด้วยชุดข้อมูลที่ 15 ให้ผลลัพธ์ในการตรวจจับที่แม่นยำที่สุด โดยมีค่าเปอร์เซ็นต์ความถูกต้องในการคัดแยกข้อมูลที่ผิดปกติที่ 99.6117% ค่าความคลาดเคลื่อนเฉลี่ยสมบูรณ์ที่ 0.1264 ค่าเบี่ยงเบนมาตรฐานของความคลาดเคลื่อนสมบูรณ์ที่ 0.1270 และค่าดัชนีชี้วัดประสิทธิภาพในการทำนายที่ 100.0043% ซึ่งสามารถตรวจจับความผิดปกติได้ก่อนที่จะถึงตำแหน่งที่ถูกระบุว่าแบร์ริงเริ่มเกิดความผิดปกติขึ้นประมาณ 20 วินาที สำหรับในกรณีที่ทดสอบอัลกอริทึมด้วยชุดข้อมูลที่ 2 อัลกอริทึมสามารถตรวจจับความผิดปกติที่เกิดขึ้นได้หลังจากแบร์ริงเริ่มเกิดความผิดปกติขึ้นประมาณ 15 นาที 10 วินาที (สามารถตรวจจับความผิดปกติที่เกิดขึ้นได้ก่อนที่แบร์ริงจะเกิดความเสียหายและไม่สามารถทำงานต่อไปได้ประมาณ 1 ชั่วโมง 47 นาที 40 วินาที) ด้วยค่าดัชนีชี้วัดประสิทธิภาพในการตรวจจับ 87.6526% ซึ่งเป็นกรณีที่ให้ผลลัพธ์ในการตรวจจับความผิดปกติที่มีความแม่นยำน้อยที่สุด แต่ทว่าเมื่อพิจารณาค่าโอกาสที่แบร์ริงจะทำงานผิดปกติจากรูปที่ 4.2 จะสังเกตได้ว่าค่าโอกาสที่แบร์ริงทำงานผิดปกติมีแนวโน้มเพิ่มสูงขึ้นอย่างต่อเนื่องก่อนที่จะถึงขอบเขตที่แบร์ริงเริ่มทำงานผิดปกติ และหลังจากที่อัลกอริทึมสามารถตรวจจับความผิดปกติที่เกิดขึ้นได้แล้ว แบร์ริงยังสามารถทำงานต่อไปได้อีกระยะเวลาหนึ่ง (ประมาณ 1 ชั่วโมง 47 นาที 40 วินาที) ก่อนที่แบร์ริงจะเสียหายจนไม่สามารถทำงานต่อไปได้ ดังนั้นพนักงานซ่อมบำรุงจึงสามารถนำข้อมูลสำคัญดังกล่าวที่ได้จากอัลกอริทึมไปใช้ในการวิเคราะห์เพื่อรับมือกับปัญหาที่จะเกิดขึ้นได้อย่างทัน่วงที ช่วยป้องกันการหยุดทำงานกะทันหันของเครื่องจักรกลที่อยู่นอกเหนือแผนการซ่อมบำรุงได้

บทที่ 5

สรุปผลงานวิจัยและข้อเสนอแนะ

5.1 บทนำ

ในบทนี้เป็นบทสรุปการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง โดยกล่าวถึงวัตถุประสงค์และความสำคัญของการวิจัย ขั้นตอนการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่ง ผลการทดสอบอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งที่ได้พัฒนาขึ้น ตลอดจนเสนอแนวคิดที่สำคัญสำหรับการพัฒนาต่อยอดอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งเพื่อเพิ่มประสิทธิภาพให้อัลกอริทึม และการพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของแบริ่งไปสู่อัลกอริทึมการทำนายอายุการใช้งานคงเหลือของแบริ่งต่อไป

5.2 สรุปเนื้อหาของวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้ได้นำเสนออัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของแบริ่งตั้งแต่ระยะแรกเริ่ม โดยมีวัตถุประสงค์เพื่อใช้เป็นเครื่องมือในการตรวจจับความผิดปกติในการทำงานของแบริ่ง ซึ่งเป็นข้อมูลที่สำคัญยิ่งที่ช่วยให้เจ้าหน้าที่ซ่อมบำรุงรักษาเครื่องจักรกลสามารถวางแผนการซ่อมบำรุงรักษาได้อย่างเหมาะสม นอกจากนี้อัลกอริทึมตรวจจับการทำงานที่ผิดปกติของแบริ่งยังสามารถนำไปใช้เป็นส่วนขยายให้กับอัลกอริทึมทำนายอายุการใช้งานคงเหลือของแบริ่ง เพื่อตรวจจับความผิดปกติที่เกิดขึ้นก่อนที่จะทำการคำนวณหาอายุการใช้งานคงเหลือ ซึ่งช่วยลดการประมวลผลของอัลกอริทึมทำนายอายุการใช้งานของแบริ่งลงได้

อัลกอริทึมตรวจจับการทำงานที่ผิดปกติของแบริ่งที่ได้นำเสนอได้ออกแบบด้วยวิธีการวิเคราะห์สัญญาณการสั่นสะเทือนของแบริ่ง โดยเลือกสกัดคุณลักษณะสำคัญของสัญญาณทั้งบนโดเมนเวลา และบนโดเมนเวลา-ความถี่ ทั้งหมด 3 ชนิดด้วยกัน คือ Crest Factor, Kurtosis และ Wavelet Packet Decomposition Node Energy ที่ระดับความละเอียดในการแปลงในระดับที่ 5 โดยใช้ Daubechies40 เป็นเบสิสในการแปลง จากนั้นนำคุณลักษณะสำคัญทั้งหมดที่สกัดได้เป็นข้อมูลในการเรียนรู้เพื่อประมาณค่าตัวแปรต่างๆ ของแบบจำลองการถดถอยโลจิสติกแบบทวินาม เพื่อใช้เป็นเครื่องมือในการตรวจจับความผิดปกติที่เกิดขึ้นกับแบริ่ง โดยผลลัพธ์ที่ได้จากแบบจำลองการถดถอยโลจิสติกแบบทวินามสำหรับตรวจจับความผิดปกติของแบริ่ง คือ ค่าโอกาสที่แบริ่งทำงานในสภาวะปกติ และค่าโอกาสที่แบริ่งทำงานในสภาวะที่ผิดปกติ โดยใช้ค่าโอกาสที่แบริ่งทำงานในสภาวะที่ผิดปกติที่ผ่านการปรับความราบเรียบด้วยวิธีของ Savitzky-Golay เป็นปริมาณที่ใช้ในการตรวจจับการทำงานที่ผิดปกติของแบริ่ง เมื่อใดก็ตามที่ค่าโอกาสที่แบริ่งทำงานที่สภาวะผิดปกติมีปริมาณเกินกว่าค่าขอบเขตในการจัดจำแนกข้อมูลของแบบจำลองการถดถอยโลจิสติกทวินาม (มีค่าขอบเขตการจัดจำแนกเท่ากับ 0.7708) ตำแหน่งดังกล่าวจะถูกระบุว่าเป็นตำแหน่งที่แบริ่งเกิดความผิดปกติขึ้น

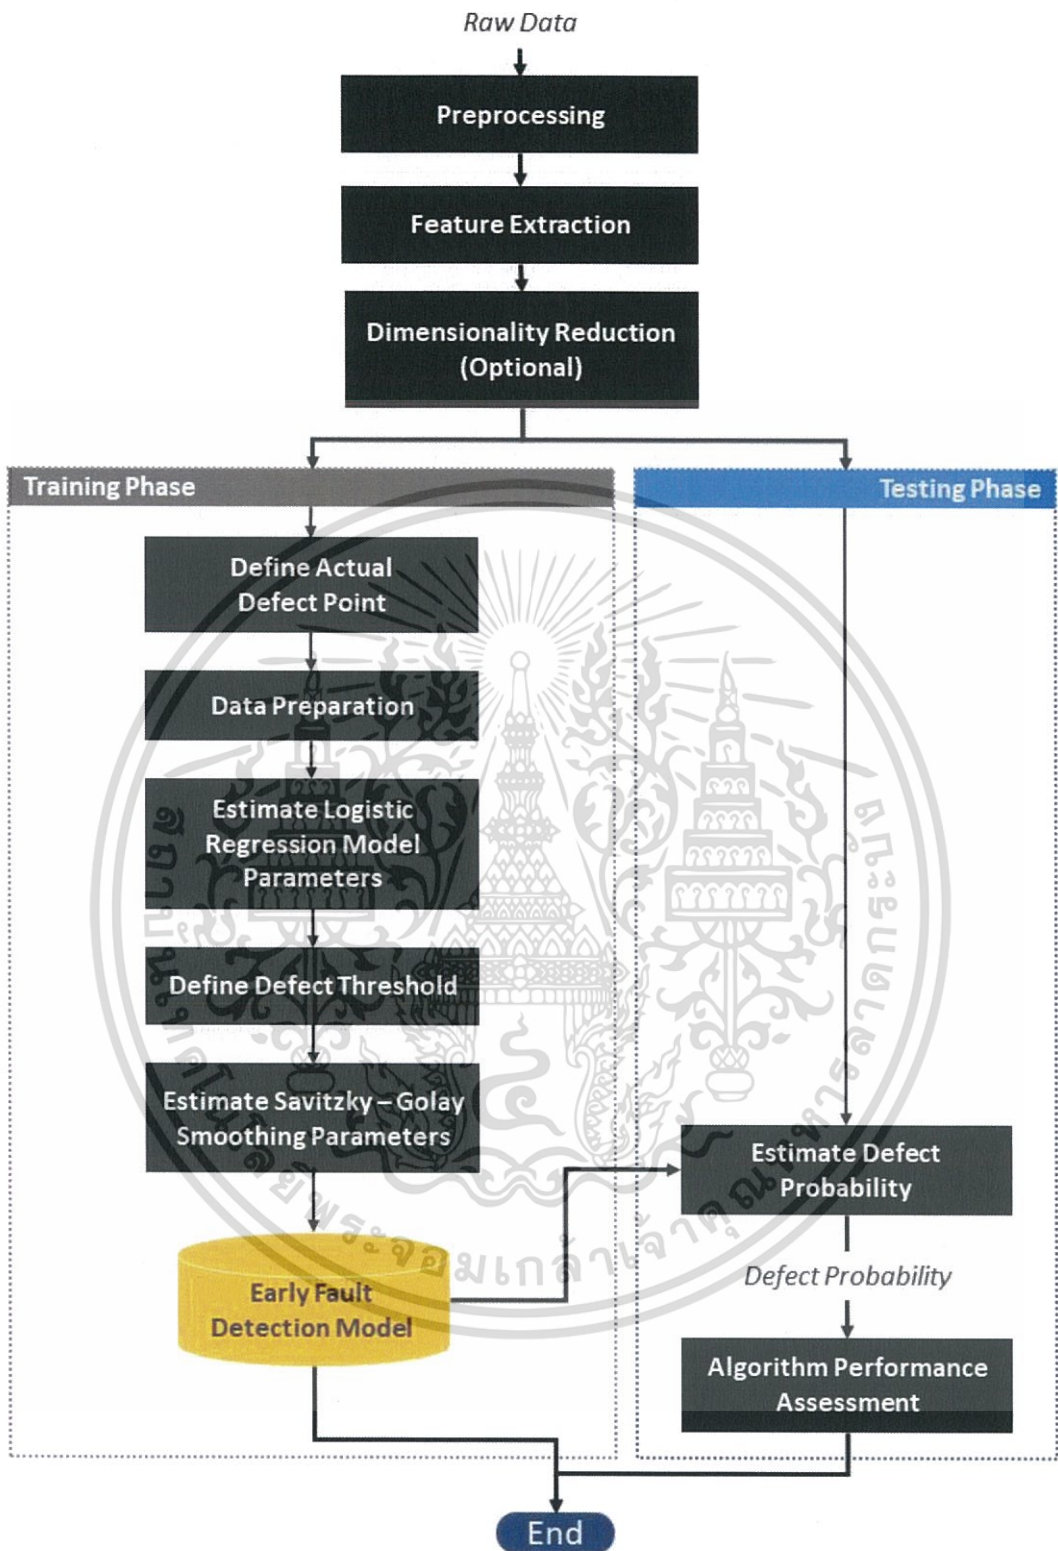
เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อใช้ในการศึกษาวิจัยเท่านั้น ไม่อนุญาตให้เผยแพร่หรือใช้ซ้ำโดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยสามารถสรุปขั้นตอนการทำงานของอัลกอริทึมตรวจสอบความผิดปกติในการทำงานของแบริ่งได้ดังรูปที่ 5.1 ต่อจากนั้นทำการประเมินประสิทธิภาพในการตรวจสอบความผิดปกติที่เกิดขึ้นกับแบริ่งด้วยอัลกอริทึมที่นำเสนอ โดยใช้ตัวชี้วัดทั้ง 4 ชนิด คือ ค่าเปอร์เซ็นต์ความแม่นยำในการตรวจสอบความผิดปกติ, ค่าเฉลี่ยความคลาดเคลื่อนสมบูรณ์, ค่าเบี่ยงเบนมาตรฐานของความคลาดเคลื่อนสมบูรณ์ และค่าดัชนีชี้วัดประสิทธิภาพในการทำงาน โดยพบว่าการทดสอบอัลกอริทึมด้วยชุดข้อมูลที่ 15 อัลกอริทึมตรวจสอบความผิดปกติในการทำงานของแบริ่งมีประสิทธิภาพในการตรวจจับที่ดีที่สุด โดยมีค่าเปอร์เซ็นต์ความถูกต้องในการคัดแยกข้อมูลที่ผิดปกติที่ 99.6117% ค่าความคลาดเคลื่อนเฉลี่ยสมบูรณ์ที่ 0.1264 ค่าเบี่ยงเบนมาตรฐานของความคลาดเคลื่อนสมบูรณ์ที่ 0.1270 และค่าดัชนีชี้วัดประสิทธิภาพในการทำงานที่ 100.0043% ซึ่งสามารถตรวจจับความผิดปกติได้ก่อนที่จะถึงจุดที่ถูกระบุว่าแบริ่งเกิดความผิดปกติ (ก่อนจุด Actual Defect) ประมาณ 20 วินาที และการทดสอบอัลกอริทึมด้วยชุดข้อมูลที่ 2 เป็นการทดสอบที่ให้ผลการตรวจจับที่มีความแม่นยำน้อยที่สุด โดยที่อัลกอริทึมสามารถตรวจจับความผิดปกติที่เกิดขึ้นได้หลังจากที่แบริ่งเริ่มเกิดความผิดปกติขึ้นประมาณ 15 นาที 10 วินาที (สามารถตรวจจับความผิดปกติที่เกิดขึ้นได้ก่อนที่แบริ่งจะเสียหายและไม่สามารถทำงานต่อไปได้ประมาณ 1 ชั่วโมง 47 นาที 40 วินาที) ด้วยค่าดัชนีชี้วัดประสิทธิภาพ 87.6526%

ดังนั้นจะเห็นว่าอัลกอริทึมตรวจสอบความผิดปกติในการทำงานของแบริ่งตั้งแต่ระยะแรกเริ่มสามารถนำไปใช้เป็นเครื่องมือในการทำงานโอกาสที่แบริ่งจะทำงานผิดปกติได้ ช่วยให้เจ้าหน้าที่บำรุงรักษาเครื่องจักรกลสามารถนำข้อมูลที่เป็นประโยชน์เหล่านี้ที่ได้จากการทำนายไปใช้ในการวางแผนการซ่อมบำรุงได้อย่างเหมาะสมต่อไป

5.3 ข้อเสนอแนะในการพัฒนางานวิจัย

อัลกอริทึมในการตรวจจับความผิดปกติในการทำงานของแบริ่งที่ได้แนะนำเสนอนี้ ได้รับการพัฒนาผ่านการวิเคราะห์ชุดข้อมูลการสั่นสะเทือนที่ได้จากการทดสอบแบริ่งจำนวน 17 ชุดข้อมูล โดยใช้ 13 ชุดข้อมูลในการเรียนรู้ เพื่อหาค่าพารามิเตอร์ที่สำคัญของอัลกอริทึม ดังนั้นจะเห็นว่าในการพัฒนาอัลกอริทึมตรวจสอบความผิดปกตินี้ต้องการชุดข้อมูลสำหรับการเรียนรู้จำนวนมาก ทำให้เกิดความสิ้นเปลืองทั้งเวลา และเงินทุน ในการพัฒนาอัลกอริทึม เพื่อเป็นการปรับปรุงจุดบกพร่องดังกล่าว จึงควรค่าอย่างยิ่งในการปรับปรุงอัลกอริทึมให้สามารถปรับค่าพารามิเตอร์ที่สำคัญของอัลกอริทึมให้ได้ค่าที่เหมาะสม โดยอาศัยข้อมูลในการเรียนรู้ที่น้อยลง โดยอาจใช้วิธีการวิเคราะห์องค์ประกอบ (Factor Analysis) เช่น การวิเคราะห์องค์ประกอบสำคัญ (Principle Component Analysis) กับชุดคุณลักษณะสำคัญที่ใช้ในการเรียนรู้ของอัลกอริทึม เพื่อให้สามารถคัดแยกเฉพาะคุณลักษณะที่สำคัญยิ่งต่อการตรวจจับความผิดปกติในการทำงานของแบริ่ง ซึ่งวิธีการดังกล่าวนี้ช่วยลดจำนวนตัวแปรต้นของแบบจำลองตรวจจับความผิดปกติลงได้เป็นอย่างมาก ทำให้แบบจำลองที่ได้มีความซับซ้อนน้อยลง ลดการประมวลผลที่ไม่จำเป็น และยังสามารถคงประสิทธิภาพในการตรวจจับความผิดปกติไว้ได้



รูปที่ 5.1 ภาพรวมอัลกอริทึมตรวจจับความผิดปกติในการทำงานของเครื่อง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] Gandhare, B.S. and Akarte, M. 2012. Maintenance Strategy Selection. *Ninth AIMS International Conference on Management* (2012), 1330–1336.
- [2] Thor, J. et al. 2013. Comparison of Multi Criteria Decision Making Methods From The Maintenance Alternative Selection Perspective. *International Journal Of Engineering And Science (IJES)*. 2, 6 (2013), 27–34.
- [3] Sankararaman, S. 2015. Remaining Useful Life Prediction through Failure Probability Computation for Condition-based Prognostics. *Annual Conference of the Prognostics and Health Management Society 2015* (2015), 1–8.
- [4] Tobon-Mejia, D. et al. 2010. A Mixture of Gaussians Hidden Markov Model for Failure Diagnostic and Prognostic. *2010 IEEE International Conference on Automation Science and Engineering, CASE 2010* (2010), 338–343.
- [5] Kurse, S. et al. 2013. Multi step ahead prognosis of bearing signals using NARX network. *International Journal of Innovative Research in Science, Engineering and Technology*. 2, 9 (2013), 4759–4767.
- [6] Satishkumar, R. and Sugumaran, V. 2016. Vibration based Health Assessment of Bearings using Random Forest Classifier. *Indian Journal of Science and Technology*. 9, 10 (2016).
- [7] Hu, C. et al. 2010. Ensemble of data-driven prognostic algorithms with weight optimization and k-fold cross validation. *ASME 2010 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference* (2010), 1023–1032.
- [8] Patidar, S. and Soni, P.K. 2013. An Overview on Vibration Analysis Techniques for the Diagnosis of Rolling Element Bearing Faults. *International Journal of Engineering Trends and Technology (IJETT)*. 4, 5 (2013), 1804–1809.
- [9] Devendiran, S. and Manivannan, K. 2016. Vibration based condition monitoring and fault diagnosis technologies for bearing and gear components-A review. *International Journal of Applied Engineering Research*. 11, 6 (2016), 3966–3975.
- [10] Kharche, P.P. and Kshirsagar, S. V 2014. Review of Fault Detection in Rolling Element Bearing. *International Journal of Innovative Research in Advanced Engineering*. 1, 5 (2014), 169–174.
- [11] Nabhan, A. et al. 2015. Bearing Fault Detection Techniques - A Review. (2015).
- [12] Jammu, N.S. and Kankar, P.K. 2011. A Review on Prognosis of Rolling Element Bearings. *International Journal of Engineering Science and Technology*. 3, 10 (2011), 7497–7503.

[13] Lacey, S.J. 2008. An Overview of Bearing Vibration Analysis. *Maintenance and*
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Asset Management*. 23, 6 (2008), 32–42.
- [14] Graney, B.P. and Starry, K. 2012. Rolling Element Bearing Analysis. *Materials Evaluation*. 70, 1 (2012), 78–85.
- [15] Kruger, W. 2009. Tracking rolling element bearing failures using mechanical and electrical vibration testing methods. ALL-TEST Pro.
- [16] Bearing and Shaft: <https://vibralign.com>.
- [17] Nectoux, P. et al. 2012. PRONOSTIA: An Experimental Platform for Bearings Accelerated Life Test. *IEEE International Conference on Prognostics and Health Management* (2012).
- [18] Kankar, P.K. et al. 2011. Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*. 38, 3 (2011), 1876–1886.
- [19] Lee, H.H. et al. 2007. Bearing fault diagnosis using fuzzy inference optimized by neural network and genetic algorithm. *Journal of Electrical Engineering & Technology*. 2, 3 (2007), 353–357.
- [20] Brkovic, A. et al. 2015. Early fault detection and diagnosis in bearings based on logarithmic energy entropy and statistical pattern recognition. *2nd International Electronic Conference on Entropy and Its Applications* (2015), 1–14.
- [21] Rai, A. and Upadhyay, S.H. 2016. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings. *Tribology International*. 96, (2016), 289–306.
- [22] Yan, W. et al. 2008. Feature Extraction for Bearing Prognostics and Health Management (PHM)– a Survey. *Air Force Research Laboratory* (2008).
- [23] Ngui, W.K. et al. 2013. Wavelet Analysis: Mother Wavelet Selection Methods. *Applied Mechanics and Materials*. 393, September 2013 (2013), 953–958.
- [24] Kumar, H.S. et al. 2014. Selection of Mother Wavelet for Effective Wavelet Transform of Bearing Vibration Signals. *Advanced Materials Research*. 1039, (2014), 169–176.
- [25] Wavelet Packet Decomposition Tree: <https://www.mathworks.com>.
- [26] Habib, M.R. et al. 2016. Mechanical fault detection and classification using pattern recognition based on bispectrum algorithm. *Sustainable Vital Technologies in Engineering and Informatics* (2016).
- [27] Savitzky, A. and Golay, M.J.E. 1964. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical chemistry*. 36, 8 (1964), 1627–1639.
- [28] Kaneko, H. et al. 2016. Practical Use of Savitzky-Golay Filtering-Based Ensemble Online SVR. *IFAC-PapersOnLine* (2016), 371–376.



ภาคผนวก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก
บทความที่ได้รับการตีพิมพ์



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Early Fault Detection based on Ball Bearing Vibration Analysis using Multinomial Logistic Regression

Thanadat Kersiri

Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand 10520
thanadat.kersiri.edu@gmail.com

Rutchanee Gullayanon

Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand 10520
rutchanee.gu@kmitl.ac.th

ABSTRACT

Rotating machines play an important role in several applications such as transportation, industry and military. Maintaining continuous operations of these machines is vital to these applications. The reliability of these rotating machines depends on ball bearing health. Bearing can fail from many factors, e.g., impurity of lubricant, improper installation, etc. All of these defects can be detected by vibration analysis. Therefore, vibration signals are utilized to develop early fault detection of ball bearing to warn operators of any anomalies in the system. This paper presents a fault detection algorithm using a logistic regression method to assess the health state of the system. This regression utilizes the node energy of wavelet packet decomposition, kurtosis and crest factor as key features. The resulting signals are processed using the Savitzky-Golay smoothing algorithm before determining the time location where the defects occur with a confidence interval of 99%. The proposed method was tested with actual vibration data of bearing which were provided by the FEMTO-ST institute and showed that it is capable of accurately predicting defect time only 10 seconds after the actual defect occurred. The worst-case prediction of 970 seconds after defect occurs also observed during experiment. Although the system did not set off alarm for fault detection after 970 seconds, one can observe an increase in the fault probability trends in early state. Therefore, the proposed algorithm can be utilized for early fault detection in ball bearing applications.

CCS Concepts

- Computing methodologies~Model development and analysis
- Computing methodologies~Planning and scheduling
- Computing methodologies~Simulation types and techniques

Keywords

Fault detection, intelligent diagnostic system, machine reliability, fault diagnostic, prognostic health management, predictive model.

1. INTRODUCTION

Rotating machines play a critical role in several applications such as transportation, manufacturing, military etc. Therefore, studying the maintenance methodology and improving fault detection algorithms can increase the performance of the system. This

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than ACM must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from Permissions@acm.org.

ISMSI '17, March 25-27, 2017, Hong Kong, Hong Kong

© 2017 ACM. ISBN 978-1-4503-4798-3/17/03...\$15.00

DOI: <http://dx.doi.org/10.1145/3059336.3059367>

process is critical especially for sensitive processes that require continuous operations with high reliability such as oil refinery systems and petrochemical plants. In such systems, time-based or condition-based maintenance was no longer sufficient to maximize operation time and efficiencies while keeping outages to a minimal. As a result, an early fault detection system was developed to detect anomaly signals and warn operators at an early state, which prevents the system from unplanned shutdowns or fatal accidents.

Engineers and researchers developed early fault detection systems for machineries by monitoring data from sensors placed on the machines. This system warns the operator as soon as abnormal signals are detected. Engineers can utilize this information in planning appropriate maintenance schedules. An early fault detection system is computationally demanding. Therefore, in practice, we apply these algorithms only to critical systems.

A critical component of a machine or system is a component which when it fails, it causes the overall system to shut down or reduce productivity dramatically. From a literature review, ball bearing is verified that the critical component of any rotating machines. Bearing can fail from many causes such as impurity of lubricant, insufficient lubricant, improper installation, etc. Locations of the ball bearing failures can be in whole part of bearing, inner race, outer race, rolling element etc. Each failure mode can be categorized by differences in vibration patterns. Thus engineers can identify locations or failure modes by studying vibration signals (For more detail about bearing defect characteristic are available on [1], [2] and [3]).

Diagnostic algorithm selection is a critical step for early fault detection because a suitable algorithm for a specific system can reduce computation process while return highly accurate results to cover all failure modes in the system. Several approaches are used for ball bearing diagnostics: acoustic analysis approach, temperature analysis approach, vibration analysis approach (For vibration based analysis see [4] and [5]). More details about ball bearing fault detection techniques can be found in [6] and [7]. Among these approaches, vibration analysis is widely used for ball bearing diagnosis because vibration signals are generated from direct reaction between bearing surfaces. These signals contain different characteristics depending on the excited source. Consequently, a vibration analysis approach can detect all failure modes of ball bearing.

To analyze these signals, several features are extracted from both time and time-frequency domains. These features, which represent different signal characteristics of vibration signals, are then utilized for learning of classifiers in order to predict ball bearing fault states. Details for this feature extraction will be discussed in Section 3.

Multinomial Logistic Regression (MLR) is one of the popular tools to correlate input features to failure modes. This methodology

classifies the failure mode of a given input data in terms of probability. We will discuss MLR in details in Section 4.

In practice, MLR predictions fluctuate caused by several factors including measurement noise, disturbance signals, lack of training data and improper feature selection for classifier training. To improve the classification performance, a smoothing algorithm such as moving average is used. However, in signals with low signal-to-noise ratio, moving average seems unsuitable because it required a lot of historic data (wide windows) to filter out noise. This will result in over lagging predicting result. Fortunately, in 1964, Savitzky and Golay proposed a time-domain smoothing algorithm based on least-square approximation. This algorithm is a powerful smoothing algorithm that is utilized in many applications. Kaneko et. al. proposed a Support Vector Machine (SVM) to predict unknown measurement parameters. The predicted parameter values are then processed by Savitzky-Golay filter to reduce prediction noise in order to increase prediction accuracy [8].

In this paper, a vibration approach is developed using several features extracted from both time and time-frequency domains. These features are used for training using logistic regression in order to predict bearing health states. The Savitzky-Golay filters are used for noise reduction in predicted values. The confidence interval is of 99% are used as a threshold to justify the faulty point. During the experiments, we used actual data of ball bearing provided by the FEMTO-ST Institute for testing this proposed method and assess performance of the algorithm.

2. PHM2012 DATA CHALLENGE DATASET

In this research, we choose the PHM2012 data challenge dataset provided by the FEMTO-ST Institute for analyzing and developing bearing fault detection system. The PHM2012 dataset recorded from bearing accelerated life degradation platform (PROGNOSTIA) shown in Figure 1.




Figure 1. PROGNOSTIA Platform (figure from [9])

In PROGNOSTIA, vibration sensors and temperature sensors are installed for data monitoring. Vibration data is captured by horizontal and vertical accelerometers which are installed on outer races of bearing. Vibration data is recorded at a sampling rate of 25.6 kHz. Measurement data of 0.1 seconds, equivalent to 2560 data, were recorded every 10 seconds (Figure 2). RTD PT100 is placed on PROGNOSTIA for capture temperature data. Since this paper only considers the vibration approach, only vibration data will be considered. The PHM2012 dataset consists of 17 datasets,

operating at three operating conditions: rotating at 1800 rpm with 4000 N of radial load (dataset 1 to dataset 7), 1650 rpm with 4200 N radial load (dataset 8 to dataset 14) and 1500 rpm with 5000 N (dataset 15 to dataset 17). More details regarding PROGNOSTIA and PHM2012 data challenge set are available in [9].




Figure 2. PHM2012 data acquisition (figure from [9])

3. FEATURE EXTRACTION

Feature extraction is a critical step in analyzing and developing an early fault detection algorithm. Improper feature selection, which increases dimension of analyzed data, not only consumes unnecessary computations resources, it also decreases fault detection performance. Feature extraction can be categorized into 3 major types: time-domain, frequency-domain and time-frequency domain features (More details about feature extraction of ball bearing are available in [10] and [11]).

Several time-domain features are used for bearing fault detection such as mean values, peak-to-peak values, rms values, crest factors, skewness, kurtosis, etc. In time-domain, anomaly signals are often difficult to detect in an initial defect stages. However, they become apparent and change rapidly right before total failure. Additionally, time-domain features are difficult to categorize into each failure mode. Despite all challenges, time-domain features like kurtosis gives most effective feature detection results [7].

Frequency-domain features are more suitable for categorize anomaly signal into each failure mode by analyzing dominance frequency using Fourier Transform. Nonetheless, frequency-domain features do not contain time instant information when the defect occurs. Many research utilized Short Time Fourier Transform (STFT) to extract times and frequency details from a signal. However, STFT window sizes cannot be adjusted dynamically while performing feature extraction, thus researchers have to select a fixed window size based on time and frequency resolutions. Therefore, time-frequency transforms were developed to overcome this limitation.

A Wavelet Transform (WT) is one of the time-frequency domain transform method widely used in signal processing because wavelet transform able to change resolution of transform, able to analyze in virus signals type not only sinusoidal and etc. A mother wavelet selection is a critical procedure for WT since analyze signal with different mother wavelets give different results. Currently, we have many methods for mother wavelet selections but no standard technique for mother wavelet selection. Many researches use similarity criteria for selecting a mother wavelet base on qualitative or quantitative approaches [12]. Kumar et al. presented the best possible mother wavelet selection criteria for applying WT on bearing vibration signals, namely, Maximum Energy to Shannon Entropy Ratio Criteria and Minimum Shannon Entropy Criteria (MSEC) [13]. Therefore, this paper will apply Maximum Energy to Shannon Entropy Ratio Criteria $R(s)$ for selecting mother wavelet.

In this paper, we will apply the crest factor, kurtosis and wavelet packet node energy to the PHM2012 dataset to create a feature matrix used for training and testing our early fault detection system. For the mother wavelet selection, we transform vibration data on dataset 1, 2, 8, 9, 15 and 16 using three different wavelet families, Symlets, Coiflets and Daubechies, at decomposition level 5. The resulting feature matrix (*Fea*) will consist of 68 features on each sampling (64 wavelet packet decomposition energy nodes, 2 kurtosis values and 2 crest factors values). Next, we calculate the Maximum Energy to Shannon Entropy Ratio (MESER). The mother wavelet that gives the highest MESER value will be selected for wavelet transformation basis. From the results listed in Table 1, Daubechies40 (DB40) showed the highest value. Thus, DB40 is used for this research.

4. MULTINOMIAL LOGISTIC REGRESSION

Multinomial Logistic Regression (MLR) is utilized for estimating bearing health states. The health states, N , can be either normal or defect ($N = 2$). There are two steps for estimating the probability on MRL states. The first step uses Equation 1 to calculate the probability that bearing stay in state r (reference state). In the second step, the probability that bearing stays in state j , state other than reference state, is calculated using Equation 2. The exponential term L_i is called the log-odds response, which is the logged, relative probability that bearing stays in state j compared to state r .

$$\Pr(\text{State} = r | \text{Fea}) = \frac{1}{1 + \sum_{i=2}^N e^{L_i(\text{Fea})}} \quad (1)$$

Table 1. Maximum Energy to Shannon Entropy Ratio of horizontal vibration

Condition	Maximum Energy to Shannon Entropy Ratio, R(s) ($\times 10^2$)					
	1800-rpm 4000-N		1650-rpm 400-N		1500-rpm 5000-N	
Mother Wavelet	Dataset 1	Dataset 2	Dataset 8	Dataset 9	Dataset 15	Dataset 16
SYM2	6.1966	1.2388	2.9464	2.6585	0.9300	0.8291
SYM3	6.5842	1.2860	3.0783	2.7755	0.9807	0.8706
SYM4	6.8376	1.2991	3.1209	2.7768	1.0191	0.8889
SYM5	6.9777	1.3383	3.1930	2.8586	1.0471	0.9099
SYM6	7.2737	1.3657	3.3113	2.9100	1.0788	0.9331
SYM7	7.4851	1.3934	3.3320	2.9571	1.1033	0.9565
SYM8	7.8358	1.4433	3.5195	3.0720	1.1370	0.9800
SYM10	8.2493	1.5139	3.6724	3.2198	1.1918	1.0280
COIF1	6.3277	1.2479	2.9420	2.6480	0.9488	0.8420
COIF2	7.2539	1.3714	3.2478	2.9141	1.0702	0.9339
COIF3	7.9341	1.4748	3.5601	3.1338	1.1580	1.0034
COIF4	8.7345	1.5636	3.7952	3.3160	1.2265	1.0640
COIF5	9.4341	1.6602	4.0356	3.5443	1.3016	1.1289
DB1	5.4389	1.1520	2.6935	2.4426	0.8462	0.7574
DB2	6.1966	1.2388	2.9464	2.6585	0.9300	0.8291
DB3	6.5842	1.2860	3.0783	2.7755	0.9807	0.8706
DB4	6.9044	1.3320	3.2013	2.8904	1.0127	0.9004
DB5	7.2634	1.3748	3.2680	2.9606	1.0541	0.9381
DB6	7.4838	1.3967	3.3223	3.0003	1.0732	0.9517
DB7	7.6414	1.4340	3.4244	3.0857	1.0947	0.9757
DB8	7.8651	1.4632	3.5198	3.1547	1.1254	0.9996
DB9	8.1147	1.4981	3.5843	3.2178	1.1526	1.0244
DB10	8.3365	1.5240	3.6748	3.3036	1.1804	1.0462
DB20	10.2568	1.8374	4.4341	3.9349	1.4148	1.2598
DB30	11.9813	2.1635	5.2638	4.6037	1.6695	1.4827
DB40	13.3250	2.4401	6.0023	5.2350	1.9083	1.7000

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\Pr(\text{State} = j | \text{Fea}) = \frac{e^{L_j(\text{Fea})}}{1 + \sum_{i=2}^N e^{L_i(\text{Fea})}} \quad (2)$$

$$L_i = \ln \left(\frac{\Pr(\text{State} = i | \text{Fea})}{\Pr(\text{State} = r | \text{Fea})} \right) \quad (3)$$

or simplified to,

$$L_i = \beta_0 + (\beta_1 \times \text{Fea}_1) + \dots + (\beta_n \times \text{Fea}_n) \quad (4)$$

where the logistic model parameters, $\beta_0, \beta_1, \dots, \beta_n$, are estimated using Maximum-Likelihood algorithm.

5. SMOOTHING AND CLASSIFICATION THRESHOLD

Prior to using the MLR probability as the classifier for bearing normal or defect state, these probabilities have to be filter using the Savitzky-Golay smoothing method. Next, a faulty threshold has to be define for our bearing application. To define a faulty threshold, we use a mean value of faulty probability on each training set which passes the actual defect point (Table 2) to estimate confidence interval at 99%. The confidence interval can be defined by Equation 5.

$$CI_L = \bar{x} - \left(CCF \times \frac{\sigma}{\sqrt{N}} \right) \quad (5)$$

where CI_L is lower-confidence interval value, \bar{x} is mean of mean value of failure probability, CCF is the confidence coefficient that can calculate by inverse of Student's t-cumulative distribution function, σ is a standard deviation of the mean failure probability value and N is the number of training sets which equals to 13 sets.

Table 2. Failure probability mean on each training set

Dataset Number	Dataset	Mean of Failure Probability
1	1800-rpm 4000-N #1	0.9166
3	1800-rpm 4000-N #3	0.6413
4	1800-rpm 4000-N #4	0.7272
5	1800-rpm 4000-N #5	0.9484
7	1800-rpm 4000-N #7	0.8747
9	1650-rpm 4200-N #2	0.9063
10	1650-rpm 4200-N #3	0.8786
11	1650-rpm 4200-N #4	0.7136
12	1650-rpm 4200-N #5	0.9382
13	1650-rpm 4200-N #6	0.8312
14	1650-rpm 4200-N #7	0.8764
16	1500-rpm 5000-N #2	0.9175
17	1500-rpm 5000-N #3	0.9357

6. PREDICTION PERFORMANCE INDEX

The Prediction Performance Index (PPI) for measuring the performance of the early fault detection algorithm can be evaluated by using Equation 6. The value of PPI greater than 100% indicates

that the algorithm most likely will detect bearing defects before the actual event. Whereas the value of PPI less than 100% indicates late detection of the system defects.

$$PPI = 100 \times \left(1 - \frac{(FP - \text{ActDef}) - (FP - \text{PrDef})}{(FP - \text{ActDef})} \right) \quad (6)$$

where,

FP is the total failure of the bearing where further operating can cause major damage to the system.

ActDef is the actual defect point which is identified during the data preparation process.

PrDef is the predicted defect point obtained by the algorithm.

7. RESULTS

Four data sets from the PHM2012 data challenge (dataset 2, 6, 8 and 15) were used to test the proposed fault detection algorithm. A data point is considered an indicator of the system failure detection if its fault probability is greater than 99% confidence interval (probability more than 0.7708).

The best fault detection result can be seen from dataset 15. It's failure probability were shown in Figure 3. Our algorithm detects defect state 10 seconds after the actual defect occurred, 4,640 seconds (≈ 77 minutes) before total failure. The worst fault detection result can be seen from dataset 2. It's failure probability were shown in Figure 4. Our algorithm detects defect state 970 seconds (≈ 16 minutes) after actual defect occurred, 6,400 seconds (≈ 106 minutes) before total failure.

Although the experimental results indicated late fault detection, this algorithm can still be utilized as a predictor for fault detection because this algorithm can detect anomaly signal long before point of system total failure.

Table 3. PPI results for dataset 2, 6, 8 and 15

Dataset No.	Actual Defect (sec)	Predict Defect (sec)	Fail Point (sec)	PPI
2	1,340	2,310	8,710	86.8385%
6	1,530	2,340	24,480	96.4706%
8	630	750	9,110	98.5849%
15	500	510	5,150	99.7849%

8. CONCLUSION

This paper proposed a vibration-based, early fault detection algorithm for ball bearing applications. Features from both vertical and horizontal accelerometer vibration data are extracted using kurtosis, crest factor and wavelet packet decomposition node energy with Daubechies40 at level 5 of decomposition. The extracted features were then processed using MLR for training and assessing health states of the bearing. Next, the results were filtered using the Savitzky-Golay smoothing algorithm to rid of any calculation uncertainty. Finally, a 99% confidence level of faulty probability mean on each training data set are used to justify the point of fault state.

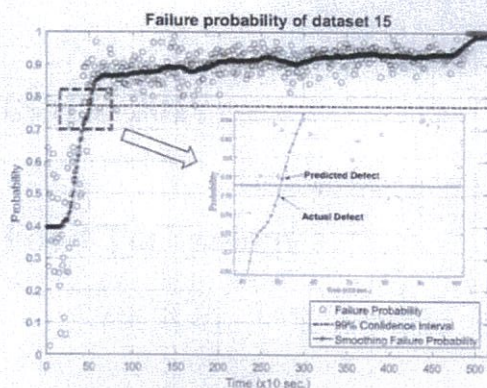


Figure 3. Failure probability of dataset 15

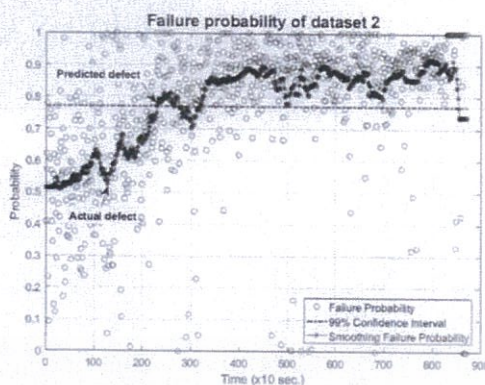


Figure 4. Failure probability of dataset 2

The proposed algorithm is accurately predicted with PPI value up to 99.7849% on testing dataset 15 that can label fault point after defects occur in 10 seconds. Even though the test from dataset number 2 resulted in 86.8385% of PPI value, but fault probability is increasing continuously before touching the fault threshold. Therefore, this algorithm can provide the operating engineer a visual queue to manage effective maintenance plan by using prediction information.

9. REFERENCE

- [1] Lacey, S. J. 2008. An Overview of Bearing Vibration Analysis. *Maintenance and Asset Management* 23, 6 (Dec. 2008), 32-42.
- [2] Granet, B. P. and Starry, K. 2012. Rolling Element Bearing Analysis. *Materials Evaluation* 70, 1 (Jan. 2012), 78-85.
- [3] Kruger, W. 2009. *Tracking rolling element bearing failures using mechanical and electrical vibration testing methods*. ALL-TEST Pro, Connecticut, USA
- [4] Patidar, S. and Soni, P. K. 2013. An Overview on Vibration Analysis Techniques for the Diagnosis of Rolling Element Bearing Faults. *International Journal of Engineering Trends and Technology (IJETT)* 4, 5 (May 2013), 1804-1809.
- [5] Devendiran, S. and Manivannan, K. 2016. Vibration Based Condition Monitoring and Fault Diagnosis Technologies For Bearing and Gear Components-A Review. *International Journal of Applied Engineering Research* 11, 6 (2016), 3966-3975.
- [6] Nabhan, A., Ghazaly, N. M., Sami, A. M., and Mousa, M. O. 2015. *Bearing Fault Detection Techniques-A Review*.
- [7] Kharche, P. P. and Kshirsagar, S. V. 2014. Review of Fault Detection in Rolling Element Bearing. *International Journal of Innovative Research in Advanced Engineering* 1, 5 (Jun. 2014), 169-174.
- [8] Kaneko, H., Matsumoto, T., Ootakara, S., and Funatsu, K. 2016. Practical Use of Savitzky-Golay Filtering-Based Ensemble Online SVR. *IFAC-PapersOnLine* 49, 7 (Aug. 2016), 371-376. DOI=<https://doi.org/10.1016/j.ifacol.2016.07.364>
- [9] Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Morello, B., Zerhouni, N., and Vernier, C. 2012. *PRONOSTIA: An Experimental Platform for Bearings Accelerated Life Test*. FEMTO-ST Institute, France.
- [10] Yan, W., Qiu, H., and Iyer, N. 2008. *Feature Extraction for Bearing Prognostics and Health Management (PHM)-A Survey*. In Air Force Research Laboratory.
- [11] Rai, A. and Upadhyay, S. H. 2016. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings. *Tribology International* 96, (Apr. 2016), 289-306. DOI=<http://doi.org/10.1016/j.triboint.2015.12.037>
- [12] Ngui, W. K., Leong, M. S., and Hee, L. M. 2013. Wavelet Analysis: Mother Wavelet Selection Methods. *Applied Mechanics and Materials* 393, (Sep. 2013), 953-958. DOI=<http://www.scientific.net/AMM.393.953>
- [13] Kumar, H. S., Srinivasa Pai, P., Sriram, N. S., and Vijay, G. S. 2014. Selection of Mother Wavelet for Effective Wavelet Transform of Bearing Vibration Signals. *Advanced Materials Research* 1039, (Jul. 2014), Trans Tech Publications, Switzerland, 169-176. DOI=<https://www.scientific.net/AMR.1039.169>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ - นามสกุล	นายชนเดช เกิดศิริ
วัน/เดือน/ปีเกิด	21 สิงหาคม 2535
ประวัติการศึกษา	พ.ศ. 2558 หลักสูตรวิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมระบบควบคุม (เกียรตินิยมอันดับ2) สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ความชำนาญเฉพาะด้าน	1. การซ่อมบำรุงรักษาเครื่องจักรกลเชิงการทำนาย 2. การพัฒนาอัลกอริทึมตรวจจับความผิดปกติในการทำงานของเครื่องจักรกล โดยอาศัยการวิเคราะห์สัญญาณเฝ้าติดตาม



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้