

การพัฒนาระบบผู้เชี่ยวชาญในการพยากรณ์สถานะปั๊มแบบมอเตอร์ปิดผนึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมอุตสาหกรรม ภาควิชาวิศวกรรมอุตสาหกรรม

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2564

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Development of Expert System to predict canned motor pump status



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Industrial Engineering

Department of Industrial Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2021

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพัฒนาระบบผู้เชี่ยวชาญในการพยากรณ์สถานะไข้แบบ มอเตอร์ปิดผนึก
โดย	นายคมกริช เกื้อนสุวรรณ
สาขาวิชา	วิศวกรรมอุตสาหการ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ศาสตราจารย์ ดร.ปารเมศ ชูติมา

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	ประธานกรรมการ
.....	
(รองศาสตราจารย์จรัสพัฒน์ เงามประเสริฐวงศ์)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ศาสตราจารย์ ดร.ปารเมศ ชูติมา)	
.....	กรรมการ
(รองศาสตราจารย์ ดร.ดาริชา สุธีวงศ์)	
.....	กรรมการภายนอกมหาวิทยาลัย
(รองศาสตราจารย์ ดร.ชูเวช ชาญสง่าเวช)	

คมกริช เกื่อนสุวรรณ : การพัฒนาระบบผู้เชี่ยวชาญในการพยากรณ์สถานะปั๊มแบบมอเตอร์ปิดผนึก. (Development of Expert System to predict canned motor pump status) อ.ที่ปรึกษาหลัก : ศ. ดร.ปารเมศ ชุตินา

งานวิจัยนี้นำเสนอการพัฒนาระบบผู้เชี่ยวชาญในการทำนายสถานะปั๊มแบบมอเตอร์ปิดผนึกของโรงงานกรณีศึกษาโดยประยุกต์ใช้หลักการทำนายเชิงสถิติและอัลกอริทึมการเรียนรู้ของเครื่องร่วมกับความรู้ของผู้เชี่ยวชาญ โรงงานกรณีศึกษาคือโรงงานในธุรกิจปิโตรเคมี ซึ่งใช้ปั๊มแบบมอเตอร์ปิดผนึก ในการส่งถ่ายของเหลวในกระบวนการผลิตภายในพื้นที่โรงงาน ซึ่งปัจจุบันการบำรุงรักษาปั๊มแบบมอเตอร์ปิดผนึกของโรงงานนั้น ได้ปรับปรุงกลยุทธ์จากการบำรุงรักษาตามสภาพเป็นการบำรุงรักษาเชิงทำนาย โดยการจะทำให้ประสิทธิภาพในการทำนายนั้นอยู่ในระดับที่ต้องการได้จะต้องใช้ความรู้จากผู้เชี่ยวชาญปั๊มแบบมอเตอร์ปิดผนึกในการค้นหาสัญญาณความผิดปกติลักษณะต่างๆที่อาจเกิดขึ้นได้ โดยระบบผู้เชี่ยวชาญนี้มีส่วนช่วยในการลดภาระของผู้เชี่ยวชาญโดยการทดแทนด้วยระบบ งานวิจัยนี้ประกอบไปด้วยการระบุนกรอบของงานวิจัยและระบบ ขั้นตอนการทดลองและทดสอบระบบ รวมถึงการเตรียมชุดข้อมูลและการทดสอบแบบจำลองที่ใช้ ซึ่งผลการทำวิจัยพบว่าแบบจำลองการพยากรณ์ค่าเฉลี่ยเคลื่อนที่แบบบูรณาการอัตโนมัติ (Autoregressive integrated average model, ARIMA) สำหรับการพยากรณ์ และอัลกอริทึมแรนดอมฟอเรส (Random Forest, RF) สำหรับการระบุสถานะปัจจุบัน นั้นมีความเหมาะสมสำหรับระบบนี้ อันเนื่องมาจากผลของการประเมินประสิทธิภาพเชิงเปรียบเทียบระหว่างแบบจำลองที่ถูกเลือกมาประเมิน ยิ่งไปกว่านั้นระบบผู้เชี่ยวชาญที่สร้างขึ้นจะเป็นต้นแบบในการนำไปใช้กับอุปกรณ์อื่นๆ ในโรงงานในกรณีศึกษาต่อไป

สาขาวิชา วิศวกรรมอุตสาหการ

ลายมือชื่อนิสิต

ปีการศึกษา 2564

ลายมือชื่อ อ.ที่ปรึกษาหลัก

6370033721 : MAJOR INDUSTRIAL ENGINEERING

KEYWORD: Expert System

Komkrish Thuensuwan : Development of Expert System to predict canned motor pump status. Advisor: Prof. PARAMES CHUTIMA, Ph.D.

This research presents the development of an Expert System to predict Canned Motor Pump (CMP) Status by applying a forecasting technics and machine learning (ML) algorithm with domain expert knowledge in the case study plant. A Case study plant is a petrochemical plant that uses CMP to transfer liquid between production unit. The current CMP maintenance strategy is improving from condition-based maintenance to predictive maintenance. To archive desired level of predictive maintenance need CMP domain expert knowledge to find potential failure signs. This expert system is contributing to reducing expertise human load by substitution with the system. The research contains identifying system framework, experiment steps, including dataset preparation and model testing. The experiment result shows Autoregressive integrated average model (ARIMA) for forecasting model and Random Forest (RF) algorithm for classification model is suitable for this system due to model performance evaluation comparing candidate models. Further on, this contribution is a role model, and enrolling in other equipment in the case study plant is a benefit of this work.

CHULALONGKORN UNIVERSITY

Field of Study: Industrial Engineering

Student's Signature

Academic Year: 2021

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ในหัวข้อ การพัฒนาระบบผู้เชี่ยวชาญในการพยากรณ์สถานะปั๊มแบบมอเตอร์ปิดผนึก สำเร็จลุล่วงไปได้ด้วยดี ในการดำเนินงานวิจัยและจัดทำวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอขอบพระคุณ ศาสตราจารย์ ดร.ปารเมศ ชูติมา อาจารย์ที่ปรึกษาวิทยานิพนธ์ ท่านได้เสียสละเวลาอันมีค่า ในการให้คำปรึกษา มอบวิชาความรู้อันเป็นประโยชน์อย่างยิ่ง ตลอดระยะเวลาในการดำเนินการวิจัย อีกทั้งยังคอยตรวจสอบและแก้ไขข้อบกพร่องต่าง ๆ เพื่อให้การวิจัยและวิทยานิพนธ์ฉบับนี้มีความถูกต้องและเกิดประโยชน์สูงสุด ส่งผลให้การดำเนินการวิจัยในครั้งนี้สำเร็จลุล่วงไปได้ด้วยดี

ขอขอบพระคุณ รองศาสตราจารย์จิรพัฒน์ เงามประเสริฐวงศ์ ประธานกรรมการสอบวิทยานิพนธ์ รองศาสตราจารย์ ดร. ดาริชา สุธีวงศ์ กรรมการการสอบวิทยานิพนธ์ และรองศาสตราจารย์ ดร.ชูเวช ชาญสง่าเวช กรรมการภายนอกมหาวิทยาลัย ที่ได้เสียสละเวลาอันมีค่าในการสละเวลามารับฟังการนำเสนอผลงานวิจัยและให้คำแนะนำที่มีประโยชน์ ทำให้การดำเนินการวิจัยและวิทยานิพนธ์ฉบับนี้มีความถูกต้องสมบูรณ์มากยิ่งขึ้น

ขอขอบพระคุณอาจารย์ภาควิชาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัยทุกท่านที่ได้มอบความรู้ ตลอดจนข้อมูลที่มีประโยชน์ต่างๆ เป็นผลทำให้การดำเนินการวิจัยในครั้งนี้สามารถนำไปประยุกต์ใช้เพื่อสร้างระบบผู้เชี่ยวชาญได้อย่างมีประสิทธิภาพ

สุดท้ายนี้ ผู้วิจัยขอกราบขอบพระคุณบิดา มารดา และครอบครัว ตลอดจนผู้ที่เกี่ยวข้องทุกท่าน ที่คอยสนับสนุนและให้กำลังใจเสมอมา ข้าพเจ้าหวังเป็นอย่างยิ่งว่า งานวิจัยและวิทยานิพนธ์ฉบับนี้ จะสามารถนำไปใช้เพื่อก่อให้เกิดประโยชน์แก่สังคมและผู้ที่เกี่ยวข้องได้เป็นอย่างดี

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

คมกริช เกื้อนสุวรรณ

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญรูปภาพ.....	ญ
บทที่ 1 บทนำ.....	1
1.1 ที่มา	1
1.2 ความสำคัญของปัญหา.....	3
1.3 วัตถุประสงค์ของงานวิจัย.....	9
1.4 ขอบเขตของงานวิจัย.....	9
1.5 ขั้นตอนการศึกษาและวิธีการดำเนินการวิจัย	10
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	11
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	12
2.1 ทฤษฎีที่เกี่ยวข้อง	12
2.1.1 ป้อนแบบมอเตอร์ปิดผนึก.....	12
2.1.2 การวิเคราะห์ลักษณะการเสียและระดับผลกระทบ (Failure Mode and Effect Analysis, FMEA) [5].....	13
2.1.3 การจัดการข้อมูล [6].....	13

2.1.4 การเรียนรู้ของเครื่อง (Machine Learning) [7].....	15
2.1.5 การประเมินแบบจำลองการเรียนรู้ของเครื่อง [8].....	16
2.1.7 การพยากรณ์ (Forecasting) [12].....	18
2.2 งานวิจัยที่เกี่ยวข้อง.....	24
บทที่ 3 การดำเนินงานวิจัย	30
3.1 กรอบการดำเนินงานวิจัย	30
3.2 การประเมินองค์ความรู้ของผู้เชี่ยวชาญ.....	32
3.1.1 การจัดการข้อมูลสูญหาย (Missing Data) [6]	39
3.1.2 การทำความสะอาดข้อมูล (Cleaning Data) [6]	40
3.1.3 การจัดการค่าผิดปกติในข้อมูล (Correct Data) [6].....	40
3.2 การวิเคราะห์ลักษณะการเสียและผลกระทบ (Failure Mode and Effect Analysis, FMEA) [5]	41
3.3 การสร้างแบบจำลองพยากรณ์พารามิเตอร์ค่าสภาพของลูกปืน (Forecasting).....	42
3.3.1 สํารวจลักษณะของข้อมูล (Examine Data Patterns)	44
3.3.2 เลือกวิธีการพยากรณ์และทำการทดสอบความแม่นยำ [12].....	45
3.4 การสร้างแบบจำลองจำแนกสถานะปั๊มแบบมอดอร์ปิดผนึก (Classification)	52
3.4.1. การสร้างแบบจำลองการเรียนรู้ของเครื่อง	57
บทที่ 4 ผลการดำเนินงานวิจัย	68
4.1 ผลแบบจำลองพยากรณ์พารามิเตอร์ค่าสภาพของลูกปืน (Forecasting)	68
4.2 สรุปผลแบบจำลองแสดงสถานะปัจจุบันของปั๊ม (Classification)	69
4.3 การนำแบบจำลองไปใช้งานผ่านกระดานแสดงผล (Dashboard).....	71
บทที่ 5 สรุปผลการดำเนินงานวิจัยและมุมมองสำหรับการพัฒนาต่อไป.....	72
บรรณานุกรม.....	74
ประวัติผู้เขียน.....	78



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญตาราง

	หน้า
ตารางที่ 1 จำนวนปั๊มแบบมอเตอร์ปิดผนึก แยกตามลำดับความสำคัญ	4
ตารางที่ 2 ประวัติการเสียของปั๊มแบบมอเตอร์ปิดผนึก กลุ่มระดับความสำคัญสูง ปี พ.ศ. 2559 ถึง 2563.....	5
ตารางที่ 3 ชั่วโมงการทำงานในการอ่านค่าและประเมินสถานะปั๊มแบบมอเตอร์ปิดผนึกระดับความสำคัญสูง	9
ตารางที่ 4 ขั้นตอนการศึกษา วิธีการดำเนินการวิจัย และผลที่คาดว่าจะได้รับ	10
ตารางที่ 5 สมการคำนวณค่าความคลาดเคลื่อน	23
ตารางที่ 6 กรอบการดำเนินงานวิจัย	31
ตารางที่ 7 การใช้งานองค์ความรู้ของผู้เชี่ยวชาญในงานวิจัย	33
ตารางที่ 8 คุณสมบัติของคอมพิวเตอร์ส่วนบุคคลที่ใช้ในงานวิจัย	36
ตารางที่ 9 จำนวนข้อมูลดิบที่ใช้ในการสร้างแบบจำลอง	37
ตารางที่ 10 แบบจำลองการถดถอยเชิงเส้น	50
ตารางที่ 11 การแบ่งระดับสถานะของปั๊มในโรงงานตัวอย่าง	53
ตารางที่ 12 ค่าเฉลี่ยการเปลี่ยนแปลงค่า Bearing Condition (Radial)	58
ตารางที่ 13 ค่าเฉลี่ยการเปลี่ยนแปลงค่า Bearing Condition (Axial).....	58
ตารางที่ 14 Feature ที่เหมาะสมสำหรับการสร้างแบบจำลองการเรียนรู้ของเครื่องในงานวิจัยนี้	59
ตารางที่ 15 แบบจำลองที่เหมาะสมจากการปรับหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม	64
ตารางที่ 16 นิยามของแต่ละ “term” ของ “Confusion Matrix”	67
ตารางที่ 17 ผลเปรียบเทียบค่าความคลาดเคลื่อนของแต่ละแบบจำลอง.....	68
ตารางที่ 18 เปรียบผลลัพธ์ระหว่างอัลกอริทึม	71

สารบัญรูปภาพ

	หน้า
รูปที่ 1 กระบวนการเลือกวิธีบำรุงรักษาตามหลัก “RCM” [1].....	2
รูปที่ 2 ตัวอย่างลักษณะทางกายภาพปั๊มแบบมอเตอร์ปิดผนึก [2].....	3
รูปที่ 3 กราฟสัดส่วนจำนวนอุปกรณ์จำแนกตามระดับความสำคัญ.....	4
รูปที่ 4 มาตรฐานค่าสภาพของลูกปืนชนิดทรงกระบอกคาร์บอน [3].....	6
รูปที่ 5 ตัวอย่างตำแหน่งเซนเซอร์	7
รูปที่ 6 รายการพารามิเตอร์โดยจำแนกตามปั๊ม	8
รูปที่ 7 ตัวอย่างแบบปั๊มแบบมอเตอร์ปิดผนึก (Typical canned motor pump) [4]	12
รูปที่ 8 ตัวอย่างตารางเมทริกซ์ความสัมพันธ์ [10].....	16
รูปที่ 9 การแบ่งแบบ “Cross Validation” [11]	18
รูปที่ 10 ตัวอย่างลักษณะข้อมูลมีแนวโน้มขึ้นและมีวัฏจักร [12]	19
รูปที่ 11 ตัวอย่างลักษณะข้อมูลเปลี่ยนแปลงตามฤดูกาล [12].....	19
รูปที่ 12 สมการคำนวณ การพยากรณ์อย่างง่าย [12].....	20
รูปที่ 13 สมการคำนวณ การพยากรณ์โดยใช้ค่าเฉลี่ย [12].....	21
รูปที่ 14 สมการการวิเคราะห์การถดถอย [12].....	22
รูปที่ 15 ขั้นตอนของวิธี “ARIMA” [12].....	22
รูปที่ 16 สมการหาค่าคงเหลือ (Residual) [12].....	23
รูปที่ 17 ตัวอย่าง “CPS architecture for maintenance and PDM” จากบทความตัวอย่าง [13]	25
รูปที่ 18 ตัวอย่างเปรียบเทียบกระบวนการทำงานแบบเดิมและใหม่อ้างอิงจากบทความตัวอย่าง [13]	25
รูปที่ 19 ตัวอย่างผังเทคนิคของการเรียนรู้ของเครื่องจากบทความตัวอย่าง [13].....	26

รูปที่ 20 ตัวอย่างการสร้างตารางเมทริกซ์ความสับสน (Confusion Matrix) จากบทความตัวอย่าง [14].....	27
รูปที่ 21 ตัวอย่างตารางวิเคราะห์สาเหตุของลักษณะข้อบกพร่องและผลกระทบจากบทความตัวอย่าง [15].....	28
รูปที่ 22 ตัวอย่างแผนภูมิลักษณะการเสียประเภทต่างๆ[20]	32
รูปที่ 23 ตัวอย่างกราฟความสัมพันธ์ของสัญญาณการเสียซ้อนเร้น[19]	33
รูปที่ 24 ตัวอย่างแผนผังการใช้การเรียนรู้ของเครื่องกับระบบระบุความเสียหายอัจฉริยะ [17].....	35
รูปที่ 25 กรอบแนวคิดในการสร้างระบบผู้เชี่ยวชาญ.....	35
รูปที่ 26 ตัวอย่างระบบผู้เชี่ยวชาญประเภทอิงกฎ [21].....	36
รูปที่ 27 ตัวอย่างข้อมูลที่ใช้ในการสร้างแบบจำลอง.....	38
รูปที่ 28 ตัวอย่างข้อมูลหลังจากที่จัดการข้อมูลสูญหาย	39
รูปที่ 29 Boxplot ของค่ากระแสของอุปกรณ์ตัวอย่างก่อนจัดการค่าผิดปกติ	40
รูปที่ 30 Boxplot ของค่ากระแสของอุปกรณ์ตัวอย่างหลังจัดการค่าผิดปกติ.....	41
รูปที่ 31 “FMEA” ของปั๊มแบบมอเตอร์ชนิดนี้ในงานวิจัยนี้.....	42
รูปที่ 32 ตัวอย่าง ลักษณะทั่วไปของค่า ค่าสภาพของลูกปืนปั๊มด้านแนวแกนในงานวิจัยนี้.....	43
รูปที่ 33 แผนภูมิอนุกรมเวลาของตัวอย่างข้อมูลในงานวิจัยนี้	44
รูปที่ 34 แผนภูมิความสัมพันธ์ระหว่างตัวข้อมูลเองในงานวิจัยนี้.....	45
รูปที่ 35 ตัวอย่างค่าพยากรณ์ด้วยการพยากรณ์อย่างง่าย (Naïve).....	46
รูปที่ 36 ค่าความคลาดเคลื่อนด้วยการพยากรณ์อย่างง่าย (Naïve)	46
รูปที่ 37 แผนภูมิความสัมพันธ์ระหว่างตัวข้อมูลเองบางส่วน.....	47
รูปที่ 38 แผนภูมิหลังจากทำการแปลงข้อมูล	48
รูปที่ 39 z test of coefficients ARIMA(0,1,1).....	49
รูปที่ 40 Residual plot	49
รูปที่ 41 ผลทดสอบความคลาดเคลื่อนของ ARIMA (0,0,1).....	50

รูปที่ 42 ANOVA table.....	51
รูปที่ 43 ผลทดสอบความคลาดเคลื่อนของแบบจำลอง Linear Regression.....	51
รูปที่ 44 แผนภูมิสถานะเปรียบเทียบกับไฟแอลอีดีของปั๊ม [24]	52
รูปที่ 45 ตัวอย่างรูปแบบข้อมูลในกรณีศึกษา	53
รูปที่ 46 แผนผังการสร้างแบบจำลอง [11].....	54
รูปที่ 47 ขั้นตอนการสร้างแบบจำลองการเรียนรู้ของเครื่อง	55
รูปที่ 48 สัดส่วนสถานะของข้อมูล.....	56
รูปที่ 49 ตัวแปรที่ใช้ในการสร้างแบบจำลอง.....	56
รูปที่ 50 ค่าสภาพลูกปืนทรงกระบอกคาร์บอน.....	57
รูปที่ 51 ตัวอย่างการทำงานของอัลกอริทึม “kNN”	60
รูปที่ 52 ตัวอย่างการทำงานของอัลกอริทึม “RF”	61
รูปที่ 53 ตัวอย่างการทำงานของอัลกอริทึม “ANN” [27]	62
รูปที่ 54 ตัวอย่างการทำงานของอัลกอริทึม “SVM” [29]	62
รูปที่ 55 ตัวอย่าง “Cross-validation framework”	63
รูปที่ 56 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “kNN”	65
รูปที่ 57 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “RF”	65
รูปที่ 58 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “ANN”	65
รูปที่ 59 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “SVM”	66
รูปที่ 60 “Binary class confusion matrix”	66
รูปที่ 61 “Multi-class confusion matrix”	67
รูปที่ 62 เปรียบเทียบความแม่นยำระหว่างชุดข้อมูลที่ใช้สอนและทดสอบ	70
รูปที่ 63 “Multi-class Confusion matrix” ของงานวิจัยนี้.....	70

บทที่ 1

บทนำ

1.1 ที่มา

โรงงานในอุตสาหกรรมปิโตรเคมีนั้นใช้เครื่องจักรในการส่งสารเคมีจากหน่วยการผลิตหนึ่งไป อีกหน่วยการผลิตหนึ่ง เช่น ปั๊ม (Pump) สำหรับสารเคมีที่เป็นของเหลว หรือ คอมเพรสเซอร์ (Compressor) สำหรับสารเคมีที่เป็นก๊าซ เครื่องจักรเหล่านี้จึงมีความสำคัญต่อโรงงานทั้งในแง่ของ ความต่อเนื่องของกระบวนการผลิต โดยเฉพาะกระบวนการผลิตที่เป็นการผลิตแบบต่อเนื่อง (Continuous Process) ซึ่งถ้าเครื่องจักรเกิดความเสียหาย (Failure) จนไม่สามารถทำตามหน้าที่ได้จะส่งผลให้ กระบวนการผลิตต้องหยุดนอกแผน (Unplanned Shutdown) และมีโอกาสในการเกิดของเสียใน กระบวนการผลิตได้ นอกจากผลกระทบต่อกระบวนการผลิตแล้วยังส่งผลกระทบต่อ ค่าใช้จ่ายในการ บำรุงรักษาเครื่องจักรที่เพิ่มมากขึ้นทำให้ต้นทุนในการผลิตเพิ่มมากขึ้นตามไปด้วย นอกจากนี้ยังส่งผล กระทบต่อความปลอดภัยและสิ่งแวดล้อมในกรณีที่เกิดความเสียหายที่เกิดขึ้นเป็นการรั่วไหลของ สารเคมีออกสู่ภายนอกเครื่องจักร (External Leakage) ซึ่งจากความสำคัญของเครื่องจักรและ ผลกระทบต่อโรงงานนั้น จึงต้องมีการบำรุงรักษาเครื่องจักรอย่างเหมาะสม


สำหรับวิศวกรในหน่วยงานบำรุงรักษาเครื่องจักร (Maintenance Engineer) ต้องทำหน้าที่ ในการออกแบบและวางแผนการบำรุงรักษาเครื่องจักรโดยใช้องค์ความรู้ที่เกี่ยวข้องกับเครื่องจักรนั้น ๆ เพื่อให้มั่นใจได้ว่าเครื่องจักรสามารถทำงานได้อย่างต่อเนื่องไม่มีการเสียนอกแผนงานภายใต้ ข้อจำกัดในด้านทรัพยากรบำรุงรักษาที่ต้องอยู่ในปริมาณที่น้อยที่สุดเพื่อให้ต้นทุนของโรงงาน สามารถแข่งขันได้ ซึ่งทรัพยากรหรือต้นทุนในการบำรุงรักษานั้นจะแบ่งเป็น 2 ส่วนใหญ่ ๆ คือ คน (Man) และอะไหล่ (Material)

หนึ่งในกลยุทธ์ในการออกแบบและวางแผนการบำรุงรักษาเครื่องจักรนั้นคือกระบวนการ บำรุงรักษาโดยใช้ระดับความเชื่อมั่นเป็นสำคัญ (Reliability Centered Maintenance, RCM) [1] ซึ่งเป็นวิธีที่ได้รับความนิยมในปัจจุบัน วิธีนี้จะจำแนกวิธีการบำรุงรักษาเครื่องจักรออกเป็น 4 วิธี คือ

1. การบำรุงรักษาตามสภาพ (On-Condition Task)
2. การบำรุงรักษาโดยการคืนสภาพเครื่องจักรตามรอบ (Schedule Restoration/Discard Task)
3. การบำรุงรักษาโดยการทดสอบหาการเสีย (Failure Finding Task)

4. การบำรุงรักษาโดยไม่กำหนดแผน (No Scheduled Maintenance)

ซึ่งในเอกสารมาตรฐานจะมีแนวทางในการเลือกวิธีที่เหมาะสมดังรูปที่ 1




รูปที่ 1 กระบวนการเลือกวิธีบำรุงรักษาตามหลัก "RCM" [1]

วิธีที่เกี่ยวข้องกับงานวิจัยนี้คือ การบำรุงรักษาตามสภาพ (On-Condition Task) ซึ่งเป็นการกำหนดวิธีการตรวจสอบสภาพของเครื่องจักร โดยการตรวจหาสัญญาณการเสียซ่อนเร้น (Potential Failure) เพื่อทำการวางแผนซ่อมก่อนที่จะเครื่องจักรจะเสียจริง วิธีนี้เหมาะกับลักษณะการเสียที่มีสัญญาณที่สามารถตรวจพบได้ล่วงหน้า เช่น สัญญาณการสั่นสะเทือน (Vibration) หรืออุณหภูมิ (Temperature) ณ ตำแหน่งต่างๆ ของเครื่องจักร

1.2 ความสำคัญของปัญหา

โรงงานกรณีศึกษาเป็นโรงงานผลิตสารเคมีในอุตสาหกรรมปิโตรเคมีแห่งหนึ่งมีกระบวนการผลิตแบบต่อเนื่องโดยจะมีรอบหยุดตามแผนเพื่อบำรุงรักษาและจัดการกระบวนการผลิตทุก 6 เดือน ซึ่งโรงงานได้เลือกใช้ปั๊มแบบมอเตอร์ปิดผนึก (Canned Motor Pump) ซึ่งเป็นปั๊มที่มีคุณสมบัติที่สำคัญคือไม่มีโอกาสที่สารเคมีจะรั่วไหลผ่านคอเพลลาและระบบกันรั่ว (Seal) เหมือนปั๊มทั่วไปที่ใช้ในอุตสาหกรรมแต่จะมีข้อเสียคือมีลักษณะการเสียที่สำคัญคือ การเสียในรูปแบบที่เพลลาไม่สามารถหมุนได้ (Rotor Locked) จากลูกปืนชนิดทรงกระบอกคาร์บอน (Carbon Bush Bearing) ภายในปั๊มเสียหาย ลักษณะทางกายภาพของปั๊มแบบมอเตอร์ปิดผนึกแสดงดังรูปที่ 2



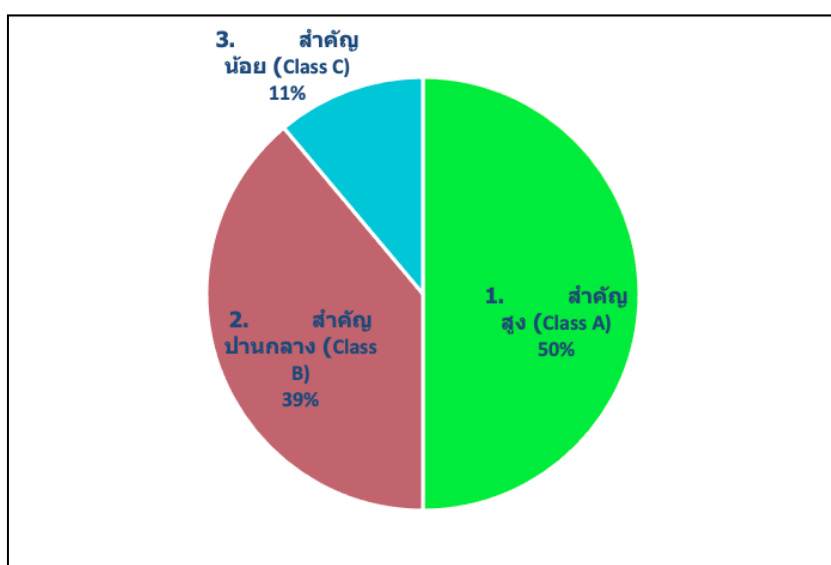
รูปที่ 2 ตัวอย่างลักษณะทางกายภาพปั๊มแบบมอเตอร์ปิดผนึก [2]

โดยในโรงงานมีการใช้งานปั๊มแบบมอเตอร์ปิดผนึกในกระบวนการผลิตทั้งหมด 36 รายการ มีการจำแนกจำนวนตามลำดับความสำคัญของเครื่องจักรดังตารางที่ 1 และกราฟแสดงสัดส่วนจำนวนอุปกรณ์ตามลำดับความสำคัญดังรูปที่ 3 เป็น 3 ระดับ คือ

1. ความสำคัญสูง (Class A) เมื่อเครื่องจักรเสียจะส่งผลกระทบต่อกระบวนการผลิตทันที
2. ความสำคัญปานกลาง (Class B) เมื่อเครื่องจักรเสียจะไม่ส่งผลกระทบต่อกระบวนการผลิตทันที แต่จะมีผลในระยะปานกลางถ้าไม่แก้ไข
3. ความสำคัญต่ำ (Class C) เมื่อเครื่องจักรเสียจะไม่ส่งผลกระทบต่อกระบวนการผลิต

ตารางที่ 1 จำนวนปั๊มแบบมอเตอร์ปิดผนึก แยกตามลำดับความสำคัญ

ระดับความสำคัญ	จำนวนอุปกรณ์ (สัดส่วน)
1. สำคัญสูง (Class A)	18 (50%)
2. สำคัญปานกลาง (Class B)	14 (40%)
3. สำคัญน้อย (Class C)	4 (11%)
จำนวนทั้งหมด	36



รูปที่ 3 กราฟสัดส่วนจำนวนอุปกรณ์จำแนกตามระดับความสำคัญ

จากรูปที่ 3 จะเห็นได้ว่าจำนวนของปั๊มแบบมอเตอร์ปิดผนึก ที่มีระดับความสำคัญสูงมีสัดส่วนค่อนข้างมากคือห้าสิบเปอร์เซ็นต์ (50%) ถ้าปั๊มในจำนวนนี้เกิดการเสียหายปั๊มไม่สามารถทำงานได้ในช่วงการดำเนินการผลิตปกติ จะส่งผลให้กระบวนการผลิตต้องหยุดนอกแผน และส่งผลให้เกิดการสูญเสียโอกาสในการผลิต กระทบต่อกำไรของบริษัทโดยตรง ซึ่งจากประวัติพบว่าแต่ละปี กลุ่มปั๊มแบบมอเตอร์ปิดผนึกระดับความสำคัญสูง (Class A) นั้นมีประวัติการเสียหายเฉลี่ย 2.8 ครั้งต่อปี ดังตารางที่ 2 ซึ่งถ้าพบสัญญาณการเสียหายอ่อนเร้น (Potential Failure) ช้าหรือ ไม่พบ จนกระทั่งปั๊มเกิดความเสียหายจนไม่สามารถทำงานได้ (Breakdown) จะส่งผลให้เกิดการหยุดผลิตนอกแผนในปีนั้น ๆ และมีผลกระทบตามที่กล่าวไป

ตารางที่ 2 ประวัติการเสียของปั๊มแบบมอเตอร์ปิดผนึก กลุ่มระดับความสำคัญสูง ปี พ.ศ. 2559 ถึง 2563

ลำดับ	ชื่อปั๊ม (Tag No.)	ประวัติการเสีย (ครั้ง)					รวม
		ปี 2559	ปี 2560	ปี 2561	ปี 2562	ปี 2563	
1	A	-	-	-	-	-	0
2	B	1	-	-	-	-	1
3	C1	-	-	-	-	-	0
4	C2	-	1	-	-	-	1
5	D	-	-	-	-	-	0
6	E	1	-	1	1	-	3
7	F	-	-	-	-	-	0
8	G	-	-	-	-	1	1
9	H	-	-	-	-	-	0
10	I	-	-	-	-	1	1
11	J	1	-	-	-	1	2
12	K	-	-	-	1	-	0
13	M	1	-	-	-	1	2
14	N	1	-	-	-	-	1
15	O	-	-	-	-	-	0
16	P	0	0	0	1	1	1
17	Q	-	-	-	-	-	-
18	R	1	-	-	-	-	1
รวม		5	1	1	3	5	14

ปัจจุบันวิธีการบำรุงรักษาปั๊มแบบมอเตอร์ปิดผนึก คือ ใช้วิธีการอ่านค่าจากเซนเซอร์ที่วัดค่าพารามิเตอร์ต่าง ๆ ของปั๊ม จากนั้นนำมาแปรผลเป็นสถานะของปั๊มเพื่อใช้ในการวางแผนบำรุงรักษา โดยปั๊มแต่ละรายการจะมีเซนเซอร์ที่สำคัญดังนี้


1. เซนเซอร์วัดค่าสภาพของลูกปืนชนิดทรงกระบอกคาร์บอน (Carbon Bush) ตัวเซนเซอร์จะถูกติดตั้งอยู่ภายในตัวปั๊ม ใช้หลักการวัดสภาพจากค่าความต้านทานที่อ่านได้ จากนั้นส่งสัญญาณออกมาเป็นค่ากระแสวัดมาตรฐาน (4 – 20 mA) และแปลงค่าเป็นเปอร์เซ็นต์ (0 – 100%) และมีมาตรวัดแสดงสีเขียว ส้ม และแดง โดยค่าสภาพของลูกปืนชนิดทรงกระบอกคาร์บอน แบ่งออกเป็น 2 ส่วนคือ ค่าด้านแนวแกน (Radial) และค่าแนวเพลลา (Axial) ดังตัวอย่างรูปที่ 4



รูปที่ 4 มาตรวัดค่าสภาพของลูกปืนชนิดทรงกระบอกคาร์บอน [3]

2. เซนเซอร์วัดค่าอุณหภูมิของขดลวดภายในปั๊มในหน่วยองศาเซลเซียส
3. เซนเซอร์วัดค่ากระแสไฟฟ้าที่ใช้ขณะปั๊มทำงานในหน่วยแอมแปร์
4. เซนเซอร์วัดค่าสภาพกระบวนการผลิตฝั่งขาเข้าและขาออกปั๊มดังตัวอย่างในรูป 5 เช่น
 - อุณหภูมิ (Temperature) ฝั่งขาเข้าของ ของเหลวขาเข้าปั๊มในหน่วยองศาเซลเซียส
 - ปริมาณระดับ (Level) ของเหลวในภาชนะบรรจุฝั่งขาเข้าในหน่วยเปอร์เซ็นต์

- อัตราการไหล (Flow Rate) ของเหลวออกจากปั๊มในหน่วยกิโลกรัมต่อชั่วโมง



รูปที่ 5 ตัวอย่างตำแหน่งเซนเซอร์

ปัญหาที่พบคือการบริหารจัดการข้อมูลพารามิเตอร์ของปั๊มจำนวนมากที่ต้องทำการอ่านค่าและประเมินสถานะ ซึ่งถ้าพิจารณาเฉพาะจำนวนพารามิเตอร์ของปั๊มที่มีระดับความสำคัญสูง 18 รายการ มีค่าพารามิเตอร์ที่ต้องอ่านค่าและประเมินสถานะ ทั้งหมด 111 พารามิเตอร์ จำแนกตามจำนวนอุปกรณ์ดังรูปที่ 6 และ อีกปัญหาหนึ่งคือ ค่าพารามิเตอร์ของปั๊มมีลักษณะเป็นข้อมูลที่เกิดขึ้นต่อเนื่องตามแกนเวลา (Continuous Time series data) แต่ด้วยศักยภาพของคนไม่สามารถอ่านค่าและประเมินสถานะ ได้ตลอดเวลาตามข้อมูลที่เกิดขึ้นตลอดเวลา

Pump Tag	Online Parameter	UOM	Pump Tag	Online Parameter	UOM	Pump Tag	Online Parameter	UOM
A	Current	A	F	Current	A	M	Current	A
	Radial Condition	%		Radial Condition	%		Radial Condition	%
	Axial Condition	%		Axial Condition	%		Axial Condition	%
	Winding Temp	C		Winding Temp	C		Winding Temp	C
	Suction Temp	C		Suction Temp	C		Suction Temp	C
	Suction Level	%		Suction Level	%		Suction Level	%
	Flow Rate No.1	kg/h		Life Time	Day		Flow Rate	kg/h
	Second Path Valve	%		Current	A		Life Time	Day
	Life Time	Day		Radial Condition	%		Current	A
				Axial Condition	%		Radial Condition	%
B	Current	A	G	Winding Temp	C	N	Axial Condition	%
	Radial Condition	%		Suction Temp	C		Winding Temp	C
	Axial Condition	%		Suction Level	%		Suction Temp	C
	Winding Temp	C		Second Path Valve	%		Suction Level	%
	Suction Temp	C		Life Time	Day		Flow Rate	kg/h
	Suction Level	%		Current	A		Life Time	Day
	Flow Rate	kg/h		Radial Condition	%		Current	A
	Life Time	Day		Axial Condition	%		Radial Condition	%
				Winding Temp	C		Axial Condition	%
				Suction Temp	C		Winding Temp	C
C1	Current	A	H	Suction Level	%	O	Suction Temp	C
	Radial Condition	%		Flow Rate	kg/h		Suction Level	%
	Axial Condition	%		Life Time	Day		Second Path Valve	%
	Winding Temp	C		Current	A		Life Time	Day
	Flow Rate	kg/h		Radial Condition	%		Current	A
	Suction Level	%		Axial Condition	%		Radial Condition	%
	Life Time	Day		Winding Temp	C		Axial Condition	%
				Suction Temp	C		Winding Temp	C
				Suction Level	%		Suction Temp	C
				Flow Rate	kg/h		Suction Level	%
C2	Current	A	I	Life Time	Day	P	Second Path Valve	%
	Radial Condition	%		Current	A		Life Time	Day
	Axial Condition	%		Radial Condition	%		Current	A
	Winding Temp	C		Axial Condition	%		Radial Condition	%
	Flow Rate	kg/h		Winding Temp	C		Axial Condition	%
	Suction Level	%		Suction Temp	C		Winding Temp	C
	Life Time	Day		Suction Level	%		Suction Temp	C
				Flow Rate	kg/h		Suction Level	%
				Life Time	Day		Second Path Valve	%
				Current	A		Life Time	Day
D	Current	A	J	Life Time	Day	Q	Current	A
	Radial Condition	%		Current	A		Radial Condition	%
	Axial Condition	%		Radial Condition	%		Axial Condition	%
	Winding Temp	C		Axial Condition	%		Winding Temp	C
	Suction Temp	C		Winding Temp	C		Suction Temp	C
	Suction Level	%		Suction Temp	C		Suction Temp	C
	Second Path Valve	%		Suction Level	%		Suction Level	%
	Life Time	Day		Flow Rate	kg/h		Suction Level	%
				Life Time	Day		Flow Rate	%
				Life Time	Day		Life Time	Day
E	Current	A	K	Current	A	R	Current	A
	Radial Condition	%		Radial Condition	%		Radial Condition	%
	Axial Condition	%		Axial Condition	%		Axial Condition	%
	Winding Temp	C		Winding Temp	C		Winding Temp	C
	Suction Temp	C		Suction Temp	C		Suction Temp	C
	Suction Level	%		Suction Level	%		Suction Temp	C
	Life Time	Day		Flow Rate	kg/h		Suction Level - Mid	%
				Life Time	Day		Flow Rate - Bot	%
				Life Time	Day		Life Time	Day
				Life Time	Day		Life Time	Day

รูปที่ 6 รายการพารามิเตอร์โดยจำแนกตามปั๊ม

จากการประเมินเวลาที่ใช้ในการอ่านค่าและประเมินสถานะปั๊มหนึ่งรายการจะใช้เวลาครั้งละหนึ่งนาทีก่อนที่ในกรณีที่ไม่มีพบสิ่งผิดปกติหรือสัญญาณการเสียหายซ่อนเร้น (Potential Failure) แต่ถ้าพบจะใช้เวลาอย่างน้อยสามสิบนาทีในการวิเคราะห์ถึงสาเหตุและวิธีการบำรุงรักษา ซึ่งความถี่ในการอ่านค่าและประเมินสถานะคืออย่างน้อยหนึ่งครั้งต่อสัปดาห์ เมื่อประเมินเวลาที่ปั๊มจะมีค่าเฉลี่ยต่อปีอยู่ที่ 23.7 ชั่วโมงต่อปี อ้างอิงจากจำนวนพารามิเตอร์และประวัติการเสีย ปี 2559 ถึง 2563 ของปั๊มแบบมอเตอร์ปิดผนึกระดับความสำคัญสูงในโรงงานตัวอย่าง ดังตารางที่ 3

ตารางที่ 3 ชั่วโมงการทำงานในการอ่านค่าและประเมินสถานะปั๊มแบบมอเตอร์ปิดผนึกระดับ
ความสำคัญสูง

จำนวนครั้งที่พบสิ่ง ผิดปกติ (ครั้ง)	ปี 2559	ปี 2560	ปี 2561	ปี 2562	ปี 2563	เฉลี่ย
เวลาที่ใช้ในการ ทำงานต่อหนึ่งปี (ชั่วโมง)	24.7	22.7	22.7	23.7	24.7	23.7

จากปัญหาในข้างต้นจึงเป็นมูลเหตุให้ในการดำเนินงานวิจัยนี้ ซึ่งมุ่งเน้นไปที่การปรับปรุง
วิธีการอ่านค่าและประเมินสถานะปั๊มแบบมอเตอร์ปิดผนึกกลุ่มระดับความสำคัญสูงด้วยข้อมูล
พารามิเตอร์ของโรงงานตัวอย่าง โดยพัฒนาเป็นระบบผู้เชี่ยวชาญ

1.3 วัตถุประสงค์ของงานวิจัย

พัฒนาระบบผู้เชี่ยวชาญในการพยากรณ์สถานะปั๊มแบบมอเตอร์ปิดผนึก ซึ่งผลลัพธ์ที่ได้จะ
เป็นระบบผู้เชี่ยวชาญที่ผ่านการประยุกต์ใช้องค์ความรู้ของผู้เชี่ยวชาญปั๊มแบบมอเตอร์ปิดผนึก
(Domain Knowledge) และข้อมูลพารามิเตอร์ของปั๊มแบบมอเตอร์ปิดผนึก มาสร้างแบบจำลองหรือ
ส่วนประมวลผลของระบบผู้เชี่ยวชาญ และใช้กระดานแสดงผล (Dashboard) แสดงสถานะ โดยมี
เป้าประสงค์เพื่อลดเวลาการทำงานและเพิ่มประสิทธิภาพของผู้อ่านค่าและประเมินสถานะ ปั๊มแบบ
มอเตอร์ปิดผนึก กลุ่มระดับความสำคัญสูงของโรงงานตัวอย่าง

1.4 ขอบเขตของงานวิจัย

- พารามิเตอร์ของปั๊มที่นำมาใช้ในการสร้างแบบจำลองของระบบผู้เชี่ยวชาญจะเป็นข้อมูลจาก
ออนไลน์เซนเซอร์ โดยค่าพารามิเตอร์จะถูกจัดเก็บในหน่วยจัดเก็บข้อมูล (Server) สามารถ
นำมาแสดงผลย้อนหลังผ่านโปรแกรมไมโครซอฟท์เอ็กเซล (Microsoft Excel) หรือผ่าน
คอมพิวเตอร์ของหน่วยจัดเก็บข้อมูล (Server Client PC) ในกรณีที่พารามิเตอร์ของปั๊มที่
ไม่ได้ถูกวัดค่าและถูกจัดเก็บจากออนไลน์เซนเซอร์จะไม่อยู่ในขอบเขตงานวิจัยนี้
- แบบจำลองของระบบผู้เชี่ยวชาญจะถูกสร้างและทดสอบจากข้อมูลปั๊มแบบมอเตอร์ปิดผนึก
(Canned Motor Pump) ของโรงงานตัวอย่าง

3. ข้อมูลจะถูกจัดเก็บที่ช่วงเวลาเดียวกันความถี่ของการเก็บข้อมูลเท่ากัน
4. วิเคราะห์ลักษณะการเสียและระดับผลกระทบ (Failure Mode and Effect Analysis, FMEA)
5. สร้างแบบจำลองวิเคราะห์และแสดงผลข้อมูลตามวัตถุประสงค์ ประยุกต์ใช้ หลักการทางคณิตศาสตร์ ข้อมูลทางสถิติ วิธีการพยากรณ์ (Forecasting) องค์กรความรู้ของผู้ทำวิจัย และอัลกอริทึมการเรียนรู้เรื่องของเครื่อง (Machine Learning)
6. สร้างแผนผังแสดงสถานะของอุปกรณ์ (Dashboard) แสดงผลของระบบผู้เชี่ยวชาญ

1.5 ขั้นตอนการศึกษาและวิธีการดำเนินการวิจัย

รายละเอียดขั้นตอนการศึกษาและวิธีการดำเนินการวิจัยแสดงดังตารางที่ 4

ตารางที่ 4 ขั้นตอนการศึกษา วิธีการดำเนินการวิจัย และผลที่คาดว่าจะได้รับ

ลำดับ	ขั้นตอนการศึกษา	วิธีการดำเนินการวิจัย	ผลที่คาดว่าจะได้รับ
1.	ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง	สืบค้นทฤษฎีและงานวิจัยที่เกี่ยวข้อง	รับทราบถึงงานวิจัยที่เกี่ยวข้องมาปรับใช้ในงานวิจัย
2.	เลือกชนิดของแบบจำลองจากผลของการศึกษา	นำผลการศึกษาในขั้นตอนที่ 1 มาใช้ในการเลือกชนิดของแบบจำลอง	ได้ชนิดของแบบจำลอง อย่างน้อย 3 รูปแบบเพื่อมาทำการวิจัยและเปรียบเทียบผล
3.	จัดเตรียมข้อมูล	รวบรวมข้อมูลที่เกี่ยวข้อง อาทิ เช่น ค่าพารามิเตอร์ต่างๆ ที่ใช้ในการงานวิจัย ประวัติการเสีย	ข้อมูลที่ถูกแบ่งกลุ่มของข้อมูลไว้สำหรับสร้างแบบจำลองและทดสอบความแม่นยำ
4.	จัดรูปแบบข้อมูลให้พร้อมใช้งาน	ทำการการจัดการข้อมูลที่สูญหาย (Missing Data) , ทำความสะอาดข้อมูล (Data Cleaning)	ข้อมูลพร้อมสำหรับการนำไปสร้างแบบจำลอง

5.	ทำการวิเคราะห์ข้อมูลเบื้องต้น	ใช้วิธีการวิเคราะห์ลักษณะการเสียและผลกระทบ (Failure Mode and Effect Analysis, FMEA)	ได้ข้อมูลลักษณะการเสียที่สำคัญเพื่อใช้ในการสร้างแบบจำลองของระบบผู้เชี่ยวชาญ
6.	สร้างแบบจำลองระบบผู้เชี่ยวชาญ	ประยุกต์ใช้ หลักการทางคณิตศาสตร์ ข้อมูลทางสถิติ วิธีการพยากรณ์ (Forecasting) องค์ความรู้ของผู้ทำวิจัย และอัลกอริธึมการเรียนรู้ของเครื่อง (Machine Learning)	ได้แบบจำลองระบบผู้เชี่ยวชาญ
7.	ประเมินแบบจำลอง	เปรียบเทียบความแม่นยำของแบบจำลองโดยใช้การคำนวณค่าความคาดเคลื่อน	ได้แบบจำลองระบบผู้เชี่ยวชาญที่มีความแม่นยำอยู่ในเกณฑ์ที่ยอมรับได้และสะดวกต่อการใช้งาน
8.	สร้างแผนผังแสดงผล (Dashboard)	สร้างแผนผังสถานะของปั๊มโดยใช้โปรแกรมไมโครซอฟ์ฟพาวเวอร์บีไอ (MS Power Bi)	ได้แผนผังแสดงผล (Dashboard)
9.	สรุปผลการวิจัย	สรุปผลการวิจัย และสรุปแนวทางการใช้งาน	ข้อสรุปและข้อเสนอแนะที่ได้จากงานวิจัย

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1. ลดเวลาการทำงานในการอ่านค่าและประเมินสถานะจากข้อมูลของปั๊มแบบมอเตอร์ปิดผนึกของโรงงานตัวอย่าง
2. มีเครื่องมือที่มีประสิทธิภาพในการกำหนดแผนบำรุงรักษา
3. ปรับปรุงวิธีการทำงานโดยลดความคลาดเคลื่อนจากการทำงานแบบเดิม
4. นำเครื่องมือที่ได้ไปขยายผลใช้กับกรณีอื่น ๆ ที่มีลักษณะปัญหาคล้ายกัน


บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 ปัมป์แบบมอเตอร์ปิดผนึก (Canned Motor Pump, CMP) [4]

ปัมป์แบบมอเตอร์ปิดผนึกเป็นการรวมกันระหว่างปัมป์แบบแรงเหวี่ยงหนีศูนย์กลาง (Centrifugal Pump) กับอินดักชันมอเตอร์ที่มีโรเตอร์แบบกรงกระรอก (Squirrel Cage Induction Motor) โดยสร้างให้อยู่ในภาชนะบรรจุที่ปิดสนิท (Hermetically sealed unit) ดังรูปที่ 7



รูปที่ 7 ตัวอย่างแบบปัมป์แบบมอเตอร์ปิดผนึก (Typical canned motor pump) [4]

โดยทั่วไปใบพัด (Impeller) ของปัมป์ประเภทนี้จะถูกออกแบบเป็นประเภทปิด (Closed Type) และติดตั้งอยู่ที่ปลายเพลา (Shaft) ซึ่งจะใช้เพลาร่วมกับมอเตอร์ ในส่วนของโรเตอร์ (Rotor) ซึ่งอุปกรณ์ที่อยู่บนเพลาทันทีทั้งหมด จะทำงานภายในของเหลวที่ภายในปัมป์เพื่อทำหน้าที่ระบายความร้อนภายในโรเตอร์และหล่อลื่นชุดลูกปืนชนิดทรงกระบอกคาร์บอน (Carbon Bush Bearing) โดยของเหลวจะไม่สัมผัสกับชุดขดลวดมอเตอร์เพราะจะมีกระบอก (Canned) ป้องกันของเหลวหุ้มอยู่อีกชั้นหนึ่ง ในส่วนของสเตเตอร์ (Stator) ก็จะอยู่คนละห้องกับโรเตอร์ (Rotor)

การทำงานของปั๊มแบบมอเตอร์ปิดผนึกนั้นจะเป็นการหมุนของชุดโรเตอร์ที่มีการติดตั้งใบพัดของปั๊มไว้ที่ปลายเพลลา ผ่านการเหวี่ยงนำสนามแม่เหล็กโดยชุดขดลวดมอเตอร์ในฝั่งสเตเตอร์และโรเตอร์ ซึ่งจะมีของเหลวที่ไหลผ่านตัวปั๊มเข้าไปหล่อลื่นภายในโรเตอร์

2.1.2 การวิเคราะห์ลักษณะการเสียและระดับผลกระทบ (Failure Mode and Effect Analysis, FMEA) [5]

เป็นวิธีการเชิงคุณภาพ (Qualitative Method) ที่ถูกใช้ในการวิเคราะห์โอกาสหรือลักษณะการเสีย (Failure Mode) ของเครื่องจักรหรือชิ้นส่วนและ วิเคราะห์ผลกระทบ (Failure Effect) ของการเสียนั้นต่อหน้าที่การทำงานของเครื่องจักรหรือชิ้นส่วนนั้น ๆ อย่างเป็นระบบโดยมุ่งเน้นการระบุปัจจัยที่ส่งผลต่อเสถียรภาพของเครื่องจักรหรือระบบ ซึ่งวิธีการนี้ถูกพัฒนาในช่วงปี 1950 โดยอุตสาหกรรมทางการทหารและการบิน (Aerospace) จากนั้นได้กระจายไปที่อุตสาหกรรมประเภทอื่น ๆ การวิเคราะห์จะใช้กลุ่มคนที่เป็นผู้เชี่ยวชาญเกี่ยวกับเครื่องจักร อาทิ เช่น ผู้ควบคุมเครื่องจักร ผู้บำรุงรักษาเครื่องจักร โดยลักษณะการเสีย (Failure Mode) นั้นหาได้จากการตรวจสอบโอกาสในการเกิดข้อผิดพลาดตามหลัก “6M” คือ Man, Material, Machine, Measurement, Method และ environment (“Milieu”)

2.1.3 การจัดการข้อมูล [6]

1. การจัดการข้อมูลสูญหาย (Missing Data)

คือ การจัดการข้อมูลที่บางส่วนสูญหาย (Missing Data) ซึ่งข้อมูลที่สูญหายนี้จะทำให้เกิดปัญหาในการนำไปใช้เช่น การสร้างแบบจำลองทางคณิตศาสตร์ ทำให้จะต้องทำการจัดการข้อมูลในส่วนนี้ก่อนนำไปใช้งาน โดยสามารถแบ่งประเภทของข้อมูลสูญหายได้ดังนี้

- ข้อมูลสูญหายแบบสุ่มอย่างสมบูรณ์ (Missing completely at random, MCAR) คือ ข้อมูลสูญหายทุกชุดข้อมูล และข้อมูลที่สูญหายไม่ขึ้นกับค่าใดค่าหนึ่ง ข้อมูลที่สูญหายนั้นเป็นอิสระต่อกัน (Independent)
- ข้อมูลสูญหายแบบสุ่ม (Missing at random, MAR) คือ ข้อมูลสูญหายบางส่วนหรือบางกลุ่มของตัวแปรหรือบางตัว ซึ่งข้อมูลที่สูญหายนั้นเป็นอิสระต่อกัน (Independent) เนื่องจากข้อมูลบางตัวแปรไม่สูญหายไปด้วย จึงสามารถใช้หลักการทางสถิติมาช่วยได้
- ข้อมูลสูญหายแบบไม่สุ่ม (Missing Not At Random, MNAR) คือ ข้อมูลสูญหายซึ่งไม่ได้เกิดแบบสุ่ม โดยค่าของข้อมูลสูญหายขึ้นอยู่กับปัจจัยบางอย่าง เช่น ข้อมูลความชื้นหายในช่วงอุณหภูมิต่ำ

การจัดการกับข้อมูลสูญหายที่ดีที่สุดคือการนำข้อมูลที่แท้จริง (Actual Data) มาใส่แต่ในกรณีที่ไม่สามารถนำข้อมูลจริงมาใส่ได้นั้นจะมีวิธีอื่นๆ มาช่วย ดังนี้

- การลบทิ้ง คือ การตัดหรือลบข้อมูลที่ไม่ครบถ้วนหรือไม่สมบูรณ์ออกจากชุดข้อมูลโดยแบ่งวิธีย่อยออกเป็น 2 วิธี คือ
 1. การตัดข้อมูลแบบลิสทไวส์ (Listwise deletion) คือ วิธีการลบข้อมูลที่ไม่ครบถ้วนหรือไม่สมบูรณ์ออกไปทั้งแถว (Row) จะทำให้ชุดข้อมูลหายไปตามจำนวนที่ถูกลบออก เหมาะสำหรับข้อมูลสูญหายจำนวนไม่มาก
 2. การตัดข้อมูลแบบแพรวไวส์ (Pairwise deletion) คือ การนำข้อมูลเท่าที่มีมาใช้ ถ้าข้อมูลชุดใดสูญหายให้ข้ามไป
- การแทนที่ด้วยข้อมูลทางสถิติ คือ การนำข้อมูลค่าใดค่าหนึ่งมาเติมแทนที่ข้อมูลที่สูญหาย (Single Imputation Method) โดยข้อมูลที่นำมาเติมจะใช้ค่าทางสถิติ เช่น ค่าเฉลี่ย, ค่ามัธยฐาน จากข้อมูลที่มี
- การแทนที่ด้วยข้อมูลก่อนหน้า หรือข้อมูลถัดไป คือ การนำข้อมูลก่อนหน้า หรือข้อมูลถัดไปมาเติม (Imputation) แทนข้อมูลตำแหน่งที่สูญหาย มักใช้กับข้อมูลอนุกรมเวลา (Time series data)
- การคำนวณและใช้เทคนิคทางสถิติ คือ การวิเคราะห์ด้วยเทคนิคต่าง ๆ ทางสถิติ เช่นวิเคราะห์ด้วยสมการถดถอย (Regression)

2. การทำความสะอาดข้อมูล (Clean Data) [6]

การทำความสะอาดข้อมูล คือ กระบวนการตรวจสอบ แก้ไข ปรับแต่ง ลบรายการข้อมูลที่ไม่ถูกต้องออกไปจากชุดข้อมูล รวมถึงการปรับแต่งโครงสร้างบางส่วน (ที่ไม่กระทบกับตัวข้อมูล) เช่น ลบคอลัมน์ที่ไม่ใช่, เปลี่ยนชื่อคอลัมน์, ตรวจสอบและแก้ไขชนิดของข้อมูล, จัดการค่าทศนิยม, จัดการข้อมูลซ้ำ เป็นต้น เพื่อให้ข้อมูลมีคุณภาพเพียงพอในการเอาไปสร้างแบบจำลองตามเป้าประสงค์ต่าง ๆ

3. การจัดการค่าผิดปกติในข้อมูล (Correct Data) [6]

ค่าผิดปกตินอกช่วง (Outlier) เป็นค่าหรือจุดข้อมูลที่มีค่าแตกต่างไปจากข้อมูลในกลุ่มอย่างผิดปกติ คือ มีค่ากระโดดห่างจากข้อมูลส่วนใหญ่มากผิดปกติ ซึ่งวิธีกำจัดค่าผิดปกติออกจากชุดข้อมูลอาจประกอบไปด้วย

- การใช้บ็อกพล็อต (Boxplot) ดูจุดข้อมูลผิดปกติ
- การคำนวณหาค่าผิดปกติด้วย ค่าพิสัยระหว่างควอไทล์ (interquartile range, IQR)
- การคำนวณหาค่าผิดปกติด้วยวิธี ค่าคะแนนมาตรฐาน (Z-Score)

2.1.4 การเรียนรู้ของเครื่อง (Machine Learning) [7]

ในปัจจุบันวิธีการเรียนรู้ของเครื่องนั้นมีการแบ่งประเภทออกเป็น 3 ประเภทดังนี้

1. การเรียนรู้แบบมีการสอน (Supervised Learning) เป็นการเรียนรู้แบบที่ต้องมีการสอน (Train) คือ ให้คอมพิวเตอร์หรือโปรแกรม เรียนรู้จากชุดข้อมูลสำหรับการสอน (Training Data) โดยการเรียนรู้แบบมีผู้สอนนั้นมีการแบ่งประเภทย่อยอีก 2 ประเภท คือ
 - วิธีการจำแนก (Classification) เป็นการคัดแยกข้อมูลแล้วระบุเป็นผลลัพธ์จากการเรียนรู้จากชุดข้อมูลสำหรับการสอน (Training Data)
 - วิธีการทำนายค่า (Regression) เป็นการทำนายค่าเป็นตัวเลขจากตัวแปรทำนาย
2. การเรียนรู้แบบไม่ต้องมีการสอน (Unsupervised Learning) เป็นการเรียนรู้แบบที่ไม่ต้องมีการสอน ซึ่งผลลัพธ์ของการเรียนรู้แบบนี้ไม่จำเป็นผลลัพธ์ใหม่ออกมาแต่อาจจะเป็นผลการจับกลุ่มของข้อมูล (Clustering) และหาความสัมพันธ์ (Association)
3. การเรียนรู้ด้วยการป้อนกลับผลลัพธ์ (Reinforcement Learning) เป็นการเรียนรู้ที่ต้องการข้อมูลป้อนกลับมา (Feedback) จากผลลัพธ์ที่ออก เพื่อนำไปเรียนรู้และปรับปรุงผลลัพธ์ใหม่ให้ได้ตามเป้าหมาย

องค์ประกอบหรือโครงสร้างของการเรียนรู้ของเครื่อง (Machine Learning Component) [7]

1. แบบจำลอง (Model) คือ ระบบประมวลผลที่ใช้ อัลกอริทึม (Algorithm) ในการประมวลผล ซึ่งแบบจำลองอาจอยู่ในรูปแบบ สมการทางคณิตศาสตร์ หรือ โลจิก (Logic) ของโปรแกรมคอมพิวเตอร์ ตามประเภทของ อัลกอริทึม ที่เลือกใช้ ซึ่งสามารถวัดผลหรือประเมินประสิทธิภาพด้วยวิธีการต่างๆ ตามลักษณะของจำลอง ร่วมกับชุดข้อมูล
2. ชุดข้อมูล (Data set) คือ ข้อมูลที่ได้รวบรวมไว้เพื่อนำมาสอนให้กับคอมพิวเตอร์เพื่อสร้างเป็นโมเดลหรือใช้ทดสอบความถูกต้องแม่นยำของโมเดล
3. ฟีเจอร์ (Features) คือ คุณลักษณะเด่นของข้อมูลเพื่อนำไปใช้ในการสร้างแบบจำลอง
4. เป้าหมาย (Target) คือ สิ่งที่ต้องการให้แบบจำลองประมวลผล เช่น ทำนาย (Predict) หรือ จำแนก (Classification)
5. อัลกอริทึม (Algorithm) คือ วิธีหรือขั้นตอนกระบวนการคิดในโปรแกรมคอมพิวเตอร์ ซึ่งอาจจะอยู่ในรูปแบบสมการคณิตศาสตร์

2.1.5 การประเมินแบบจำลองการเรียนรู้ของเครื่อง [8]

วิธีการประเมินแบบจำลองจะแตกต่างกันตามลักษณะแบบจำลอง โดยจะแบ่งเป็น 2 กลุ่มใหญ่ ๆ สำหรับแบบจำลองการเรียนรู้แบบมีการสอน (Supervised Learning)

1. แบบจำลองการวิเคราะห์การถดถอย (Regression) จะได้ผลลัพธ์เป็นค่าตัวเลข การประเมินแบบจำลองใช้การวัดค่าความคลาดเคลื่อน (Error หรือ Residual)
2. แบบจำลองการจำแนก (Classification) จะได้ผลลัพธ์เป็นข้อมูลแบบหมวดหมู่หรือเป็นคลาส (Class) เช่น ศูนย์/หนึ่ง , ใช่/ไม่ใช่ และจะใช้ตารางที่เรียกว่า ตารางเมทริกซ์ความสับสน (Confusion Matrix) ในการเก็บข้อมูลผลลัพธ์

ตารางเมทริกซ์ความสับสน (Confusion Matrix) [10] คือ ตารางที่ใช้เก็บข้อมูลผลลัพธ์สรุปผลการทำนาย (Prediction) เปรียบเทียบกับผลลัพธ์จริง (Actual) ซึ่งขนาดของเมทริกซ์ขึ้นอยู่กับจำนวนคลาส (Class) ของข้อมูล ถ้าข้อมูลมีสองคลาสเมทริกซ์จะมีขนาด 2×2 การใส่ค่าที่ได้จากการทำนายและผลการทำนายในตารางจะทำในลักษณะสองมิติโดยฝั่งแถว (Row) จะเป็นค่าจริงและคอลัมน์ (Column) จะเป็นผลการทำนาย โดยคำศัพท์ที่เกี่ยวข้องมีดังนี้และรูปที่ 8

- “True Positive (TP)” คือ มีการทำนายถูกต้องสำหรับผลในทางบวกเช่น “Yes”
- “True Negative (TN)” คือ มีการทำนายถูกต้องสำหรับผลในทางลบเช่น “No”
- “False Positive (FP)” คือ มีการทำนายผิดต้องสำหรับผลในทางบวกเช่น “Yes” (Type I Error)
- “False Negative (FN)” คือ มีการทำนายผิดต้องสำหรับผลในทางลบเช่น “No” (Type II Error)

		inferred class					inferred class	
		A	B	C			A	not-A
true class	A	a	b	c	A	a	b+c	
	B	d	e	f		(TP)	(FN)	
	C	g	h	i	not-A	d+g	e+f+h+i	
						(FP)	(TN)	

รูปที่ 8 ตัวอย่างตารางเมทริกซ์ความสับสน [10]

การคำนวณจากการประเมินแบบจำลองด้วยตารางเมทริกซ์ความสับสน [9]

การคำนวณใช้ค่าที่ได้ในตารางเมทริกซ์ความสับสนมาคำนวณเพื่อประเมินแบบจำลองในมิติต่างๆ กันตามเป้าประสงค์ของโมเดล

1. ค่าความแม่นยำ (Accuracy) คือสัดส่วนเปอร์เซ็นต์ความถูกต้องต่อจำนวนผลทำนายทั้งหมด ดังสมการที่ 4

$$\text{Accuracy} = \frac{TF+TN}{All} \quad (4)$$

2. ค่าความเที่ยงตรง (Precision) คือ ความแม่นยำผลทำนาย (สนใจผลทำนาย หรือ Prediction) โดยคำนวณเป็นสัดส่วนที่ทำนายว่าเป็น “Positive” หรือ “Negative” เป็นจำนวนที่เปอร์เซ็นต์ สามารถคำนวณได้จากสมการที่ 5 และ 6

$$\text{Precision (Positive)} = \frac{TP}{\text{จำนวนที่ทำนายว่า Positive ทั้งหมด}} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{Precision (Negative)} = \frac{TN}{\text{จำนวนที่ทำนายว่า Negative ทั้งหมด}} = \frac{TN}{TN+FN} \quad (6)$$

3. ค่ารีคอล (Recall) คือ การวัดผลการทำนาย (Predict) เทียบกับค่าจริง (Actual) โดยวัดได้ทั้งด้าน “Positive” และ “Negative” ดังสมการที่ 7 และ 8

$$\text{Recall (Positive)} = \frac{TP}{\text{จำนวนของจริงว่า Positive ทั้งหมด}} = \frac{TP}{TP+FN} \quad (7)$$

$$\text{Recall (Negative)} = \frac{TN}{\text{จำนวนของจริงว่า Negative ทั้งหมด}} = \frac{TN}{TN+FP} \quad (8)$$

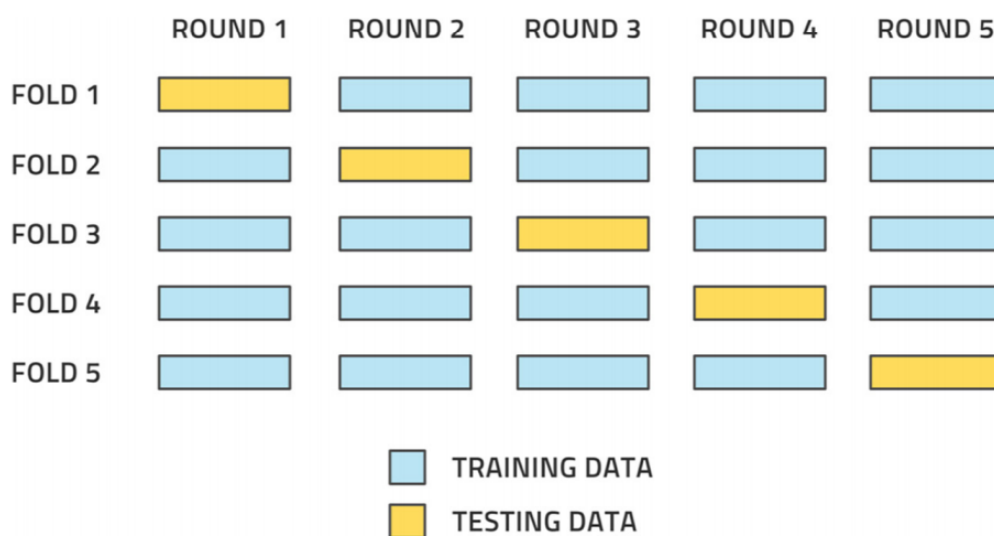
4. ค่าเอฟวันสกอร์ (F1 score) คือ ค่าแสดงประสิทธิภาพโดยรวมโดยการนำค่าความเที่ยงตรง (Precision) และ ค่ารีคอล (Recall) มาคำนวณหาค่าเฉลี่ยฮาร์โมนิก (Harmonic mean) ซึ่งค่าสูงจะถือได้ว่าแบบจำลองมีประสิทธิภาพดี ดังสมการที่ 9

$$F1 \text{ Score} = \frac{2 P R}{P+R} \quad (9)$$

การแบ่งข้อมูลสำหรับการทดสอบ [10]

ข้อมูลที่นำมาใช้ประเมินแบบจำลองไม่ควรเป็นชุดข้อมูลเดียวกับข้อมูลที่น่าไปสอนโปรแกรม โดยจะต้องแบ่งชุดของข้อมูลออกมาเป็นสองส่วน คือ ส่วนที่น่าไปสอนโปรแกรม (Training set) อาจจะมีประมาณแปดสิบเปอร์เซ็นต์ของข้อมูลทั้งหมด และส่วนที่น่าไปใช้ทดสอบ (Test set) ประมาณยี่สิบเปอร์เซ็นต์ของข้อมูล

อีกวิธีหนึ่งของการแบ่งข้อมูลคือวิธีแบ่งแบบ “Cross Validation” แบบ “K-Fold” เป็นการแบ่งชุดข้อมูลออกเป็นส่วน ๆ เท่ากัน เช่น แบ่งชุดข้อมูลออกมาเป็นห้าส่วน (5-Fold) จากนั้นเลือกข้อมูลหนึ่งส่วนเอาไว้ทดสอบ ส่วนที่เหลือนำไปสอนโปรแกรม จากนั้นเปลี่ยนชุดข้อมูลที่ทดสอบเป็นข้อมูลอีกส่วนหนึ่ง อีกส่วนนำไปสอนโปรแกรม ทำวนซ้ำจนครบทั้งห้าส่วน จากนั้นนำผลการประเมินประสิทธิภาพของแต่ละส่วนมาหาค่าเฉลี่ย ดังรูปที่ 9



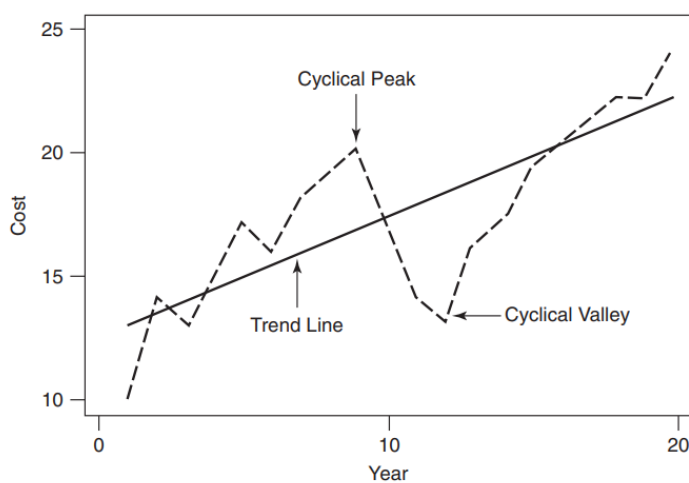
รูปที่ 9 การแบ่งแบบ “Cross Validation” [11]

2.1.7 การพยากรณ์ (Forecasting) [12]


การพยากรณ์ไม่ใช่การเดาหรือคาดคะเนแต่เป็นการประเมินสิ่งที่จะเกิดขึ้นในอนาคตโดยใช้การวิเคราะห์ข้อมูลในอดีต และ กระบวนการคิดอย่างเป็นระบบ ภายใต้สมมติฐานว่าสิ่งที่เกิดขึ้นในปัจจุบันจะส่งผลต่ออนาคต โดยงานวิจัยนี้จะมุ่งเน้นไปที่การพยากรณ์ข้อมูลอนุกรมเวลา (Time series data) เป็นหลัก ซึ่งขั้นตอนแรกของการพยากรณ์ข้อมูลอนุกรมเวลาคือการประเมินลักษณะ

ของข้อมูล (Explore Data Pattern) ลักษณะข้อมูลที่แตกต่างกันจะใช้วิธีการทำนายที่ต่างกัน โดยลักษณะของข้อมูลอนุกรมเวลาจะถูกแบ่งเป็น 4 ลักษณะ คือ

1. ข้อมูลลักษณะคงที่ (Stationary)
2. ข้อมูลลักษณะมีแนวโน้มขึ้นหรือลง (Trend) ดังรูปที่ 10
3. ข้อมูลลักษณะเปลี่ยนแปลงตามฤดูกาล (Seasonal) ดังรูปที่ 10
4. ข้อมูลลักษณะขึ้นลงเป็นวัฏจักร (Cyclical) ดังรูปที่ 11



รูปที่ 10 ตัวอย่างลักษณะข้อมูลมีแนวโน้มขึ้นและมีวัฏจักร [12]



รูปที่ 11 ตัวอย่างลักษณะข้อมูลเปลี่ยนแปลงตามฤดูกาล [12]

วิธีการพยากรณ์อย่างง่าย (Naive) เป็นตัวอย่างวิธีการพยากรณ์ที่มีความซับซ้อนน้อย สามารถเข้าใจได้ง่ายโดยมีหลักการ คือ เป็นการพยากรณ์ที่ถือว่าช่วงเวลาล่าสุดเป็นตัวทำนายอนาคตที่ดีที่สุด ซึ่งมีตัวอย่างสมการทางคณิตศาสตร์ รูปที่ 12

Naive model	$\hat{Y}_{t+1} = Y_t$
Naive trend model	$\hat{Y}_{t+1} = Y_t + (Y_t - Y_{t-1})$
Naive rate of change model	$\hat{Y}_{t+1} = Y_t \frac{Y_t}{Y_{t-1}}$
Naive seasonal model for quarterly data	$\hat{Y}_{t+1} = Y_{t-3}$
Naive trend and seasonal model for quarterly data	$\hat{Y}_{t+1} = Y_{t-3} + \frac{Y_t - Y_{t-4}}{4}$

รูปที่ 12 สมการคำนวณ การพยากรณ์อย่างง่าย [12]

การพยากรณ์โดยใช้ค่าเฉลี่ย (Average) เป็นอีกหนึ่งวิธีที่ได้รับความนิยม เป็นวิธีการพยากรณ์โดยมีสมมติฐานพื้นฐานว่า ความผันผวนของค่าในอดีตนั้นสามารถนำมาใช้ในการพยากรณ์ค่าในอนาคตได้ รูปที่ 13 นั้นเป็นตัวอย่างสมการคำนวณการพยากรณ์โดยใช้ค่าเฉลี่ยในรูปแบบต่าง ๆ

Simple average model

$$\hat{Y}_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i$$

Updated simple average, new period

$$\hat{Y}_{t+2} = \frac{t\hat{Y}_{t+1} + Y_{t+1}}{t + 1}$$

Moving average for k time periods

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k}$$

Double moving average

$$M'_t = \frac{M_t + M_{t-1} + M_{t-2} + \dots + M_{t-k+1}}{k}$$

$$a_t = 2M_t - M'_t$$

$$b_t = \frac{2}{k-1}(M_t - M'_t)$$

$$\hat{Y}_{t+p} = a_t + b_t p$$

รูปที่ 13 สมการคำนวณ การพยากรณ์โดยใช้ค่าเฉลี่ย [12]

วิธีการพยากรณ์โดยประยุกต์ใช้การวิเคราะห์การถดถอยกับข้อมูลอนุกรมเวลา (Regression with time series data) เป็นอีกหนึ่งวิธีที่ได้รับความนิยม โดยมีหลักการ คือ มีสมมุติฐานว่าค่าความคลาดเคลื่อน (Error หรือ Residual, \mathbf{E}) เป็นอิสระกัน (หรือไม่สัมพันธ์กัน) ซึ่งหมายความว่าค่าพยากรณ์ (Prediction, Y) จะขึ้นอยู่กับค่าตัวแปรทำนาย (Predictor, x) เท่านั้น ซึ่งความสัมพันธ์ระหว่าง ค่าพยากรณ์และค่าตัวแปรทำนาย มีความสัมพันธ์เชิงเส้น โดยมีสมการพื้นฐานดังรูปที่ 14

$$Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t \quad (1)$$

with

$$\varepsilon_t = \rho \varepsilon_{t-1} + v_t \quad (2)$$

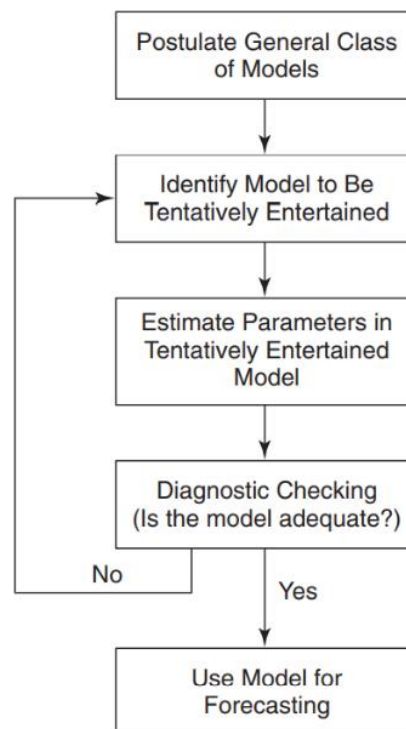
where

- ε_t = the error at time t
- ρ = the parameter (lag 1 autocorrelation coefficient) that measures correlation between adjacent error terms
- v_t = the normally distributed independent error term with mean zero and variance σ_v^2

รูปที่ 14 สมการการวิเคราะห์การถดถอย [12]

การพยากรณ์โดยใช้วิธีการใช้ ค่าเฉลี่ยเคลื่อนที่แบบบูรณาการอัตโนมัติ (Autoregressive integrated moving average, ARIMA) เป็นวิธีการพยากรณ์ ที่อาศัยพฤติกรรมของข้อมูลในอดีต เพื่อกำหนดรูปแบบในปัจจุบันและอธิบายแนวโน้มของข้อมูลในอนาคต มีขั้นตอนดังรูปที่ 15

The Box-Jenkins (ARIMA) Methodology



Source: Box, G. E. P., Jenkins, G. M., and G. C. Reinsel, *Time Series Analysis: Forecasting and Control* (3rd ed.), Upper Saddle River, New Jersey: Prentice Hall, 1994, p.17. Reprinted with permission.

รูปที่ 15 ขั้นตอนของวิธี "ARIMA" [12]

2.1.8 การวัดค่าความคลาดเคลื่อน [12]

เนื่องจากวิธีการพยากรณ์เชิงปริมาณ (Quantitative) มักเกี่ยวข้องกับข้อมูลอนุกรมเวลา โดยค่าพยากรณ์ (Y) ที่ช่วงเวลาใด ๆ จะแสดงเป็นตัวแปร “ Y_t ” ซึ่งหมายถึงค่าพยากรณ์ของอนุกรมเวลา ช่วงเวลา “ t ” ซึ่งในการวัดค่าความคลาดเคลื่อนนั้น มีการคิดค้นวิธีการหลายวิธีเพื่อวัดค่าความคลาดเคลื่อนที่เกิดจากวิธีการพยากรณ์ด้วยวิธีต่างๆ โดยวิธีส่วนใหญ่จะใช้ค่าเฉลี่ยความแตกต่างระหว่างค่าจริงและค่าพยากรณ์ ซึ่งความต่างนี้จะมีค่าคงเหลือ (Residual) หรือ ค่าความคลาดเคลื่อน (Error) อยู่ ซึ่งสามารถคำนวณได้จากสมการในรูปที่ 16

$$e_t = Y_t - \hat{Y}_t$$

where

- e_t = the forecast error in time period t
- Y_t = the actual value in time period t
- \hat{Y}_t = the forecast value for time period t

รูปที่ 16 สมการหาค่าคงเหลือ (Residual) [12]

ซึ่งค่าคงเหลือหรือค่าความคลาดเคลื่อนนี้ ได้ถูกนำไปใช้วัดประสิทธิภาพของการพยากรณ์ในหลายมิติ ขึ้นอยู่กับวิธีการคิดและคำนวณของวิธีนั้นๆ โดยวิธีที่เป็นที่นิยมนั้นแสดงดังตารางที่ 5 [12]

ตารางที่ 5 สมการคำนวณค่าความคลาดเคลื่อน

วิธีการวัดความคลาดเคลื่อน	สมการคำนวณ
The mean absolute deviation (MAD)	$MAD = \frac{1}{n} \sum_{t=1}^n Y_t - \hat{Y}_t $
The mean squared error (MSE)	$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$
The root mean squared error (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}$

The mean absolute percentage error (MAPE)	$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{ Y_t - \hat{Y}_t }{ Y_t }$
The mean percentage error (MPE)	$MPE = \frac{1}{n} \sum_{t=1}^n \frac{(Y_t - \hat{Y}_t)}{Y_t}$

2.2 งานวิจัยที่เกี่ยวข้อง


ผู้วิจัยได้ทำการศึกษางานวิจัยเกี่ยวข้อง อาทิ การนำวิธีการเรียนรู้ของเครื่อง (Machine Learning) มาประยุกต์ใช้ในงานบำรุงรักษาเครื่องจักรประเภทต่างๆ โดยมีตัวอย่างบทความที่ผู้วิจัยได้นำมาศึกษาเพื่ออ้างอิงและปรับปรุงงานวิจัยดังนี้

บทความ “Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges” [13]

บทความนี้เป็นการรวบรวมข้อมูลการทำวิจัยเกี่ยวกับการใช้การเรียนรู้ของเครื่องกับการทำนายสภาพเครื่องจักร (Predictive Maintenance) ย้อนหลังห้าปี (ค.ศ. 2015 – 2020) โดยอ้างอิงจากการเปลี่ยนแปลงของยุคอุตสาหกรรม 4.0 ที่มีการใช้ระบบควบคุมอัตโนมัติ, อินเทอร์เน็ตของสรรพสิ่ง (Internet of Things, ITO) และแบบจำลองเสมือนจริง (Cyber physical System, CPS) เพื่อจัดการกับข้อมูลขนาดใหญ่ และมีการสร้างระบบช่วยวิเคราะห์และตัดสินใจ (Data analytics to design a Decision Support System) ซึ่งจะช่วยให้สามารถแก้ไขการเสียของเครื่องจักรได้เร็วขึ้น ซึ่งระบบช่วยวิเคราะห์และตัดสินใจนั้นใช้การเรียนรู้ของเครื่องมาช่วย ซึ่งผลที่ได้คือ เพิ่มผลิตผลในการะบวนการผลิต, ลดการเสียในระบบ, ลดการหยุดผลิตนอกแผน และเพิ่มประสิทธิภาพของในด้านการเงินและบริหารทรัพยากรบุคคล

สิ่งที่ได้จากการศึกษาบทความนี้คือ การใช้การเรียนรู้ของเครื่องในการบำรุงรักษาเครื่องจักรไม่ใช่เรื่องใหม่ มีการออกแบบและทดลองใช้ในหลายรูปแบบในช่วงปีที่ผ่านมา โดยความท้าทายในการใช้การเรียนรู้ของเครื่องกับงานบำรุงรักษาเครื่องจักรคือ การจัดการกับข้อมูลที่มีความแม่นยำ มีขนาดของข้อมูลที่ใหญ่ และการนำไปใช้ในลักษณะเรียลไทม์ (Real Time) คือสามารถเรียกดูผลลัพธ์ได้ตลอดเวลา และสุดท้ายคือการเลือกอัลกอริทึมที่เหมาะสมกับการนำไปใช้ ดังแสดงในรูปที่ 17 ที่

เป็นรูปแสดงส่วนที่เป็นสิ่งที่สามารถจับต้องได้ (Physical) และส่วนที่เป็นไซเบอร์ (Cyber) ซึ่งเป็นที่ การเรียนรู้ของเครื่องเข้าไปสนับสนุน



รูปที่ 17 ตัวอย่าง “CPS architecture for maintenance and PDM” จากบทความตัวอย่าง [13]

และบทความยังเปรียบเทียบให้เห็นถึงฝั่งกระบวนการทำงานบำรุงรักษาในปัจจุบันซึ่งเป็นผล จากยุคอุตสาหกรรม 3.0 (Industrial 3.0) ซึ่งเน้นไปที่การปรับปรุงเครื่องจักรในกระบวนการผลิต เพิ่ม ความสามารถของทรัพยากรบุคคล ใช้แหล่งพลังงานใหม่ ๆ เช่น ใอน้ำ หรือ ไฟฟ้า เปรียบเทียบกั บการใช้ระบบไซเบอร์เข้ามาช่วยในการบำรุงรักษาในยุคอุตสาหกรรม 4.0 (Industrial 4.0) ดังรูปที่ 18



Fig. 2. Traditional process to perform maintenance.

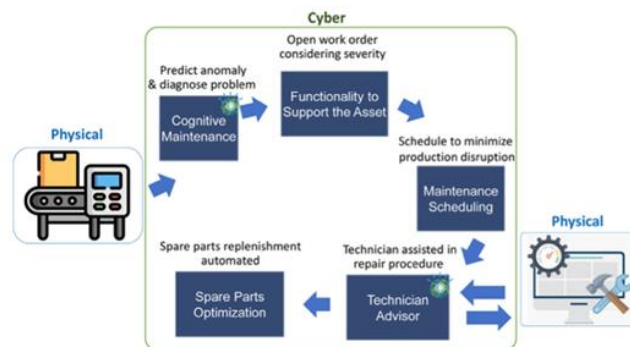


Fig. 3. Cyber-physical process to perform maintenance.

รูปที่ 18 ตัวอย่างเปรียบเทียบกระบวนการทำงานแบบเดิมและใหม่อ้างอิงจากบทความตัวอย่าง [13]

และสุดท้ายในงานวิจัยตัวอย่างได้แสดงแผนผังภาพรวมของเทคนิคต่าง ๆ ของการเรียนรู้ของเครื่องที่ใช้อยู่ในปัจจุบัน ซึ่งทำให้ผู้ทำวิจัยได้เห็นภาพรวมของเทคนิคต่าง ๆ มากขึ้นดังรูปที่ 19




Fig. 9. Taxonomy of machine learning techniques.

รูปที่ 19 ตัวอย่างผังเทคนิคของการเรียนรู้ของเครื่องจากบทความตัวอย่าง [13]

บทความ “Logistic regression model for predicting the failure probability of a landslide dam” [14]

บทความนี้เป็นการใช้แบบจำลองการวิเคราะห์การถดถอยแบบโลจิสติก (Logistic regression) เพื่อทำนายโอกาสในเกิดความเสียหายของเขื่อนจากชุดข้อมูลตัวอย่างจากนั้นนำมาประเมินแบบจำลองโดยใช้ตารางเมทริกซ์ความสับสน (Confusion Matrix) ในการประเมิน

สิ่งที่ได้จากการศึกษาบทความนี้คือตัวอย่างการใช้งานแบบจำลองการวิเคราะห์การถดถอยแบบโลจิสติก (Logistic regression) ในเชิงปฏิบัติ ซึ่งจะมีรายละเอียดตั้งแต่การเลือกตัวแปร การแบ่งชุดข้อมูลเพื่อสร้างแบบจำลอง และทดสอบ เมื่อเทียบกับทฤษฎีที่ได้ศึกษามาในหัวข้อ 2.1 และนอกจากการใช้งานแบบจำลองการวิเคราะห์การถดถอยแบบโลจิสติก (Logistic regression) แล้วยังได้ศึกษาตัวอย่างการสร้างตารางความสับสน (Confusion Matrix) เพื่อประเมินแบบจำลองดังรูปที่

Table 1
Confusion matrix. *a*: true positives; *b*: false positives (error type I); *c*: false negative (error type II); *d*: true negatives. $N (= a + b + c + d)$ is the total number of data sets.

Predicted	Observed	
	Stable dam	Unstable dam
Stable	<i>a</i>	<i>b</i>
Unstable	<i>c</i>	<i>d</i>

รูปที่ 20 ตัวอย่างการสร้างตารางเมทริกซ์ความลับสน (Confusion Matrix) จากบทความตัวอย่าง [14]

บทความ “Failure analysis of fuel pump used for diesel engines in transport utility vehicles” [15]

บทความนี้เป็นการวิเคราะห์ความเสียหายของปั๊มส่งเชื้อเพลิงในอุตสาหกรรมขนส่ง ซึ่งได้มีเก็บข้อมูลเพื่อนำมาวิเคราะห์สาเหตุการเสียหายหลักเพื่อกำหนดแนวทางปรับปรุงซึ่งเครื่องมือที่นำมาใช้คือ การวิเคราะห์สาเหตุของลักษณะการเสียและผลกระทบ (Failure Mode and Effect Analysis, FMEA) ซึ่งมีกระบวนการทำคือ ทำการระบุความเสียหายที่อาจเกิดขึ้นได้กับชิ้นส่วนของปั๊มมาทั้งหมดและระบุสาเหตุและผลกระทบของความเสียหายนั้น ๆ เนื่องจากรายการความเสียหายของชิ้นส่วนปั๊มนั้นมีจำนวนพอสมควรจึงต้องคัดกรองความเสียหายที่สำคัญเพื่อมาจัดการก่อน จึงมีการใช้การประเมินระดับตัวเลขความเสี่ยง (Risk Priority Number, RPN) มาใช้ซึ่งประกอบด้วยความรุนแรง (Severity), ความถี่ในการเกิด (Occurrence) และความสามารถในการตรวจพบ (Detection) แยกตามลักษณะความเสียหาย (Failure Mode) โดยคะแนนของแต่ละค่าจะเป็น 1 – 10 และนำสามค่ามาคูณกัน ถ้าค่าสูงคือความเสี่ยงสูง ในงานวิจัยนี้จะคัดกรองลักษณะความเสียหายที่มีระดับความเสี่ยงมากกว่าหรือเท่ากับวิเคราะห์เพื่อกำหนดแนวทางปรับปรุงต่อ

สิ่งที่ได้จากการศึกษาบทความนี้คือตัวอย่างการวิเคราะห์สาเหตุของลักษณะการเสียและผลกระทบ (Failure Mode and Effect Analysis, FMEA) กับปั๊มซึ่งเป็นอุปกรณ์ที่มีลักษณะใกล้เคียงกับงานวิจัยนี้ดัง ตัวอย่างในรูปที่ 21

Table 3
Failure mode and effect analysis and RPN evaluation of fuel pump parts.

Component	Failure mode	Effect	S	Cause	O	D	RPN	Recommendation
Lever bush	Friction, wear	Inapt acceleration or actuation	04	Overuse & excess friction	08	10	320	Replacement after stipulated time span.
Cam plate	Pitting & Rusting	Erroneous fuel supply	07	Water emulsions & fuel impurities	15	09	945	Avoid water mixes and impure fuel
Rollers	Pitting & Rusting	Inaccurate fuel supply and noise	07	Water emulsions & fuel impurities	14	09	882	Avoid water mixes and impure fuel
Adjusting plug	Friction	Improper governing action	02	Friction among plug & fulcrum lever	01	10	20	Ensure adequate lubrication and replace in case if needed.
Body	Friction & Shear	Improper pump functioning	06	Excessive tightening & fuel impurities	10	03	180	Avoid excessive tightening of bolts and repair if needed
Shim	Thermal stresses	Negligible play	01	Friction & Wear	05	10	50	Replace in case of failure
Drive shaft	Torsional fatigue	No motion transmission	10	Inapt gear shifting & strength reduction due to corrosion	11	03	330	Ensure proper gear shifting by operator & avoid corrosion
Lever shaft	Torsional forces	Improper acceleration	05	Overuse & abrupt actuation	08	09	360	Replace after specific period
Time device (TD) Piston	Thermal & Contact Stresses	Failure to adjust fuel supply	07	Dry running & water logging	12	08	672	Avoid water mixing and dry run
Solenoid	choking	Insufficient fuel supply during overload situation	05	Fuel impurities	02	06	60	Ensure fuel filtration
Supply pump	Frictional wear and corrosion	Inadequate pressure in pump	08	Water in fuel & dry run	05	07	280	Water mixing to be avoided and remove markings by polishing surface
Spring	Corrosion	Failure to regulate fuel supply	06	Water in fuel	05	08	240	Water mixing to be avoided
Pressure Valve	Thermal stress	Failure to regulate pressure	07	Dry run	02	07	98	Replace if required

รูปที่ 21 ตัวอย่างตารางวิเคราะห์สาเหตุของลักษณะข้อบกพร่องและผลกระทบจากบทความตัวอย่าง [15]

บทความ “An integrated machine learning model for aircraft components rare failure prognostics with log-based dataset” [16]

บทความนี้เป็นประยุกต์ใช้การเรียนรู้ของเครื่องในงานบำรุงรักษาเครื่องจักรในอุตสาหกรรมการบินซึ่งลักษณะงานที่ใช้จะเป็นการบำรุงรักษาเชิงทำนาย (Predictive Maintenance) โดยเลือกใช้การเรียนรู้ของเครื่องนั้น เนื่องจากเครื่องจักรในอุตสาหกรรมการบินเป็นเครื่องจักรที่มีความซับซ้อน แม้จะมีเซนเซอร์วัดค่าพารามิเตอร์ที่สนใจได้แต่ก็ไม่สามารถวัดได้ทุกค่าของทุกชิ้นส่วน โดยงานวิจัยนี้จะทำการเปรียบเทียบการใช้การเรียนรู้ของเครื่องแบบทั่วไปและแบบผสมผสานคือใช้มากกว่าหนึ่งวิธีการสร้างแบบจำลองจากนั้นทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง

สิ่งที่ได้จากการศึกษาบทความนี้คือขั้นตอนการเปรียบเทียบประสิทธิภาพระหว่างแบบจำลองโดยใช้ค่าความเที่ยงตรง (Precision), รีคอล (Recall), และ เอฟวันสกอร์ (f1-score) ซึ่งค่าเหล่านี้จะถูกใช้ในงานวิจัยนี้ด้วยทำให้ผู้วิจัยได้เห็นถึงตัวอย่างการคำนวณและใช้งานในเชิงปฏิบัติจริงนอกจากทฤษฎีที่ศึกษามาในหัวข้อ 2.1

บทความ “Applications of machine learning to machine fault diagnosis: A review and roadmap” [17]

บทความนี้เป็นการศึกษาาระบบระบุความเสียหายอัจฉริยะ (Intelligent Fault Diagnosis, IFD) ซึ่งคือการใช้หลักการการเรียนรู้ของเครื่องมาใช้ในการหาหรือระบุความเสียหายของเครื่องจักรซึ่งช่วยให้สามารถระบุสุขภาพของเครื่องจักรได้อย่างอัตโนมัติ โดยบทความนี้จะประกอบไปด้วยประวัติการพัฒนาระบบตั้งแต่อดีต ปัจจุบัน และแนวทางในอนาคต ท่ามกลางการเปลี่ยนของข้อมูลที่เพิ่มมากขึ้น

สิ่งที่ได้จากการศึกษาบทความนี้คือประวัติการใช้การเรียนรู้ของเครื่องในการระบุความเสียหาย โดยในอดีตจะใช้วิศวกรที่มีความชำนาญระบุความเสียหาย แต่ผู้ใช้เครื่องจักรต้องการที่ได้วิธีอัตโนมัติในการระบุความเสียหายและมีความแม่นยำมากขึ้น โดยความท้าทายในการทำระบบคือเครื่องจักรส่วนใหญ่มักอยู่ในสภาพที่ดีและไม่ค่อยเสียหายทำให้มีข้อมูลในการเสียน้อย ถ้าต้องการเก็บข้อมูลการเสียเพิ่มอาจจะต้องเพิ่มจำนวนเครื่องจักรซึ่งต้องลงทุนมาก การเรียนรู้ของเครื่องจึงเข้ามาช่วยในแก้ปัญหาในส่วนนี้



บทที่ 3

การดำเนินงานวิจัย

อุปกรณ์ตรวจวัดค่าตลอดเวลาและส่งค่าไปที่ระบบจัดเก็บข้อมูลและแสดงผลกลางหรือที่เรียกว่าออนไลน์เซนเซอร์ (Online Sensor) ส่งข้อมูลผ่านตัวแปลงสัญญาณเป็นค่าไฟฟ้ามาตรฐาน (Transmitter) ไปที่ระบบควบคุมและแสดงผลส่วนกลาง (Digital control system หรือ DCS) ของปั๊มแบบมอเตอร์ปิดผนึกของโรงงานตัวอย่างนั้นประกอบไปด้วย อุปกรณ์ตรวจวัดค่ากระแสของมอเตอร์ (Current) อุปกรณ์ตรวจวัดสภาพของลูกปืนชนิดทรงกระบอกคาร์บอน (Carbon Bush Bearing) ของปั๊มตามแนวรัศมี (Radial) อุปกรณ์ตรวจวัดสภาพของลูกปืนชนิดทรงกระบอกคาร์บอนตามแนวเพลลา (Axial) [3] อุปกรณ์ตรวจวัดอัตราการไหลทางออกของปั๊ม (Discharge Flowrate)

นอกจากนี้ยังมีอุปกรณ์ตรวจวัดของปั๊มที่เป็นการตรวจวัดตลอดเวลาแต่ไม่ได้ส่งค่าไปที่ระบบส่วนกลาง จำเป็นต้องทำการอ่านค่าที่หน้างาน เช่น อุปกรณ์ตรวจวัดความดันขาออกของปั๊มที่มีลักษณะเป็นมาตรวัดความดันติดตั้งที่ระบบท่อขาออก (Discharge Pressure Gauge) ซึ่งข้อมูลจากการตรวจวัดประเภทหลังนี้จะไม่อยู่ในขอบข่ายของงานวิจัยนี้ เนื่องจากงานวิจัยนี้มุ่งเน้นไปที่การใช้ข้อมูลที่สามารถเข้าถึงและนำมาใช้ได้ตลอดเวลา (Continuous data) ซึ่งข้อมูลออนไลน์นั้นจะถูกจัดเก็บในฐานข้อมูล (Data Server) และสามารถนำออกมาวิเคราะห์ตามเป้าประสงค์ต่างๆ ได้

จุฬาลงกรณ์มหาวิทยาลัย

CHULALONGKORN UNIVERSITY

3.1 กรอบการดำเนินงานวิจัย


กำหนดกรอบการดำเนินการวิจัย อ้างอิงจากข้อมูลในบทที่ 1 บทนำ และ บทที่ 2 ทฤษฎีที่เกี่ยวข้อง เพื่อให้เห็นขั้นตอนการดำเนินงานวิจัยที่ชัดเจน รวมถึงเทคนิคที่ใช้ในแต่ละขั้นตอน สรุปเครื่องมือที่ใช้ในการทดสอบและวิเคราะห์การวิจัย ส่วนสุดท้ายจะเป็นสิ่งที่ได้รับ หรือผลลัพธ์ที่ได้ในแต่ละขั้นตอนการดำเนินงานวิจัย ดังตารางที่ 6 กรอบการดำเนินการวิจัย

ตารางที่ 6 กรอบการดำเนินงานวิจัย


เทคนิค / วิธีการดำเนินการวิจัย	เครื่องมือ, การทดสอบและวิเคราะห์การวิจัย	สิ่งที่ได้รับ
1. ประเมินองค์ความรู้ของผู้เชี่ยวชาญ	ศึกษาองค์ความรู้ของผู้เชี่ยวชาญและสรุปออกมาให้อยู่รูปแบบตาราง	ตารางสรุปองค์ความรู้ของผู้เชี่ยวชาญ
2. กำหนดกรอบความคิด (Conceptual Framework)	ประยุกต์ใช้ความรู้จากทฤษฎีหรืองานวิจัยที่เกี่ยวข้อง	กรอบความคิดที่กำหนดขอบข่ายของระบบที่ได้จากการดำเนินการวิจัย
3. การจัดการข้อมูล	ประยุกต์ใช้ทฤษฎีวิทยาการจัดการข้อมูลประกอบกับความรู้ของผู้เชี่ยวชาญ	ข้อมูลที่ถูกจัดการจนสามารถนำไปใช้ในการดำเนินงานวิจัยได้
4. การวิเคราะห์ลักษณะการเสียและผลกระทบ (Failure Mode and Effect Analysis, FMEA)	ประยุกต์ใช้ความรู้จากทฤษฎีหรืองานวิจัยที่เกี่ยวข้อง	ตารางผลการวิเคราะห์ลักษณะการเสียและผลกระทบ
5. สร้างแบบจำลองพยากรณ์พารามิเตอร์ค่าสภาพของลูกปืน (Forecasting)	ประยุกต์ใช้ความรู้จากทฤษฎีหรืองานวิจัยที่เกี่ยวข้อง	แบบจำลองพยากรณ์ที่ผ่านการประเมินและเปรียบเทียบประสิทธิภาพ
6. สร้างแบบจำลองการจำแนก (Classification) สถานะปัจจุบันของปั๊มแบบมอเตอร์ปิดผนึก	ประยุกต์ใช้ความรู้จากทฤษฎีหรืองานวิจัยที่เกี่ยวข้อง	แบบจำลองระบุสถานะปัจจุบันที่ผ่านการประเมินและเปรียบเทียบประสิทธิภาพ

3.2 การประเมินองค์ความรู้ของผู้เชี่ยวชาญ

ผู้เชี่ยวชาญในการประเมินสถานะของปั๊มแบบมอเตอร์ปิดผนึกภายในโรงงานตัวอย่าง คือ วิศวกรซ่อมบำรุง ผู้ซึ่งทำหน้าที่นำองค์ความรู้ที่เกี่ยวข้อง อาทิ เช่น ลักษณะการเสีรูปแบบต่างๆ มาประยุกต์ใช้กับข้อมูลภายในโรงงานเพื่อกำหนดสถานะของปั๊ม โดยมีมุมมองหลักอยู่สองวิธีการ คือ การพยากรณ์รอบการซ่อมล่วงหน้า (Forecasting) จากการพัฒนาของพารามิเตอร์ของปั๊มเมื่อเปรียบเทียบกับขีดจำกัดของปั๊มแบบมอเตอร์ปิดผนึกและรอบการหยุดซ่อมบำรุงของโรงงานตามแผน ในมุมมองการพยากรณ์นี้จะมุ่งเน้นในการจัดการลักษณะการเสีย (Failure Mode) [5] ที่เป็นการเสียตามอายุ (Age Related Failure) [18] และอีกหนึ่งวิธีการคือ การจำแนก (Classification) ปั๊มที่มีสัญญาณการเสียซ่อนเร้น (Potential Failure) [18] ออกจากปั๊มที่สามารถทำงานได้ตามปกติ โดยรูปที่ 22 คือตัวอย่างกราฟลักษณะสัญญาณการเสียซ่อนเร้นเปรียบเทียบกับแกนเวลา โดยในวิธีการนี้จะมุ่งเน้นไปที่การจัดการลักษณะการเสียที่เป็นการเสียแบบสุ่ม (Random Failure) [19] โดยรูปแบบของการเสียทั้งในส่วนของการเสียตามอายุ และการเสียแบบสุ่ม นั้นมีการสรุปดังรูปที่ 23 [20]



รูปที่ 22 ตัวอย่างแผนภูมิลักษณะการเสียประเภทต่างๆ[20]



รูปที่ 23 ตัวอย่างกราฟความสัมพันธ์ของสัญญาณการเสียหายซ่อนเร้น[19]

ซึ่งในวิธีการพยากรณ์นั้นจะไม่สามารถตรวจพบลักษณะการเสียหายประเภทนี้ ดังนั้นจึงต้องใช้ทั้งสองวิธีการในการระบุสถานะของปั๊มแบบมอเตอร์ปิดผนึก ซึ่งสถานะต่างๆของปั๊มจะมีวิธีการจัดการบำรุงรักษาที่แตกต่างกันตามลักษณะการเสียหาย โดยการประยุกต์ใช้องค์ความรู้ของผู้เชี่ยวชาญในงานวิจัยนี้อาจจะสรุปได้ตารางที่ 7

ตารางที่ 7 การใช้งานองค์ความรู้ของผู้เชี่ยวชาญในงานวิจัย

การประเมินสถานะของปั๊มแบบมอเตอร์ปิดผนึก ภายในโรงงานตัวอย่าง		สถานะ	การบำรุงรักษา
1. วิธีการ พยากรณ์ (Forecasting)	1.1 ผลการพยากรณ์พบว่า ค่าพารามิเตอร์มีแนวโน้มจะถึง ขีดจำกัดในเวลามากกว่า 3 ปี	Stage A	ไม่มีการแผนบำรุงรักษา
	1.2 ผลการพยากรณ์พบว่า ค่าพารามิเตอร์มีแนวโน้มจะถึง ขีดจำกัดในเวลามากกว่า 1 ปี แต่ไม่ถึง 3 ปี	Stage B	แจ้งฝ่ายผลิตและผู้ที่เกี่ยวข้องให้ รับทราบ จัดเตรียมอะไหล่ และวางแผนการ ซ่อมระยะยาว (มากกว่า 1 ปี)
	1.3 ผลการพยากรณ์พบว่า ค่าพารามิเตอร์มีแนวโน้มจะถึง ขีดจำกัดในเวลาน้อยกว่า 1 ปี	Stage C	แจ้งฝ่ายผลิตและผู้ที่เกี่ยวข้องให้ รับทราบ วางแผนซ่อมบำรุงในรอบการหยุด ผลิตตามแผน (Planned Shutdown) รอบที่ใกล้ที่สุด

2. การจำแนก (Classification)	2.1 ปีมอยู่ในกลุ่มสถานะปกติ ไม่พบสัญญาณการเสียหายซ่อนเร้น	Stage A	ไม่มีการแผนบำรุงรักษา
	2.2 ปีมอยู่ในกลุ่มสถานะมี สัญญาณการเสียหายซ่อนเร้น (Potential Failure)	Stage B	วิเคราะห์ลักษณะการเสีย วางแผนซ่อมบำรุงในรอบการหยุด ผลิตตามแผน (Planned Shutdown) รอบที่ใกล้ที่สุด หาก พบว่าเป็นสัญญาณของลักษณะการ เสียที่มีโอกาสทำให้ปัมหยุดการ ทำงานสูง
	2.3 ปีมอยู่ในกลุ่มสถานะผิดปกติ	Stage C	แจ้งฝ่ายผลิตและผู้ที่เกี่ยวข้องให้ รับทราบ วางแผนซ่อมบำรุงในรอบการหยุด ผลิตตามแผน (Planned Shutdown) รอบที่ใกล้ที่สุด หรือ หยุดซ่อมบำรุงนอกแผนถ้าจำเป็น

กรอบแนวคิด (Conceptual Framework) ในการพัฒนาระบบผู้เชี่ยวชาญในงานวิจัยนี้
 ออกแบบจากการประสบการณ์ของผู้ทำวิจัยและผลการศึกษาจากงานวิจัยที่เกี่ยวข้อง อาทิ งานวิจัยจาก
 บทความ “Applications of machine learning to machine fault diagnosis: A review and
 roadmap” [17] ซึ่งมีการแบ่งสัดส่วนของระบบ เป็น การจัดการข้อมูล การประมวลผลฟิเจอร์
 (Feature) ของข้อมูลและการประเมินสถานะของอุปกรณ์จากแบบจำลองในงานวิจัย ดังรูปที่ 24

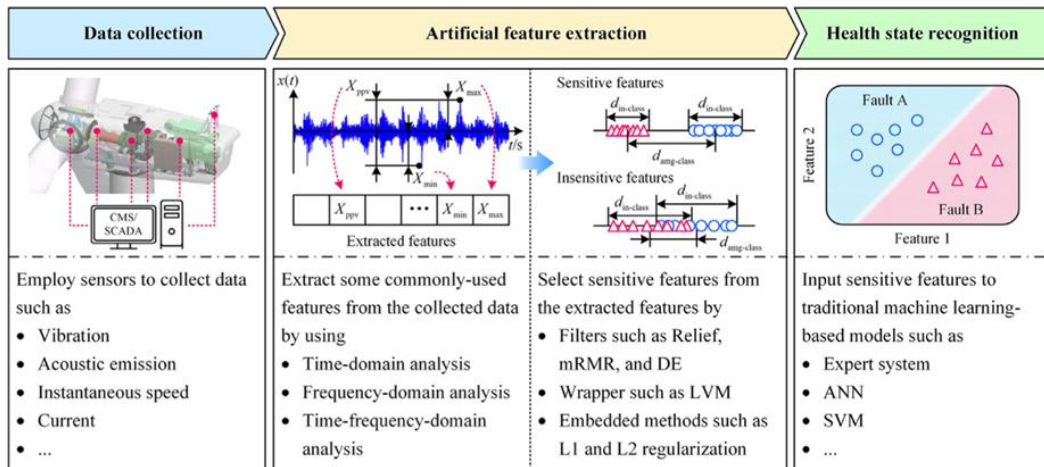



Fig. 2. Diagnosis procedure of IFD using traditional machine learning theories.

รูปที่ 24 ตัวอย่างแผนผังการใช้การเรียนรู้ของเครื่องกับระบบระบุความเสียหายอัจฉริยะ [17]

โดยการออกแบบแบบจำลองนั้นในส่วนการประมวลผลจะอยู่บนคอมพิวเตอร์ส่วนบุคคลที่มีคุณสมบัติดังตารางที่ 8 ของผู้ใช้งานระบบผู้เชี่ยวชาญที่เชื่อมต่อเข้ากับชุดข้อมูลที่ใช้สอนแบบจำลอง (Training Data Set) โดยชุดข้อมูลที่ใช้สอนแบบจำลองจะถูกนำไปใช้ทั้งสองส่วนตามเป้าประสงค์ของระบบผู้เชี่ยวชาญนี้คือ การพยากรณ์พารามิเตอร์ของปั๊มในอนาคตเพื่อวางแผนบำรุงรักษาล่วงหน้า และการจำแนกสถานะปัจจุบันของปั๊มโดยการหาสัญญาณการเสียหายซ่อนเร้น (Potential Failure) ซึ่งมีเป้าประสงค์ในการลดเวลาการทำงานของผู้เชี่ยวชาญในการค้นหาความผิดปกติของปั๊ม ข้อมูลพารามิเตอร์ปัจจุบันและอดีตจะถูกเชื่อมต่อเข้ากับแบบจำลองที่ถูกสร้างไว้และแสดงผลออกมาในรูปแบบกระดานแสดงผล (Dashboard) เพื่อให้สามารถเข้าถึงผลลัพธ์ของระบบผู้เชี่ยวชาญได้ง่ายและรวดเร็ว ดังรูปที่ 26

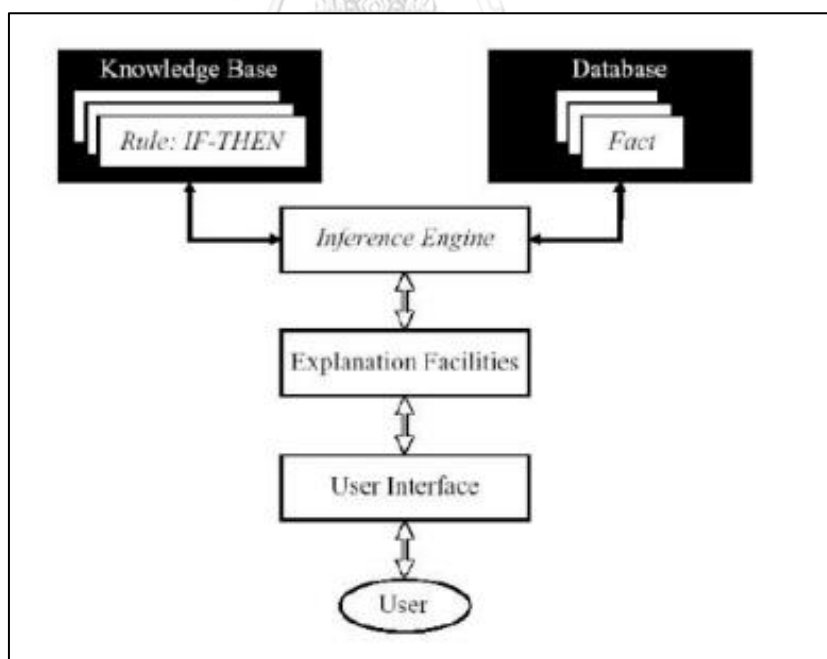


รูปที่ 25 กรอบแนวคิดในการสร้างระบบผู้เชี่ยวชาญ

ตารางที่ 8 คุณสมบัติของคอมพิวเตอร์ส่วนบุคคลที่ใช้ในงานวิจัย

คุณสมบัติ	รายละเอียด
ยี่ห้อ (Brand)	HP (Hewlett-Packard Company)
ตัวประมวลผล (Processor)	11 th Gen Intel(R) Core(TM) i7-1165G7 @ 2.80GHz
หน่วยความจำชั่วคราว (RAM)	8.00 GB (7.69 GB usable)
ระบบปฏิบัติการ (Operation System)	Edition Windows 10 Enterprise Version 21H2

โดยการออกแบบกรอบแนวคิดในการสร้างระบบผู้เชี่ยวชาญนั้นอ้างอิงโครงสร้างของระบบผู้เชี่ยวชาญประเภทอิงกฎ (Rule-Based Expert System) [21] ดังตัวอย่างในรูปที่ 26 จากศึกษาจากงานวิจัยที่เกี่ยวข้องซึ่งเป็นการส่วนขององค์ความรู้พื้นฐาน (Knowledge Base) ซึ่งมีลักษณะเป็นการกำหนดกฎของเหตุและผล (IF-THEN) ซึ่งในงานวิจัยนี้ได้สรุปมาในตารางที่ 7 ในข้างต้น และฐานข้อมูล (Database) ซึ่งเป็นข้อมูลที่เกิดขึ้นจริง ซึ่งในงานวิจัยนี้คือ ข้อมูลพารามิเตอร์ต่างๆของบีม และประวัติการเสียที่เคยเกิดขึ้น มาประสานกันเพื่อแสดงผลหรือตอบคำถามตามเป้าประสงค์ของระบบผู้เชี่ยวชาญ



รูปที่ 26 ตัวอย่างระบบผู้เชี่ยวชาญประเภทอิงกฎ [21]

3.3 การจัดการข้อมูล [6]

ในการจัดการข้อมูลจะแบ่งเป็นสองส่วนคือข้อมูลสำหรับในการสร้างและทดสอบแบบจำลอง อีกส่วนหนึ่งข้อมูลที่ใช้เป็นข้อมูลขาเข้าของแบบจำลองหลังจากที่การสร้างแบบจำลองแล้วเสร็จและถูกนำมาใช้งานจริง โดยอุปกรณ์เป้าหมายเป็นปั๊มแบบมอเตอร์ปิดผนึกทั้งหมดสลับแปดอุปกรณ์ ประกอบไปด้วยพารามิเตอร์แบบออนไลน์ต่าง ๆ โดยข้อมูลดิบจะเป็นข้อมูลค่าพารามิเตอร์ทั้งหมดหนึ่งร้อยสิบเอ็ดพารามิเตอร์ ย้อนหลังเป็นเวลาสองปี ตั้งแต่วันที่ 1 มกราคม ค.ศ. 2018 ถึงวันที่ 30 ธันวาคม ค.ศ. 2020 โดยดึงข้อมูลมาทุกหนึ่งสัปดาห์ คิดเป็นจำนวนข้อมูลดิบตัวอย่างในการสร้างแบบจำลองทั้งหมด 16,692 ข้อมูลตัวอย่าง ดังตารางที่ 9 สำหรับการทดลองสร้างแบบจำลอง โดยข้อมูลจะอยู่ในรูปแบบไมโครซอฟท์เอ็กเซลไฟล์ประเภท “CSV” (Comma-Separated Value) ซึ่งคือชุดข้อมูลที่ถูกจัดเก็บข้อมูลในรูปแบบตาราง โดยใช้จุลภาค (,) แบ่งข้อมูลในแต่ละหลัก (Column) ในการจัดการข้อมูลจะใช้ภาษาอาร์ (R programming language) [22] ผ่านเครื่องมือที่ช่วยในการพัฒนาโปรแกรม (IDE ย่อมาจาก Integrated Development Environment) ที่ชื่อ “R Studio” [23] โดยเข้าบรรจุชุดข้อมูลเข้าไปในแต่ตัวแปรเพื่อทำการจัดการข้อมูลต่อไป ดังรูปที่ 27 ซึ่งจะเห็นว่าข้อมูลบางส่วนนั้นไม่สามารถใช้ในการสร้างแบบจำลอง เช่น ข้อมูลสูญหายจากระบบต้นทาง หรือจากปัจจัยอื่นๆ อาทิ เช่น อุปกรณ์หยุดทำงานตามรอบการผลิต หรือ ระบบไฟฟ้ามีปัญหา รวมทั้งข้อมูลที่อยู่นอกช่วงปกติที่ไม่ได้เกิดจากการทำงานของอุปกรณ์ จึงจะต้องมีการจัดการข้อมูลสูญหายและทำความสะอาดข้อมูล

ตารางที่ 9 จำนวนข้อมูลดิบที่ใช้ในการสร้างแบบจำลอง

ชื่ออุปกรณ์	จำนวนพารามิเตอร์	จำนวนข้อมูล
A	8	1,248
B	6	936
C1	6	936
C2	6	936
D	6	936
E	6	936
F	6	936
G	6	936
H	7	1,092
I	5	780

J	5	780
K	4	624
M	6	936
N	7	1,092
O	5	780
P	5	780
Q	6	936
R	7	1,092
ทั้งหมด		16,692

Date	Current	Radial Condition	Axial Condition	Winding Temp	Suction Temp	Suction Level	Flow Rate	Second path valve	
30	23/7/2018	7.303595e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	157.92974	77.40474	58.61642470	1.790653e+...	6.151831e-01
31	30/7/2018	7.313173e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	157.93778	77.59943	63.39830544	1.818911e+...	6.285790e-02
32	6/8/2018	7.289792e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	157.43882	76.49682	73.75016260	1.791448e+...	6.608746e-01
33	13/8/2018	7.299937e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	157.70921	77.49298	59.19734343	1.808285e+...	3.998126e-03
34	20/8/2018	7.311600e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	158.16906	78.20231	56.74975147	1.819745e+...	1.310291e-03
35	27/8/2018	7.318992e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	158.19036	78.03081	56.91763049	1.836461e+...	1.111223e-01
36	3/9/2018	7.307585e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	158.13429	78.27510	57.07396620	1.822951e+...	2.640340e-05
37	10/9/2018	7.315898e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	158.17745	78.38638	68.02495982	1.831588e+...	1.080215e-01
38	17/9/2018	7.314503e+01	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	158.57568	79.41843	68.57012580	1.839870e+...	2.445642e-01
39	24/9/2018	7.305182e+01	43.40948611	25.80129626	158.43311	79.15788	63.49997721	1.826820e+...	1.394639e-01
40	1/10/2018	7.329290e+01	43.55978691	26.26883653	158.50681	78.43045	79.21582616	1.849693e+...	1.500341e+...
41	8/10/2018	2.092807e+01	37.05951118	27.27936418	135.70897	94.46083	16.34467313	1.096138e+...	1.795581e+...
42	15/10/2018	1.870840e-27	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	89.24545	72.96795	-0.17159152	1.926193e-01	1.213601e+...
43	22/10/2018	0.000000e+00	[-11059] No Good Data For Calculation	[-11059] No Good Data For Calculation	79.70355	59.12301	-0.07130803	1.598791e-02	0.000000e+...
44	29/10/2018	5.740834e+01	38.89383802	24.89514774	147.43763	82.77877	56.47211354	5.493226e+...	1.170178e+...
45	5/11/2018	6.988041e+01	41.45400558	21.93226906	154.27708	75.78115	53.93299537	1.432328e+...	2.000000e+...
46	12/11/2018	7.280153e+01	42.4402056	25.0967971	157.94897	76.52709	55.72246059	1.777086e+...	2.000000e+...
47	19/11/2018	7.329807e+01	43.88666704	26.20898627	158.72210	76.19573	70.54861084	1.837269e+...	8.070024e-01
48	26/11/2018	7.342630e+01	43.44753834	26.37585889	158.88873	76.40994	64.70971749	1.847000e+...	4.560850e-02
49	3/12/2018	7.323891e+01	42.5966023	25.87684109	158.74036	76.77437	60.53919930	1.823170e+...	1.723265e-02
50	10/12/2018	7.332305e+01	42.85396647	25.85605759	158.58299	76.57188	59.52643468	1.836891e+...	5.269450e-04

รูปที่ 27 ตัวอย่างข้อมูลที่ใช้ในการสร้างแบบจำลอง

3.1.1 การจัดการข้อมูลสูญหาย (Missing Data) [6]

ข้อมูลที่สูญหายในงานวิจัยนี้ส่วนใหญ่จะเป็นการสูญหายแบบไม่สุ่ม (Missing Not At Random, MNAR) จากกิจกรรมนอกช่วงดำเนินการปกติของโรงงานตัวอย่าง อาทิ เช่น หยุดซ่อมบำรุงเครื่องจักรตามแผน หรือ นอกแผนอันเนื่องมาจากการเสียหายของอุปกรณ์สำคัญของโรงงาน เมื่อกิจกรรมนอกช่วงดำเนินการปกติของโรงงานจบลงข้อมูลจะกลับเข้าช่วงปกติ ในการจัดการข้อมูลส่วนนี้จะใช้วิธี การตัดข้อมูลแบบลิสทไวส์ (Listwise deletion) คือ ทำการลบข้อมูลที่ไม่ครบถ้วนหรือไม่สมบูรณ์ออกไปทั้งแถว (Row) เนื่องจากต้องใช้ข้อมูลที่ครบถ้วนทั้งแถวในการสร้างแบบจำลองดังรูปที่ 28

Date	Current	Radial Condition	Axial Condition	Winding Temp	Suction Temp	Suction Level	Flow Rate	Second path valve
24/9/2018	73.05182	43.40949	25.80130	158.4331	79.15788	63.499977	182682.023	1.394639e-01
1/10/2018	73.29290	43.55979	26.26884	158.5068	78.43045	79.215826	184969.319	1.500341e+00
8/10/2018	20.92807	37.05951	27.27936	135.7090	94.46083	16.344673	10961.376	1.795581e+01
29/10/2018	57.40834	38.89384	24.89515	147.4376	82.77877	56.472114	54932.263	1.170178e+00
5/11/2018	69.88041	41.45401	21.93227	154.2771	75.78115	53.932995	143232.819	2.000000e+01
12/11/2018	72.80153	42.44021	25.09680	157.9490	76.52709	55.722461	177708.559	2.000000e+01
19/11/2018	73.29807	43.88667	26.20899	158.7221	76.19573	70.548611	183726.894	8.070024e-01
26/11/2018	73.42630	43.44754	26.37586	158.8887	76.40994	64.709717	184699.990	4.560850e-02
3/12/2018	73.23891	42.59660	25.87684	158.7404	76.77437	60.539199	182316.967	1.723265e-02
10/12/2018	73.32305	42.85397	25.85606	158.5830	76.57188	59.526435	183689.075	5.269450e-04
17/12/2018	73.22513	42.66586	25.76309	158.6767	76.48626	56.643695	183013.957	1.567878e-02
24/12/2018	73.32239	42.77220	25.67501	158.6534	76.32221	67.060129	183833.925	1.538287e-01
31/12/2018	73.36023	44.04406	25.47740	158.3371	76.05797	62.850052	183914.094	0.000000e+00
7/1/2019	72.38314	43.29264	25.05122	157.5344	75.96562	70.279640	171870.597	3.048685e-01
14/1/2019	73.44033	43.47892	25.52949	158.6433	75.83848	61.607243	185328.852	2.212990e-05
21/1/2019	73.35844	43.92552	25.44267	158.7118	75.99100	72.866975	185264.590	1.085446e-01
28/1/2019	73.52382	43.58167	25.54630	158.7854	75.81867	79.559360	186690.689	2.425762e-01
4/2/2019	73.56692	43.20213	25.59561	158.8258	75.73876	74.261306	186695.910	6.511409e-02
11/2/2019	73.43118	42.83168	25.54436	158.7566	76.00547	65.359889	185526.674	8.241985e-02
18/2/2019	72.83297	43.41782	25.11546	158.1477	75.86647	77.614941	177537.297	9.826620e-01
25/2/2019	73.55240	43.06241	25.97771	159.0119	76.03933	74.093928	188025.563	3.428646e-01
4/3/2019	73.44002	42.95413	25.87564	159.0142	76.28750	72.090345	187090.687	4.547553e-01


รูปที่ 28 ตัวอย่างข้อมูลหลังจากที่จัดการข้อมูลสูญหาย

3.1.2 การทำความสะอาดข้อมูล (Cleaning Data) [6]

หลังจากจัดการข้อมูลสูญหายได้ทำความสะอาดข้อมูล คือ กระบวนการตรวจสอบ แก้ไข ปรับแต่ง ลบรายการข้อมูลที่ไม่ถูกต้องออกไปจากชุดข้อมูล รวมถึงการปรับแต่งโครงสร้างบางส่วน (ที่ไม่กระทบกับตัวข้อมูล) เช่น ลบคอลัมน์ที่ไม่ใช่, เปลี่ยนชื่อคอลัมน์, ตรวจสอบและแก้ไขชนิดของข้อมูล, จัดการค่าทศนิยม, จัดการข้อมูลซ้ำ เป็นต้น เพื่อให้ข้อมูลมีคุณภาพเพียงพอ


3.1.3 การจัดการค่าผิดปกติในข้อมูล (Correct Data) [6]

จากการตรวจสอบข้อมูลโดยใช้แผนภูมิแบบกล่อง (Boxplot) พบว่ามีข้อมูลบางส่วนที่ยังกระโดดห่างจากข้อมูลส่วนใหญ่มากผิดปกติ (Outlier) เช่น ค่ากระแสของพลังงานไฟฟ้าที่ปั๊มแบบมอเตอร์แบบปิดผนึกใช้เป็นตัวนำกำลังในการทำงาน จะมีข้อมูลนอกช่วงในย่านต่ำ ดังรูปที่ 31 อยู่ส่วนหนึ่ง ซึ่งปกติแล้วจะมีค่าเฉลี่ยอยู่ที่ 70.22 แอมแปร์ ค่าต่ำสุดอยู่ที่ 13.03 แอมแปร์ ค่าสูงสุดอยู่ที่ 73.57 แอมแปร์ เมื่อทำการตรวจสอบในเชิงลึกพบว่ากลุ่มข้อมูลนี้อยู่ในช่วงระหว่างโรงงานดำเนินการหยุดซ่อมบำรุงและกลับมาผลิตปกติ ซึ่งอุปกรณ์จะทำงานที่ภาระงานต่ำในช่วงแรกจากนั้นจะค่อยๆ เพิ่มจนถึงภาระงานปกติ ทำให้ค่ากระแสในช่วงแรกต่ำกว่าปกติ ซึ่งข้อมูลในส่วนนี้ไม่ควรนำมาใช้ในการสร้างแบบจำลอง ดังรูปที่ 29



รูปที่ 29 Boxplot ของค่ากระแสของอุปกรณ์ตัวอย่างก่อนจัดการค่าผิดปกติ

ในการจัดการจะใช้ค่าพิสัยระหว่างควอไทล์ (interquartile range, IQR) ในการจัดการข้อมูล ที่ผิดปกติออกไปจากชุดข้อมูล ซึ่งจากข้อมูลตัวอย่างจะจัดการในส่วนของข้อมูลในย่านต่ำ (Lower Fence) ออกไป เมื่อดำเนินการแล้วเสร็จทำการตรวจสอบโดยใช้แผนภูมิแบบกล่องอีกครั้ง พบว่า ข้อมูลที่ผิดปกติในย่านต่ำได้อยู่ห่างออกไปจากชุดข้อมูล ดังรูปที่ 30 โดยค่าเฉลี่ยของกระแสอยู่ที่ 72.80 แอมแปร์ มีค่าต่ำสุดอยู่ที่ 70.95 แอมแปร์ และมีค่าสูงสุดอยู่ที่ 73.57 แอมแปร์



รูปที่ 30 Boxplot ของค่ากระแสของอุปกรณ์ตัวอย่างหลังจัดการค่าผิดปกติ

3.2 การวิเคราะห์ลักษณะการเสียและผลกระทบ (Failure Mode and Effect Analysis, FMEA) [5]

เพื่อเป็นข้อมูลพื้นฐานในการสร้างแบบระบบผู้เชี่ยวชาญ ให้ได้ตามเป้าประสงค์ของงานวิจัย คือการพยากรณ์การเสียและค้นหาสัญญาณการเสียซ่อนเร้นของอุปกรณ์ด้วยแบบจำลองต่างๆ นั้น จะต้องระบุอาการเสียที่สำคัญของอุปกรณ์และความสัมพันธ์ของพารามิเตอร์ของอุปกรณ์ เพื่อจำกัดขอบเขตระบบผู้เชี่ยวชาญ เนื่องจากปั๊มแบบมอเตอร์ปิดผนึกนั้นมีลักษณะการเสีย (Failure Mode) หลายแบบ แต่มีลักษณะการเสียที่สำคัญ (Dominant Failure Mode) นั้นเพียงไม่กี่รูปแบบ ซึ่งสามารถพยากรณ์และจำแนกสถานะผิดปกติได้ผ่านพารามิเตอร์ที่นำมาวิเคราะห์ผ่านระบบผู้เชี่ยวชาญ โดยเครื่องมือแรกที่ใช้ในการแสดงอาการเสียของปั๊มแบบมอเตอร์ปิดผนึกคือการทำ การวิเคราะห์ลักษณะการเสียและระดับผลกระทบ (Failure Mode and Effect Analysis, FMEA) เพื่อแสดงอาการเสียทั้งหมดที่เป็นไปได้ของอุปกรณ์และพิจารณาเลือกเฉพาะอาการเสียที่มีผลกระทบสำคัญต่อตัวอุปกรณ์ มาใช้ในการสร้างระบบผู้เชี่ยวชาญ โดยใช้ข้อเท็จจริงและประสบการณ์ของผู้ทำวิจัยที่ทำงานเกี่ยวข้องกับปั๊มแบบมอเตอร์ปิดผนึกมากกว่า 5 ปี ได้ผลของวิเคราะห์ลักษณะการเสียและระดับ

ผลกระทบ (Failure Mode and Effect Analysis, FMEA) ของปั๊มแบบมอเตอร์ปิดผนึกตามรูปที่ 31 ซึ่งลักษณะการเสียหายส่วนใหญ่จะส่งผลต่อการทำหน้าที่หลักของปั๊มโดยตรง (Primary Function) ซึ่งสามารถใช้พารามิเตอร์ที่มีอยู่มาสร้างแบบจำลองตามเป้าประสงค์ของงานวิจัยได้ โดยใช้ เซนเซอร์วัดค่าสภาพของลูกปืนชนิดทรงกระบอกคาร์บอน (Carbon Bush) ที่ติดตั้งมาปั๊ม ซึ่งสามารถวัดสภาพการสึกหรอของชิ้นส่วนภายในปั๊มได้ทั้งแนวแกนและแนวเพลาเป็นหลักฐานพารามิเตอร์อื่นๆ ใช้พิจารณาประกอบ

Canned Pump			
Sub-Unit (ISO 14224)	Failure Mode (Any Event which cause of functional failure)	Failure Cause	Failure Effect
Pump Unit	1 Rotor Damage (Crack and wear)	1.1 Fatigue from cycle work stresses 1.2 Cavitation damage 1.3 Recirculation damage from reversing flow 1.4 Rubbing between rotor and stationary parts	Pump Fail to transfer liquid
	2 Bearing Damage (Crack and wear)	2.1 Fatigue from cycle work stresses 2.2 Insufficient Lubrication (process) 2.3 Wear at Bearing from life cycle usage	Pump Fail to transfer liquid
	3 Internal parts Damage (Wear ring, diffuser, Split ring, Bushing)	3.1 Wear from using 3.2 Rubbing between rotor and stationary parts 3.3 Corrosion damage from chemical re-action 3.4 Erosion damage from movement of liquid inside pump 3.5 Dry Running (Loss Suction) from suction valve fail.	Pump Fail to transfer liquid
	4 Pump casing Leakage	4.1 Corrosion damage from chemical re-action 4.2 Gasket deterioration	Pump Fail to contain liquid
	5 Stator Damage	5.1 Insulation Deterioration 5.2 Short Circuit 5.3 Overload	Pump Fail to transfer liquid
	6 Bearing Monitor device error	6.1 Cable damage 6.2 Terminal Loose 6.3 Sensor Damage	Pump loss of protection


รูปที่ 31 “FMEA” ของปั๊มแบบมอเตอร์ปิดผนึกในงานวิจัยนี้

3.3 การสร้างแบบจำลองพยากรณ์พารามิเตอร์ค่าสภาพของลูกปืน (Forecasting)

การพยากรณ์พารามิเตอร์ค่าสภาพของลูกปืนชนิดทรงกระบอกคาร์บอนของปั๊มแบบมอเตอร์แบบปิดผนึกจะได้รับความสนใจเมื่อค่าพารามิเตอร์มีแนวโน้มสูงขึ้นอย่างมีนัยยะสำคัญ หรือพบความผิดปกติของอุปกรณ์เพื่อพิจารณากำหนดรอบบำรุงรักษาในระยะยาว (Maintenance Long Range Plan) ซึ่งจำเป็นจะต้องจัดเตรียมงบประมาณ และทรัพยากรต่างๆ อาทิเช่น อะไหล่ หรือ จำนวนบุคลากร ให้เหมาะสมกับแผนบำรุงรักษาในระยะยาว ยิ่งรู้ล่วงหน้าได้มากเท่าใดก็ยิ่งมีโอกาสที่จะสามารถบริหารจัดการต้นทุนบำรุงรักษาได้ดียิ่งขึ้น โดยเครื่องมือที่นำมาใช้ในการทดลองสร้างแบบจำลองในการพยากรณ์นี้จะใช้การพยากรณ์เชิงสถิติ [13] โดยเลือกวิธีการพยากรณ์ที่มีโอกาสเหมาะสมกับประเภทและลักษณะของข้อมูลมาเปรียบเทียบประสิทธิภาพเพื่อหาแบบจำลองที่ดีที่สุด

จากการทำการวิเคราะห์ลักษณะการเสียและระดับผลกระทบ (Failure Mode and Effect Analysis, FMEA) พบว่า อาการเสียที่มีผลกระทบสูงการที่ปั๊มไม่สามารถที่ทำหน้าที่หลักส่งของเหลวจากที่หนึ่งไปอีกที่หนึ่งได้ (Primary Function) คือกลุ่ม อุปกรณ์ภายในปั๊มเสียหาย อาทิ ลูกปืนชนิด

ทรงกระบอกคาร์บอน (Carbon Bush Bearing) และอุปกรณ์หมุนและขับเคลื่อนภายในปั๊มเสียหาย (Rotor and Stator) ซึ่ง Parameter หลักที่ใช้พยากรณ์อาการเสียนี้ได้คือ ค่าสภาพของลูกปืนปั๊ม ด้านแนวแกน (Radial E-monitor) ซึ่งมีลักษณะข้อมูลเป็นค่าที่เกิดขึ้นต่อเนื่องตามเวลาในหน่วย เปอร์เซ็นต์ (%) โดยลักษณะทั่วไปของค่านี้คือจะขึ้นอย่างช้าๆ ตามลักษณะการสึกหรอของลูกปืนชนิด ทรงกระบอกคาร์บอนภายในปั๊ม ดังรูปที่ 32



รูปที่ 32 ตัวอย่าง ลักษณะทั่วไปของค่า ค่าสภาพของลูกปืนปั๊มด้านแนวแกนในงานวิจัยนี้


ในการหาแบบจำลองในการพยากรณ์พารามิเตอร์ค่าสภาพของลูกปืนของปั๊มแบบมอเตอร์ แบบปิดผนึกมีขั้นตอนดำเนินการวิจัยดังนี้ [12]

1. รวบรวมข้อมูล (Collect Data) และทำความสะอาดข้อมูล (Data Manipulation and Cleaning) โดยจะกำหนดวิธีการจัดเก็บข้อมูลตามหัวข้อที่ 3.1 ของงานวิจัยนี้
2. สืบค้นลักษณะของข้อมูล (Examine Data Patterns) เพื่อใช้ในการเลือกวิธีการพยากรณ์
3. เลือกวิธีการพยากรณ์และทำการทดสอบความแม่นยำโดยแบ่งข้อมูลสำหรับสร้างแบบจำลอง (Training Dataset) และสำหรับทดสอบ (Test Dataset) โดยการหาค่าความคลาดเคลื่อน (Error)

3.3.1 ตรวจสอบลักษณะของข้อมูล (Examine Data Patterns)


ในเบื้องต้นได้ใช้แผนภูมิแบบกระจาย (Scatter Diagram) ตามแนวแกนของเวลากลายเป็นแผนภูมิอนุกรมเวลา (Time Series Plot) เพื่อดูลักษณะของข้อมูลว่ามีลักษณะเป็นค่าค่อยๆขึ้นเป็นแนวโน้มเชิงบวก (Positive Trend) ดังรูปที่ 33 ไม่พบลักษณะการขึ้นลงเป็นรอบตามฤดูกาล (Seasonality)

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
57.08	59.97	66.82	66.53	71.59	78.69



รูปที่ 33 แผนภูมิอนุกรมเวลาของตัวอย่างข้อมูลในงานวิจัยนี้

จากนั้นทำการสร้างแผนภูมิความสัมพันธ์ระหว่างตัวข้อมูลเอง (Autocorrelation Plot, ACF) พบว่ามีค่าสูงในช่วงเวลาแรก (Time Lag) จากนั้นค่อยๆ ลดลงตามช่วงเวลา ซึ่งแสดงลักษณะของแนวโน้มเชิงบวก (Positive Trend) เช่นเดียวกับแผนภูมิอนุกรมเวลาดังรูปที่ 34



รูปที่ 34 แผนภูมิความสัมพันธ์ระหว่างตัวข้อมูลเองในงานวิจัยนี้

3.3.2 เลือกวิธีการพยากรณ์และทำการทดสอบความแม่นยำ [12]

ได้แบ่งวิธีการพยากรณ์ออกเป็นสองกลุ่มคือ กลุ่มวิธีการพยากรณ์ด้วยอนุกรมเวลาเชิงเส้น (Time Series Method) 2 วิธีคือ การพยากรณ์อย่างง่าย (Naïve) และ การพยากรณ์ด้วยวิธีของบ็อกซ์และเจนคลิน (Box and Jenkins) หรือวิธีที่เรียกว่าค่าเฉลี่ยเคลื่อนที่แบบบูรณาการอัตโนมัติ (Autoregressive integrated moving average, ARIMA) อีกกลุ่มหนึ่งวิธีการพยากรณ์เชิงสาเหตุ (Causal Method) ซึ่งเลือกวิธี การพยากรณ์โดยใช้สมการถดถอยเชิงเส้น (Linear Regression) ทั้งแบบตัวแปรเดียวและหลายตัวแปร โดยวิธีที่เลือกมานั้นพิจารณาแล้วว่าเหมาะสมกับลักษณะของข้อมูลมีลักษณะของแนวโน้ม (Trend)

การสร้างแบบจำลองด้วยการพยากรณ์อย่างง่าย (Naïve) [12]

วิธีนี้เป็นการนำค่าที่ช่วงเวลาปัจจุบันหรือข้อมูลล่าสุดมาใช้ในการพยากรณ์ ดังนั้นการเปลี่ยนแปลงของผลการพยากรณ์ จะเปลี่ยนแปลงค่อนข้างเร็วเมื่อค่าล่าสุดเปลี่ยนแปลงไปทิศทางใดทิศทางหนึ่ง โดยสมการของแบบจำลองที่ประยุกต์ใช้หลักการพยากรณ์อย่างง่ายที่นำมาทำการทดลองคือ สมการการพยากรณ์อย่างง่ายแบบปรับแนวโน้ม (Adjusted to take trend) โดยค่าพยากรณ์จะเพิ่มตามผลต่างของค่าปัจจุบันและช่วงเวลาก่อนหน้า ดังสมการ นี้

$$\hat{Y}_{t+1} = Y_t + (Y_t - Y_{t-1})$$

อีกสมการหนึ่งที่เลือกมาใช้สร้างแบบจำลองการพยากรณ์อย่างง่ายคือ สมการการพยากรณ์อย่างง่ายแบบปรับตามอัตราการเปลี่ยนแปลง (Adjusted to the rate of change) โดยค่าพยากรณ์จะปรับตามอัตราส่วนการเปลี่ยนแปลงระหว่างค่าปัจจุบันและช่วงเวลาก่อน ดังสมการ นี้

$$\hat{Y}_{t+1} = Y_t \frac{Y_t}{Y_{t-1}}$$

แบบจำลองการพยากรณ์อย่างง่ายทั้งสองรูปแบบได้นำมาสร้างแบบจำลองการพยากรณ์ผ่านการคำนวณด้วยสมการคณิตศาสตร์และแสดงผลการพยากรณ์กับข้อมูลตัวอย่างดังรูปที่ 35 และนำไปทดสอบความคลาดเคลื่อนได้ผลดังรูปที่ 36

t	Date	Radial E-Monitor	Naïve (Adjust to take trend)	Naïve (Adjust to rate of change)
1	7/11/2018	60.03110465	60.03110465	
2	8/11/2018	59.86770047	60.03110465	
3	9/11/2018	59.96991155	59.70429629	59.70474107
4	10/11/2018	60.07951823	60.23552681	60.07229713
5	11/11/2018	59.82928085	59.92350965	60.18932524
6	12/11/2018	59.41963743	59.73505205	59.58008573
7	13/11/2018	59.4429536	59.10422281	59.01279879
8	14/11/2018	59.4631944	59.78168439	59.46627892
9	15/11/2018	59.39598559	59.14470441	59.48344209
10	16/11/2018	59.57899349	59.64726677	59.32885274
11	17/11/2018	59.74292082	59.51072021	59.76256526
12	18/11/2018	59.92900975	59.97512143	59.90729918
13	19/11/2018	60.46573071	59.88289807	60.11567832
14	20/11/2018	60.62736695	61.04856335	61.00725851
15	21/11/2018	60.1687199	60.20617055	60.78943527
16	22/11/2018	60.21742168	60.13126925	59.71354252
17	23/11/2018	60.27930416	60.30357411	60.26616288
18	24/11/2018	60.64780694	60.25503421	60.34125023


รูปที่ 35 ตัวอย่างค่าพยากรณ์ด้วยการพยากรณ์อย่างง่าย (Naïve)
จุฬาลงกรณ์มหาวิทยาลัย

t	Date	E-Monitor	Naïve (Adjust to take trend)	et	et2	Abs	Abs/Yt	Naïve (Adjust to rate of change)	et	et2	Abs	Abs/Yt
586	12/8/2020	77.31327926	80.32255483	-3.0092756	9.05573946	3.00927557	0.03892314	77.59669141	-0.2834122	0.08032245	0.0064517	8.3449E-05
587	13/8/2020	77.7456632	74.30400369	3.44165951	11.8450202	3.44165951	0.04426819	77.25380125	0.49186195	0.24192818	0.05852924	0.00075283
588	14/8/2020	77.86941096	81.18732271	-3.3179118	11.0085384	3.31791175	0.04260867	78.1804653	-0.3110543	0.0967548	0.00936149	0.00012022
589	15/8/2020	78.68934279	74.55149921	4.13784358	17.1217495	4.13784358	0.05258455	77.99335569	0.6959871	0.48439804	0.23464147	0.00298187
590	16/8/2020	77.91137069	82.82718637	-4.9158157	24.1652438	4.91581568	0.06309497	79.51790815	-1.6025375	2.58096262	6.66136806	0.08549931
591	17/8/2020	77.64365568	72.99555501	4.64810067	21.6048398	4.64810067	0.05986453	77.14109011	0.50256557	0.25257215	0.06379269	0.00082161
592	18/8/2020	77.73393848	82.29175635	-4.5578179	20.7737037	4.55781787	0.05863356	77.37686058	0.3570779	0.12750463	0.01625743	0.00020914
593	19/8/2020	77.37626846	73.17612061	4.20014785	17.641242	4.20014785	0.05428212	77.82432626	-0.4480578	0.20075579	0.04032089	0.00052087
594	20/8/2020	77.64798167	81.57641631	-3.9284346	15.4325987	3.92843464	0.05059288	77.02024415	0.62773752	0.39405439	0.15527886	0.00199978
595	21/8/2020	78.02035045	73.71954703	4.30080342	18.4969101	4.30080342	0.05512412	77.92064902	0.09970143	0.09994037	9.8811E-05	1.2665E-06
596	22/8/2020	77.56827496	82.32115387	-4.7528789	22.589579	4.75287891	0.06127349	78.39450496	-0.82623	0.68265602	0.46601924	0.00600786
597	23/8/2020	77.48906264	72.81539605	4.67366659	21.8431594	4.67366659	0.06031389	77.11881894	0.3702437	0.13708039	0.01879103	0.0002425
598	24/8/2020	78.05303768	82.16272923	-4.1096916	16.8895646	4.10969155	0.05265255	77.40993121	0.64310647	0.41358593	0.17105332	0.0021915
599	25/8/2020	78.52399207	73.94334613	4.58064594	20.9823172	4.58064594	0.05833435	78.6211174	-0.0971253	0.00943333	8.8988E-05	1.1333E-06
				MAD	3.154				MAD	2.340		
				MAPE	5%				MAPE	3%		
				MSE	13.836				MSE	0.315		
				RMSE	3.720				RMSE	0.561		

รูปที่ 36 ค่าความคลาดเคลื่อนด้วยการพยากรณ์อย่างง่าย (Naïve)


การสร้างแบบจำลองด้วยค่าเฉลี่ยเคลื่อนที่แบบบูรณาการอัตโนมัติ (Autoregressive integrated moving average, ARIMA [12]

วิธีการพยากรณ์โดยใช้หลักการเปลี่ยนแปลงที่ถดถอยตามช่วงเวลาก่อนหน้า (Autoregressive , AR) ร่วมกับวิธีการพยากรณ์ค่าเฉลี่ยเคลื่อนที่ (Moving Average , MA) ซึ่งเป็นการใช้ค่าความคลาดเคลื่อนมาพยากรณ์ โดยก่อนที่จะทำการทำนายด้วยวิธีนี้จะต้องทำการปรับลักษณะข้อมูลด้วยกันวนซ้ำ (Drift หรือ Irrigation, I) เพื่อให้รูปแบบของข้อมูลเป็นแบบคงตัว (Stationary) เกิดเป็นค่าน้ำหนักของ 3 ตัวแปร คือ “AR”, “I” และ “MA” ซึ่งการระบุค่าน้ำหนัก (Order) ของตัวแปรที่เหมาะสมต้องใช้การตรวจสอบลักษณะของข้อมูลเพื่อกำหนดค่าน้ำหนักโดยใช้แผนภูมิอนุกรมเชิงเวลา (Time Series Plot), แผนภูมิความสัมพันธ์ระหว่างตัวข้อมูลเอง (Autocorrelation Plot, ACF) ดังรูปที่ 35 และ 36 ที่ผ่านมา และเพิ่มด้วยแผนภูมิความสัมพันธ์ระหว่างตัวข้อมูลเองบางส่วน (Partial Autocorrelation, PACF) ดังรูปที่ 37



รูปที่ 37 แผนภูมิความสัมพันธ์ระหว่างตัวข้อมูลเองบางส่วน

ซึ่งจากแผนภูมิทั้ง 3 อ้างอิงจากทฤษฎีในบทที่ 2 พบว่าจะต้องทำการปรับข้อมูลให้เป็นลักษณะคงตัว (Stationary) ก่อนโดยแปลงข้อมูลให้เป็นข้อมูลความแตกต่างระหว่างข้อมูลปัจจุบันกับข้อมูลก่อนหน้าหนึ่งช่วงเวลา (1 Time Lag) จากนั้นทำการทดสอบลักษณะของข้อมูลใหม่ด้วยแผนภูมิทั้งสาม ดังรูปที่ 38



รูปที่ 38 แผนภูมิหลังจากทำการแปลงข้อมูล

ซึ่งจากแผนภูมิพบว่าลักษณะข้อมูลมีลักษณะคงตัวแล้ว จากรูปแบบนี้พบว่าค่า “ACF” จะลดลงเป็นศูนย์หลังจากช่วงเวลาแรก และค่า “PACF” ค่อยๆลดลงตามช่วงเวลาตามทฤษฎีพบว่า รูปแบบนี้แสดงค่าน้ำหนักที่ “MA” เท่ากับ 1 ประกอบกับการแปลงข้อมูลหนึ่งรอบ ค่าน้ำหนักของ “I” จึงเท่ากับ 1 ดังนั้น ค่าน้ำหนักของแบบจำลองนี้คือ “ARIMA” (0,1,1) จากนั้นนำค่าน้ำหนักไปสร้างแบบจำลองโดยใช้ภาษาอาร์ (R-Programming) ผ่านคำสั่งสำเร็จรูปได้แบบจำลองสมการด้านล่าง และผลของการทดสอบค่าซี (z-test) ดังรูปที่ 39

$$Diff. Y = 0.061 + 0.282e_{t-1}$$

```

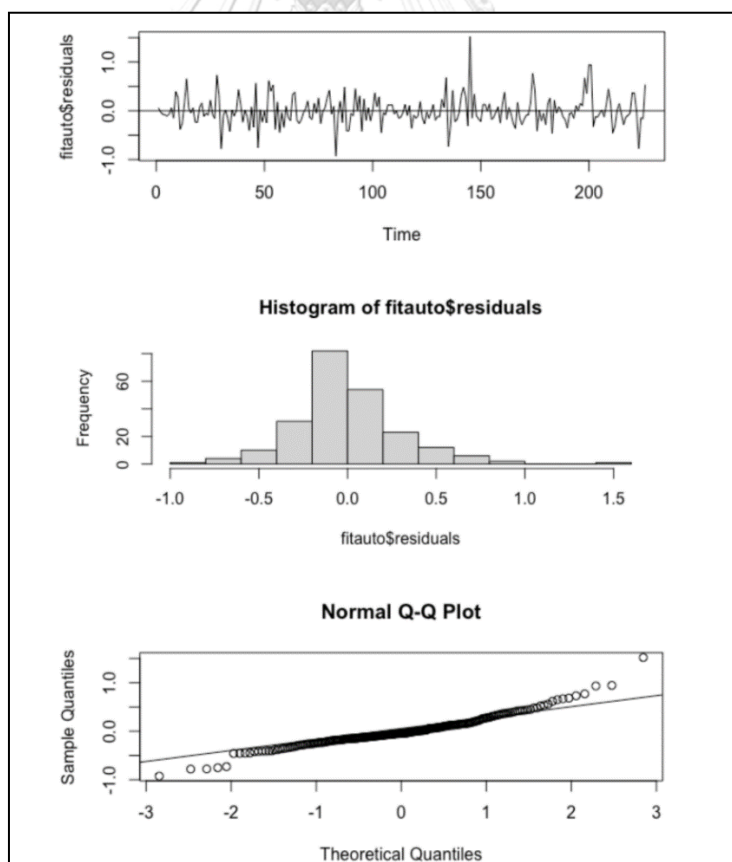
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ma1   -0.282044  0.081416 -3.4642 0.0005317 ***
drift  0.061246  0.017079  3.5859 0.0003359 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

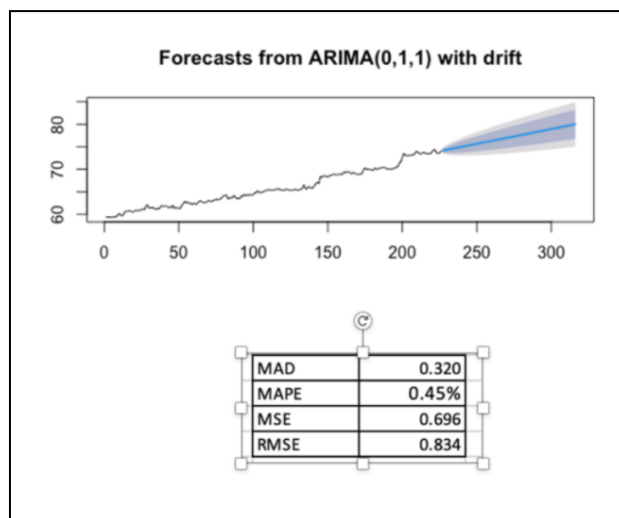
```

รูปที่ 39 z test of coefficients ARIMA(0,1,1)

จากนั้นทำการตรวจสอบการกระจายของความคลาดเคลื่อนด้วยแผนภูมิแบบต่างๆ (Residual Plot) ดังรูป ที่ 40 เพื่อตรวจสอบว่ามีการกระจายตัวแบบปกติหรือไม่ (Normal Distribution) ซึ่งจากผลการทดสอบพบว่ามีการกระจายตัวของค่าความคลาดเคลื่อนมีการกระจายตัวแบบปกติ จึงสามารถสรุปได้ว่าแบบจำลองนี้สามารถนำไปใช้ในการพยากรณ์ได้ จากนั้นนำแบบจำลองไปทดสอบกับชุดข้อมูลทดสอบ (Test Data Set) ได้ผลดังรูปที่ 41



รูปที่ 40 Residual plot



รูปที่ 41 ผลทดสอบความคลาดเคลื่อนของ ARIMA (0,0,1)

การสร้างแบบจำลองด้วยวิธีการถดถอยเชิงเส้น (Linear Regression) [12]

ในการสร้างแบบจำลองนี้ได้เลือกตัวแปรทำนายมาทั้งหมด 2 ตัวแปรโดยเลือกจากประสบการณ์และองค์ความรู้ที่เกี่ยวข้องกับปั๊มแบบมอเตอร์ปิดผนึกของผู้ทำวิจัย คือ ค่ากระแสของปั๊ม และค่าสภาพการเคลื่อนแนวแกนเพลลา โดยใช้ระดับความเชื่อมั่นที่ 95%

Y: Bearing Condition – Radial (%)

X₁: Current (A)

X₂: Axial Movement (%)

จากทฤษฎีในบทที่ 2 ได้ทำการสร้างแบบจำลองโดยใช้ข้อมูลตัวอย่างของงานวิจัยนี้โดยแยกเป็นตัวแปรทำนายหนึ่งตัวและตัวแปรทำนาย 2 ตัว ดังตารางที่ 6 ซึ่งประกอบไปด้วยสมการของแบบจำลอง และค่าสัดส่วนที่ค่าพยากรณ์ที่สามารถอธิบายได้ด้วยตัวอาร์สแควร์ (R²) ซึ่งจะมีค่าอยู่ระหว่าง 0 -1 หรือสามารถคิดเป็นเปอร์เซ็นต์ได้ด้วยการคูณ 100 กลายเป็นค่าอยู่ระหว่าง 0% - 100%

ตารางที่ 10 แบบจำลองการถดถอยเชิงเส้น

Predictor	Model	R ²
x ₁	Y = 50.83 + 0.17x ₁	11%
x ₂	Y = 0.54 + 0.56x ₂	18%
x ₁ , x ₂	Y = -76.38 + 0.97x ₁ + 10.14x ₂	39%

ซึ่งจากผลของค่าอาร์สแควร์ (R^2) พบว่าแบบจำลองที่มีตัวแปรพยากรณ์ x_1, x_2 นั้นให้ค่าสูงสุด จึงเลือกแบบจำลองนี้เป็นตัวแทนในการเปรียบเทียบประสิทธิภาพกับแบบจำลองอื่นๆ ก่อนที่จะนำไปประเมินค่าความคลาดเคลื่อนคลื่อนนั้น ได้นำแบบจำลองไปทดสอบหาการกระจายตัวของค่าความคลาดเคลื่อนและทำการวิเคราะห์ความแปรปรวน (Analysis of Variance, ANOVA) เพื่อดูว่าตัวแปรทำนายและผลพยากรณ์มีความสัมพันธ์กันอย่างมีนัยยะสำคัญหรือไม่ ซึ่งจากผลการทดสอบก็พบว่าภาพรวมของแบบจำลองนั้นผ่านค่าทดสอบ สามารถนำแบบจำลองนี้ไปใช้งานได้ตามรูปที่ 42 จากนั้นทำการทดสอบค่าความคลาดเคลื่อนได้ผลดังรูปที่ 43

SUMMARY OUTPUT								
Regression Statistics								
Multiple R	0.63184645							
R Square	0.39922994							
Adjusted R Sq	0.38362552							
Standard Error	4.00404207							
Observations	80							
ANOVA								
	df	SS	MS	F	Significance F			
Regression	2	820.356855	410.178427	25.5844186	3.0218E-09			
Residual	77	1234.49117	16.0323529					
Total	79	2054.84803						
	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%	Lower 95.0%	Upper 95.0%
Intercept	-76.384709	18.6918288	-4.0865295	0.00010649	-113.6049	-39.164523	-113.6049	-39.164523
P-1703 Axial E	0.97010477	0.1863609	5.20551665	1.5615E-06	0.59901281	1.34119673	0.59901281	1.34119673
P-1703 Current	10.1416495	1.43784628	7.05336146	6.5862E-10	7.2785318	13.0047672	7.2785318	13.0047672

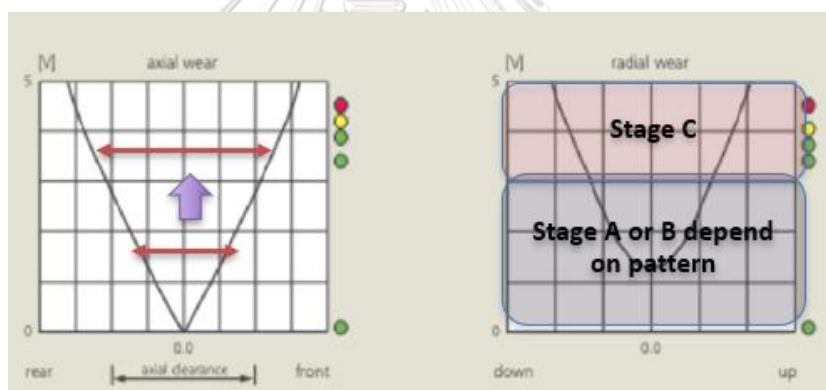
รูปที่ 42 ANOVA table

Date	Y P-1703 Radial E-Monitor	Predicted	X1 P-1703 Axial E-Monitor	X2 P-1703 Current	et	et2	Abs	Abs/Yt
21/01/2562	57.561201	60.05340281	32.49018221	10.3453813	-2.49220181	6.21106986	2.49220181	0.04329656
22/01/2562	57.31061383	60.3257783	32.71862356	10.35038674	-3.01516447	9.09121681	3.01516447	0.05261093
23/01/2562	57.43249201	60.3184928	32.69842801	10.35160018	-2.88600078	8.32900051	2.88600078	0.05025031
24/01/2562	57.2781481	60.51986093	32.9488904	10.34749763	-3.24171283	10.5087021	3.24171283	0.05659598
25/01/2562	57.47938626	60.87540933	33.29200788	10.34973479	-3.39602307	11.5329727	3.39602307	0.05908245
26/01/2562	57.45541779	60.6539172	33.12254583	10.34410492	-3.19849941	10.2303985	3.19849941	0.05566924
27/01/2562	57.58502857	60.66572821	33.13695852	10.34389087	-3.08069964	9.49071028	3.08069964	0.0549827
28/01/2562	57.40583086	61.01908127	33.40407236	10.35318173	-3.61325041	13.0555785	3.61325041	0.06294222
29/01/2562	57.12453498	61.19728163	33.52671954	10.359021	-4.07274665	16.5872653	4.07274665	0.07129593
30/01/2562	57.14368672	61.27333889	33.65188191	10.35454802	-4.12965216	17.054027	4.12965216	0.07226786
31/01/2562	57.07709609	61.35935237	33.75741645	10.35293427	-4.28225627	18.3377188	4.28225627	0.07502583
1/02/2562	57.39276109	61.28594455	33.73612671	10.3477325	-3.89318346	15.1568774	3.89318346	0.06783405
2/02/2562	57.7805688	61.70213315	34.10852165	10.35314843	-3.92156435	15.3786669	3.92156435	0.06786995
3/02/2562	57.57942154	61.70883374	34.18302437	10.34668254	-4.12941219	17.0520451	4.12941219	0.07171681
4/02/2562	57.5495312	61.59325837	34.11001094	10.34227056	-4.04372717	16.3517295	4.04372717	0.07026516
5/02/2562	57.56240758	61.86536185	34.21843531	10.35872947	-4.30295427	18.5154155	4.30295427	0.07475285
6/02/2562	57.56763154	61.89763726	34.28958454	10.35510612	-4.33000572	18.7489495	4.33000572	0.07521598
7/02/2562	57.55895613	64.22931345	34.35306629	10.57894468	-6.67035732	44.4936668	6.67035732	0.11588739
8/02/2562	57.56212323	62.32786753	34.41879007	10.38516901	-4.7657443	22.7123187	4.7657443	0.08279306
9/02/2562	57.55632795	62.57361128	34.59318929	10.39271791	-5.01728333	25.1731321	5.01728333	0.08717171
					MAD	3.924		
					MAPE	7%		
					MSE	16.201		
					RMSE	4.025		

รูปที่ 43 ผลทดสอบความคลาดเคลื่อนของแบบจำลอง Linear Regression

3.4 การสร้างแบบจำลองจำแนกสถานะปั๊มแบบมอเตอร์ปิดผนึก (Classification)

สถานะปัจจุบันของปั๊มแบบมอเตอร์ปิดผนึกได้ถูกจำแนกโดยอ้างอิงกับสภาพหน้างานและพารามิเตอร์ที่อ่านค่าได้ ออกเป็น 3 ระดับ คือระดับ “Stage A”, “Stage B” และ “Stage C” ตามตารางที่ 7 ซึ่งจำแนกโดยวิศวกรที่มีองค์ความรู้หรือเชี่ยวชาญเกี่ยวกับปั๊มแบบมอเตอร์ปิดผนึก (Expertise Judgment) ในโรงงานตัวอย่าง โดยการจำแนกสถานะของปั๊มแบบมอเตอร์ปิดผนึกนั้นใช้ข้อมูลจากอุปกรณ์ตรวจสอบสภาพลูกปืนชนิดทรงกระบอกคาร์บอนที่ติดตั้งจากผู้ผลิตปั๊ม [3] ซึ่งเป็นอุปกรณ์ที่รับข้อมูลจากเซ็นเซอร์ที่ติดตั้งในสเตเตอร์ (Stator) ในสองทิศทางคือแนวแกน (Radial) และแนวเพลา (Axial) เมื่อลูกปืนทรงกระบอกคาร์บอนของปั๊มชำรุดเกิดขึ้น โรเตอร์ (Rotor) จะเคลื่อนด้านแนวรัศมีหรือแนวแกนออกจากตำแหน่งปกติ เซ็นเซอร์วัดจะตรวจจับและส่งสัญญาณเอาท์พุทบนจอแอลอีดี (LED) ที่ปั๊ม ไฟแอลอีดี (LED) สีเขียวแสดงถึงสถานะปกติไฟแอลอีดี (LED) สีเหลืองแสดงว่าปั๊มควรได้รับการยกเครื่องและตรวจสอบ ควรหยุดใช้งานปั๊ม หากไฟ LED สีแดงสว่างขึ้น ดังแผนภูมิในรูปที่ 44



รูปที่ 44 แผนภูมิสถานะเปรียบเทียบกับไฟแอลอีดีของปั๊ม [24]

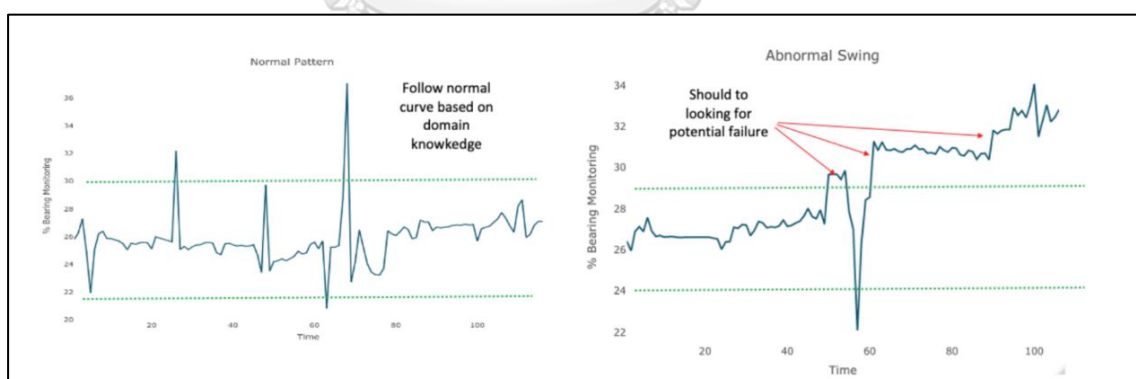
ปัญหาของวิธีการจำแนกสถานะวิธีนี้คือ ระยะเวลาที่สถานะของปั๊มแบบมอเตอร์ปิดผนึกเปลี่ยนจากสถานะปกติ (ไฟแอลอีดีของปั๊มจะเป็นสีเขียวหนึ่งดวง) เปลี่ยนไปเป็นสถานะผิดปกติ (ไฟแอลอีดีจะเป็นสีเขียวหนึ่งสองดวง, สีเหลือง หรือ สีแดง) สั้นเกินไป ถ้าไม่จำแนกสถานะ “Stage B” ออกจากสถานะ “Stage A” จะทำให้วางแผนบำรุงรักษาไม่ทัน ซึ่งถ้าพิจารณาที่ค่าพารามิเตอร์ของปั๊มที่ใช้ในการประเมินจะพบว่า ลักษณะการเปลี่ยนแปลงของพารามิเตอร์นั้นไม่ใช่การเติบโตเชิงเส้น (Linear) แต่จะเพิ่มขึ้นด้วยอัตราเร่งถ้าปั๊มมีความผิดปกติ และค่าพารามิเตอร์จะเปลี่ยนแปลงเร็วที่สุดเมื่อที่ใกล้ถึงจุดสิ้นสุดของอายุขัยของปั๊ม ซึ่งถ้าปั๊มเกิดแสดงสัญญาณความเสียหายไกลจากรอบการหยุดซ่อมบำรุงโรงงานตามแผน อาจมีความเสี่ยงที่จะเกิดขึ้นการบำรุงรักษาโดยไม่ได้วางแผนไว้ (Unplanned maintenance) เพื่อแก้ปัญหานี้ ผู้เชี่ยวชาญจึงนำเข้าสู่สัญญาณและแปลงหน่วยเป็น

เปอร์เซ็นต์ หลังจากนั้นนำมาพล็อตสัญญาณข้อมูลเพื่อเรียนรู้รูปแบบลักษณะปกติและผิดปกติแล้ว
จำแนกสถานะของปั๊มโดยจำแนกสถานะ “Stage B” ออกจากสถานะ “Stage A” ตารางที่ 11
แสดงสถานะเปรียบเทียบกับหลอดไฟแสดงผลของปั๊ม

ตารางที่ 11 การแบ่งระดับสถานะของปั๊มในโรงงานตัวอย่าง

สถานะ	หลอดไฟแสดงผลของปั๊ม
Stage A	สีเขียว 1 ดวง
Stage B	สีเขียว 1 ดวง
Stage C	สีเขียว 2 ดวงขึ้นไปจนถึงสีแดง

เหตุผลในการจำแนกสถานะเป็นระดับแทนลักษณะการเสียโดยตรง (Failure Mode) อ้างอิง
ผลการทำ “FMEA” เนื่องจากสภาพปั๊มถูกประเมินสภาพจากพารามิเตอร์ที่ได้จากเซ็นเซอร์ออนไลน์
เพียงสองหรือสามตัวซึ่งมีข้อมูลไม่เพียงพอที่จะระบุสาเหตุที่แท้จริง ในการจำแนกสถานะที่สำคัญคือ
“Stage B” เนื่องจากเป็นการตรวจจับความล้มเหลวตั้งแต่เนิ่นๆ ซึ่งต้องการข้อมูลสภาพแวดล้อมจาก
แหล่งออฟไลน์ เช่น ระดับเสียง (Noise Level) ค่าการสั่นสะเทือน (Vibration) อุณหภูมิของปั๊ม
(Temperature) และโหมดการทำงาน (Operating mode) เพื่อรองรับการหาสาเหตุที่แท้จริงต่อไป
โดยลักษณะของสถานะ “Stage B” นั้นมีลักษณะของข้อมูลดังตัวอย่าง รูปที่ 45




รูปที่ 45 ตัวอย่างรูปแบบข้อมูลในกรณีศึกษา

จากที่กล่าวไปในข้างต้นในงานวิจัยส่วนนี้ จึงมุ่งเน้นไปการสร้างแบบจำลองจำแนกสถานะ
ของปั๊ม โดยมุ่งเน้นไปที่สถานะ “Stage B” ซึ่งต้องใช้ข้อเท็จจริงของผู้เชี่ยวชาญในการจำแนก ความ
คาดหวังของแบบจำลองนี้คือลดเวลาในการทำงานของวิศวกรผู้เชี่ยวชาญในการจำแนกสถานะ โดย
งานวิจัยนี้ได้ทดลองสร้างแบบจำลองโดยการประยุกต์วิธีการเรียนของเครื่องแบบมีผู้สอน

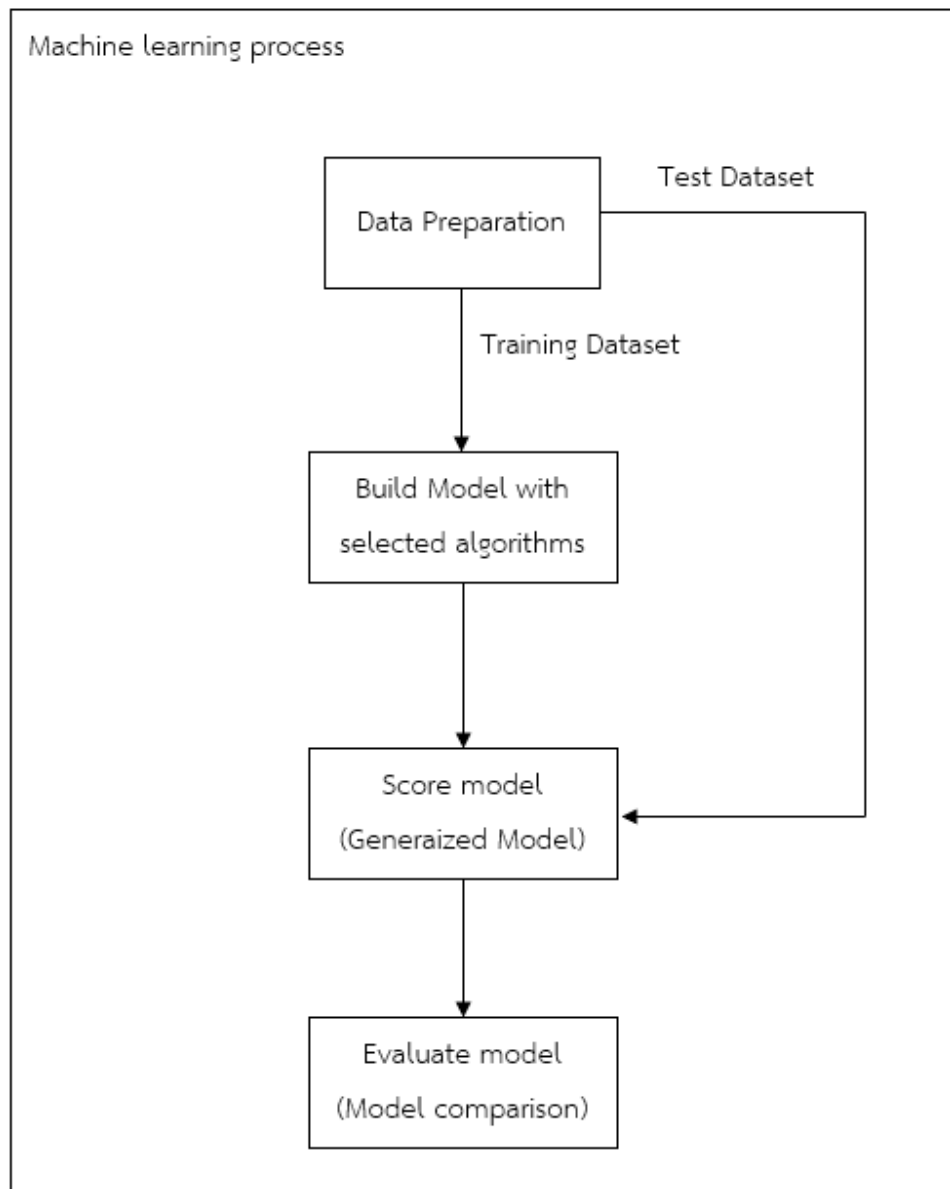
(Supervised Machine Learning) [8] แบบจำแนก (Classification Algorithm) [8] รูปแบบต่างๆ มาทดลองกับข้อมูลของโรงงานตัวอย่าง และมีการวัดประสิทธิภาพเพื่อเลือกแบบจำลองที่เหมาะสมที่สุดนำไปใช้งานต่อไป

แนวทางในการวิจัยครั้งนี้ใช้อัลกอริทึมการเรียนรู้ของเครื่อง เพื่อแจ้งเตือนหากพบสัญญาณความผิดปกติที่อาจเกิดขึ้น โดยขั้นตอนการสร้างแบบจำลองการเรียนรู้ของเครื่องนั้นประยุกต์ใช้องค์ความรู้ที่ได้จากการศึกษาทฤษฎีการเรียนรู้ของเครื่อง [7] และงานวิจัยที่มีการสร้างแบบจำลองการเรียนรู้ของเครื่อง ดังรูปที่ 46 เป็นแผนผังการสร้างแบบจำลองจากงานวิจัยที่เกี่ยวข้อง[11]




รูปที่ 46 แผนผังการสร้างแบบจำลอง [11]


โดยรูปที่ 47 เป็นขั้นตอนการสร้างแบบจำลองที่ใช้การวิจัย ประกอบด้วย ขั้นตอนแรกเป็นกระบวนการจัดเตรียมข้อมูล เพื่อจัดการชุดข้อมูลเพื่อล้างข้อมูลผิดปกติ จัดการข้อมูลที่ขาดหายไป และเลือกคุณลักษณะข้อมูลหรือฟีเจอร์ (Feature) ที่จะใช้ในการสร้างแบบจำลอง ซึ่งชุดข้อมูลที่ใช้สร้างแบบจำลองจะมีการระบุสถานะการลาเบล (Label) ชุดข้อมูลโดยผู้เชี่ยวชาญ เพื่อใช้สอนแบบจำลอง ขั้นตอนถัดไปเป็นการปรับแต่งค่าไฮเปอร์พารามิเตอร์ (Hyperparameter) ของแต่ละแบบจำลองซึ่งค่าพารามิเตอร์เฉพาะของแต่ละอัลกอริทึมที่เลือกใช้ ประกอบกับวิธีการสุ่มตัวอย่างใหม่เพื่อปรับปรุงผลลัพธ์ ขั้นตอนที่สาม คือการให้คะแนนแบบจำลองโดยชุดข้อมูลทดสอบ และขั้นตอนสุดท้ายคือการประเมินแต่ละแบบจำลองเชิงเปรียบเทียบประสิทธิภาพ ผลที่ได้จากขั้นตอนการสร้างแบบจำลองจะได้แบบจำลองที่เหมาะสมสำหรับปรับใช้กับระบบผู้เชี่ยวชาญในงานวิจัย โดยชุดข้อมูลจะประกอบไปด้วย 1,863 ข้อมูล แบ่ง ข้อมูลละ 7 ฟีเจอร์ (Feature) เริ่มต้น และระบุเป็นสามสถานะเป้าหมาย ชุดข้อมูลแบบสุ่มร้อยละแปดสิบเพื่อใช้ในการสร้างแบบจำลอง และร้อยละสิบสำหรับประเมินแบบจำลอง ดังรูปที่ 48 และ 49



รูปที่ 47 ขั้นตอนการสร้างแบบจำลองการเรียนรู้ของเครื่อง




รูปที่ 48 สัดส่วนสถานะของข้อมูล



รูปที่ 49 ตัวแปรที่ใช้ในการสร้างแบบจำลอง

3.4.1. การสร้างแบบจำลองการเรียนรู้ของเครื่อง

ปัจจัยที่ทำให้การใช้การเรียนรู้ของเครื่องประสบความสำเร็จในงานวิจัยนี้คือการคัดเลือกฟีเจอร์ (Feature) หรือตัวแปรคุณลักษณะของข้อมูลที่ใช้ในแบบจำลอง เนื่องปั๊มแบบมอเตอร์แบบปิดผนึกหนึ่งตัวมีฟีเจอร์จำนวนมาก การที่จะนำทุกฟีเจอร์มาใช้ในการสร้างแบบจำลองการเรียนรู้ของเครื่องนั้น อาจส่งผลให้ผลที่มีความคลาดเคลื่อนได้ เนื่องจากมีเพียงบางฟีเจอร์เท่านั้นที่มีคุณลักษณะหรือความสัมพันธ์การสัญญาณการเสียหายของปั๊มที่ต้องการจำแนกออกมา ดังนั้นในการทำวิจัยนี้จึงมีการวิเคราะห์ลักษณะการเสียและระดับผลกระทบ (Failure Mode and Effect Analysis, FMEA) เพื่อหาลักษณะการเสีย (Failure Mode) ที่สำคัญ ที่มีผลกระทบ (Failure Effect) ทำให้ปั๊มไม่ทำงานได้ตามหน้าที่หลักของปั๊มได้ (Primary Function โดยพิจารณาคัดเลือกเฉพาะฟีเจอร์ที่สำคัญมาใช้ในการสร้างแบบจำลอง โดยจากผลการวิจัยได้เลือกค่าสภาพลูกปืนทรงกระบอกคาร์บอน (Carbon Bush Bearing Condition) ทั้งด้านแนวแกน (Radial) และแนวเพลา (Axial) มาใช้ในการสร้างแบบจำลอง ดังรูปที่ 50



รูปที่ 50 ค่าสภาพลูกปืนทรงกระบอกคาร์บอน

โดยได้ทำการวิเคราะห์ฟีเจอร์ (Feature Engineering) เพิ่มเติม ซึ่งก็คือ ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ที่ถูกคัดเลือกมาจากกระบวนการทำ การวิเคราะห์ลักษณะการเสียดและระดับผลกระทบ (Failure Mode and Effect Analysis, FMEA) โดยนำชุดข้อมูลที่จัดเตรียมไว้มาวิเคราะห์ โดยคัดเลือกข้อมูลที่มีการระบุสถานะเป็น “Stage B” ซึ่งเป็นสถานะเป้าหมายของงานวิจัย จากการวิเคราะห์พบว่าจะมีการเปลี่ยนแปลงที่สำคัญของค่าสภาพลูกปืนทรงกระบอกคาร์บอน ระหว่างช่วงเวลาระหว่างหนึ่งสัปดาห์ สี่สัปดาห์ จนถึงสิบสองสัปดาห์ย้อนหลัง เมื่อเปรียบเทียบกับกลุ่มปั๊มที่มีการระบุสถานะเป็น “Stage A” อย่างเห็นได้ชัด ดังข้อมูลในตารางที่ 12 และ 13 โดยช่วงสัปดาห์ที่นำมาเปรียบเทียบนั้นเลือกจากองค์ความรู้ของผู้เชี่ยวชาญ ซึ่งความแตกต่างนี้อาจเป็นปัจจัยในการจำแนกสถานะระหว่าง “Stage A” และ “Stage B” ได้ จึงทำการนำฟีเจอร์ค่าความแตกต่างระหว่างช่วงสัปดาห์ของค่า ค่าสภาพลูกปืนทรงกระบอกคาร์บอนมาใช้ในการสร้างแบบจำลอง อีกหนึ่งฟีเจอร์ที่นำมาใช้ในการสร้างแบบจำลองนอกเหนือจาก ค่าสภาพลูกปืนทรงกระบอกคาร์บอน คือค่ากระแส (Current) ใช้งานของปั๊มซึ่งการเปลี่ยนแปลงของค่ากระแสที่ผิดปกตินั้นถือว่าเป็นอีกหนึ่งสัญญาณการเสียดอ่อนเร้นของปั๊มที่ทำให้ปั๊มไม่สามารถทำงานได้

ตารางที่ 12 ค่าเฉลี่ยการเปลี่ยนแปลงค่า Bearing Condition (Radial)

สถานะ	ค่าเฉลี่ยการเปลี่ยนแปลง ใน 1 สัปดาห์ Bearing Condition (Radial)	ค่าเฉลี่ยการเปลี่ยนแปลงใน 4 สัปดาห์ Bearing Condition (Radial)	ค่าเฉลี่ยการเปลี่ยนแปลงใน 12 สัปดาห์ Bearing Condition (Radial)
Stage A	0.39%	0.96%	0.96%
Stage B	2.29%	4.81%	8.32%

ตารางที่ 13 ค่าเฉลี่ยการเปลี่ยนแปลงค่า Bearing Condition (Axial)

สถานะ	ค่าเฉลี่ยการเปลี่ยนแปลง ใน 1 สัปดาห์ Bearing Condition (Axial)	ค่าเฉลี่ยการเปลี่ยนแปลงใน 4 สัปดาห์ Bearing Condition (Axial)	ค่าเฉลี่ยการเปลี่ยนแปลงใน 12 สัปดาห์ Bearing Condition (Axial)
Stage A	0.40%	0.68%	1.15%
Stage B	4.02%	6.97%	10.65%


จากการวิเคราะห์ในข้างต้นจึงสรุปได้ว่า ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวแกน และแนวเพลลา ณ เวลาปัจจุบันและการเปลี่ยนแปลงในช่วงหนึ่งถึงสิบสองสัปดาห์ย้อนหลังและค่ากระแสใช้งาน นั้นเหมาะสมสำหรับการสร้างแบบจำลองการเรียนรู้ของเครื่องในงานวิจัยนี้ดังตารางที่ 14

ตารางที่ 14 Feature ที่เหมาะสมสำหรับการสร้างแบบจำลองการเรียนรู้ของเครื่องในงานวิจัยนี้

ฟีเจอร์	นิยาม	หน่วย
EI_C	ค่ากระแสใช้งานของปั๊ม	แอมแปร์
E_R0	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวแกน ณ สัปดาห์ปัจจุบัน	เปอร์เซ็นต์
E_R1	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวแกน ที่เปลี่ยนแปลงไปในหนึ่งสัปดาห์ย้อนหลัง	เปอร์เซ็นต์
E_R4	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวแกน ที่เปลี่ยนแปลงไปในสี่สัปดาห์ย้อนหลัง	เปอร์เซ็นต์
E_12	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวแกน ที่เปลี่ยนแปลงไปในสิบสองสัปดาห์ย้อนหลัง	เปอร์เซ็นต์
E_A0	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวเพลลา ณ สัปดาห์ปัจจุบัน	เปอร์เซ็นต์
E_A1	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวเพลลา ที่เปลี่ยนแปลงไปในหนึ่งสัปดาห์ย้อนหลัง	เปอร์เซ็นต์
E_A4	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวเพลลา ที่เปลี่ยนแปลงไปในสี่สัปดาห์ย้อนหลัง	เปอร์เซ็นต์
E_A12	ค่าสภาพลูกปืนทรงกระบอกคาร์บอน ด้านแนวเพลลา ที่เปลี่ยนแปลงไปในสิบสองสัปดาห์ย้อนหลัง	เปอร์เซ็นต์

อัลกอริทึมที่เลือกทั้งหมด 4 อัลกอริทึมมาทำการสร้างและทดสอบ ประกอบไปด้วย อัลกอริทึม เค-เนียร์ส เนเบอร์ (K-nearest neighbor) หรือ “kNN” เป็นแบบจำลองที่เรียนรู้จากตัวอย่างข้อมูล (Instance-based learner) [7] โดยอัลกอริทึมจะหาความสัมพันธ์ระหว่างจุดข้อมูลหรือในที่นี้เรียกว่า เพื่อนบ้าน (Neighbor) บนระนาบหรือ “Space” ของชุดข้อมูล “n” มิติ (n-Dimensional space) ซึ่งทำการวัดระยะห่างแบบยูคลิด (Euclidean distance) ระหว่างจุดของข้อมูลกับเพื่อนบ้านหรือชุดข้อมูลที่ใช้สอนที่อยู่บนระนาบข้อมูลเดียวกัน โดยมีไฮเปอร์พารามิเตอร์คือค่า “k” ซึ่งคือจำนวนเพื่อนบ้านที่ใกล้ที่สุด อัลกอริทึมจะค้นหาเพื่อนบ้านที่ใกล้ที่สุด “k” เพื่อนบ้าน


จากการวัดระยะและทำการจำแนก (Classify) คลาส (Class) ตามคลาสของข้อมูลส่วนมากของจุดข้อมูลเพื่อนบ้านที่ใกล้ที่สุด (Majority Vote) ตามจำนวนที่กำหนด ดังรูปที่ 51



รูปที่ 51 ตัวอย่างการทำงานของอัลกอริทึม “kNN”
(ที่มา จุฬาลงกรณ์มหาวิทยาลัย)

http://res.cloudinary.com/dyd911kmh/image/upload/f_auto,q_auto:best/v1531424125/KNN_final1_ibdm8a.png

อัลกอริทึมที่สองที่เลือกคือ แรนดอมฟอเรส (Random Forest) หรือ “RF” เป็นแบบจำลองที่เรียนรู้จากรูปแบบแผนผังแบบต้นไม้ (Tree-based learner) [25] คือมีรากและการแตกแขนงของใบ ซึ่งพัฒนามาจากอัลกอริทึม ต้นไม้การตัดสินใจ (Decision Tree) อีกทีหนึ่ง โดยอัลกอริทึมจะรวมแผนผังการตัดสินใจที่ไม่สัมพันธ์กันโดยอ้างอิงจากชุดย่อยของข้อมูลการฝึกที่สุ่มเลือกโดยวิธีการบูตสเตรป (Bootstrap method) [26] ดังรูปที่ 52 ไฮเปอร์พารามิเตอร์ของอัลกอริทึมนี้หลักคือจำนวนตัวแปรทำนายแบบสุ่ม (No. of Random Selected Predictors, Mtry) และอาจจะมียุเปอร์พารามิเตอร์อื่นๆ อาทิ เช่น จำนวนต้นไม้ (ntree) หรือ วิธีการสุ่มข้อมูล (Splitting Rule)

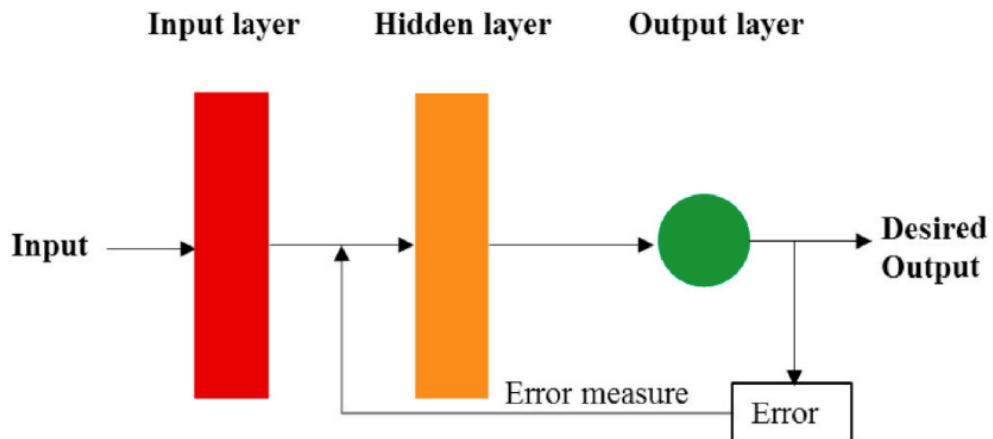


รูปที่ 52 ตัวอย่างการทำงานของอัลกอริทึม “RF”

(ที่มา

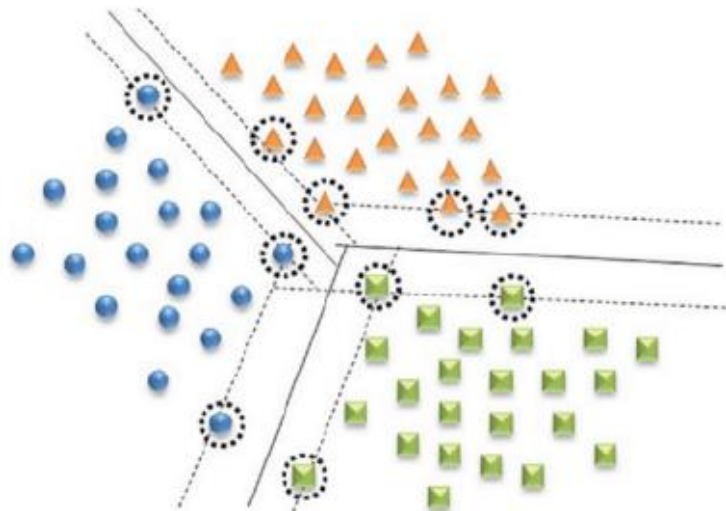
https://upload.wikimedia.org/wikipedia/commons/7/76/Random_forest_diagram_complete.png)

อัลกอริทึมที่สามที่เลือกคือ โครงข่ายประสาทเทียม (Artificial neural networks) หรือ “ANN” เป็นแบบจำลองที่เรียนรู้ โดยอาศัยหลักการของระบบประสาทของสมองมนุษย์ (Biological human neural networks) ซึ่งประกอบด้วย ชั้นของหน่วยประมวลผล (Layer) หรือโหนด (Node) และชั้นซ่อน (Hidden Layer) โดยอัลกอริทึมมีส่วนที่ทำหน้าที่แปลงผลลัพธ์ของการประมวลผลเป็น รูปแบบผลลัพธ์ที่ต้องการเรียกว่า “Activated function” โดยอัลกอริทึมที่เชื่อมต่อกับชุดข้อมูล จะเริ่มทำงานโดยกำหนดน้ำหนักเริ่มต้นให้กับการเชื่อมต่อแต่ละโหนดในโครงสร้างประสาทเพื่อทำการประมวลผลผลลัพธ์ โดยทั่วไปอัลกอริทึมประสาทเครือข่ายจะแบ่งประเภทได้ 2 ประเภท คือ “Feed-forward” และ “Backpropagation” โดยประเภท “Backpropagation” นั้นใช้กันอย่างแพร่หลาย ซึ่งช่วยในคำนวณความคลาดเคลื่อนและความคลาดเคลื่อนนั้นวนกลับมาปรับน้ำหนักเพื่อปรับปรุงประสิทธิภาพจนถึง ไม่สามารถปรับปรุงได้อีกต่อไป [27] ดังรูปที่ 53




รูปที่ 53 ตัวอย่างการทำงานของอัลกอริทึม “ANN” [27]

อัลกอริทึมสุดท้ายที่เลือก ซัพพอร์ต เวกเตอร์แมชชีน (Support Vector Machine) หรือ “SVM” เป็นแบบจำลองที่เรียนรู้ โดยหลักการจำแนกประเภทเชิงเส้น (Linear classifier) ซึ่งจะทำการหาขอบเขตมาร์จิน (Margin) สูงสุดบนระนาบไฮเปอร์เพลน (Hyperplane boundaries) เพื่อนำขอบเขตนั้นมาทำการจำแนกหรือทำนาย[28] ดังรูปที่ 54 ซึ่งจำนวนข้อมูลที่อยู่ขอบเขตนั้นจะแทนค่าด้วยพารามิเตอร์ “ c ” ซึ่งเป็นไฮเปอร์พารามิเตอร์ของอัลกอริทึมนี้



รูปที่ 54 ตัวอย่างการทำงานของอัลกอริทึม “SVM” [29]

ในงานวิจัยนี้ จะประยุกต์ใช้วิธี ครอสวาลิเดชัน (Cross-validation) [30] หรือ “CV” ในการสร้างแบบจำลองกับชุดข้อมูลที่ใช้สอน (Training Dataset) เพื่อหาค่าไฮเปอร์พารามิเตอร์ที่ทำให้แบบจำลองที่มีประสิทธิภาพสูงสุดในแต่ละอัลกอริทึม ก่อนที่จะนำไปเปรียบเทียบระหว่างอัลกอริทึม ซึ่งการทำ ครอสวาลิเดชัน จะลดความเสี่ยงที่จะเกิดโอเวอร์ฟิตติ้ง (Overfitting) อีกด้วย โดยชุดข้อมูลการสอนจะแบ่งออกเป็นชุดย่อย “k” ชุด แบบจำลองได้รับการสอนโดยใช้ชุดข้อมูล “k-1” ชุด จากนั้นตรวจสอบกับอีก 1 ชุดที่เหลือ และสลับเปลี่ยนชุดข้อมูลระหว่างชุดข้อมูลสอนและทดสอบจนครบรอบ ดังรูปที่ 55 จากนั้นนำผลของทุกรอบมาหาค่าเฉลี่ยประสิทธิภาพ ซึ่งจะกลายเป็นค่าประสิทธิภาพของอัลกอริทึมนั้นๆ โดยเลือกแบบจำลองที่มีประสิทธิภาพสูงสุดไปทดสอบกับข้อมูลการทดสอบซึ่งเป็นการประเมินขั้นสุดท้าย (Final Evaluation and model generalization) ตารางที่ 9 แสดงถึงไฮเปอร์พารามิเตอร์ของอัลกอริทึมที่ทำการจูนด้วยวิธี “CV” ด้วยการแบ่งเป็น 5 ชุด (k = 5)



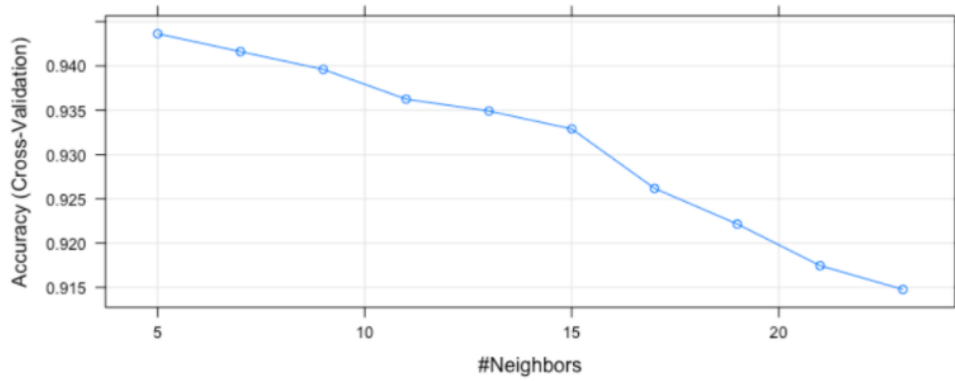
รูปที่ 55 ตัวอย่าง “Cross-validation framework”

(ที่มา https://scikit-learn.org/stable/_images/grid_search_cross_validation.png)


ตารางที่ 15 แบบจำลองที่เหมาะสมจากการปรับค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม

อัลกอริทึม	ไฮเปอร์พารามิเตอร์	ค่าทดสอบ	ค่าเหมาะสม
kNN	No. of Neighbors, k	5, 7, 9, 11, 13, 15, 17, 21, 23	k = 5
RF	No. of Random Selected Predictors, Mtry Splitting Rule	2, 3, 4, 5, 6, 7, 8 Gini, Extratrees	Mtry = 3, Gini
ANN	No. of hidden unit, Size Weight Decay	1, 3, 5, 7, 9, 11, 13, 15, 17,19 0.00 to 0.10	Size = 13, Decay = 0.01
SVM	Cost, C	0 to 2	C = 1.156895

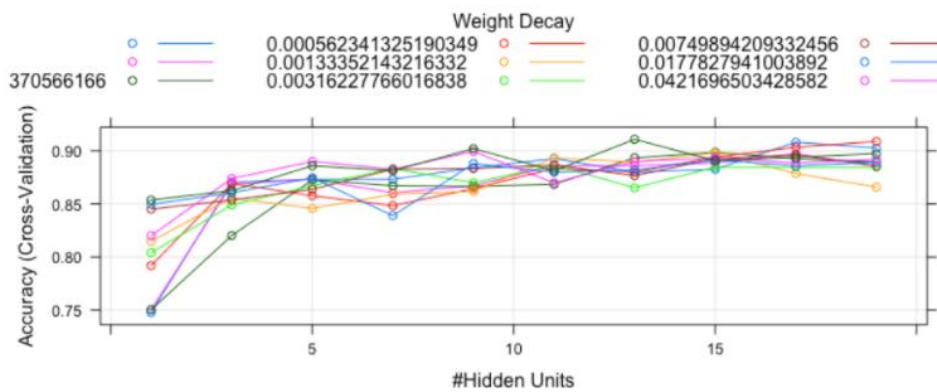
ค่าไฮเปอร์พารามิเตอร์ที่ดีที่สุดของอัลกอริทึม “kNN” ซึ่งก็คือ “k” หรือจำนวนเพื่อนบ้าน โดยเริ่มที่ “k” เท่ากับ 5 หรือ ห้าเพื่อนบ้าน พบว่าเมื่อเพิ่มขึ้นจำนวนเพื่อนบ้านมากกว่าขึ้นจาก 5 ไป ความแม่นยำของแบบจำลองนั้นมีค่าลดลง ดังนั้นที่ “k” เท่ากับ 5 จะได้ค่าความแม่นยำสูงสุด (เนื่องจากกำหนดค่าในการปรับค่า “k” ต่ำสุดที่ 5 ซึ่งเป็นการกำหนดมาจากโปรแกรมจึงไม่ได้ทำการ ทดสอบที่ค่า “k” น้อยกว่า 5) ดังรูปที่ 56 สำหรับอัลกอริทึม “RF” (Random Forest) การปรับค่า ไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดพบว่า จำนวนตัวทำนายที่ใช้ในการตัดสินใจ (Mtry) 3 ตัว และ ใช้กฎการจำแนกข้อมูล (Split) แบบ “Gini Impurity” นั้นให้ค่าความแม่นยำสูงสุด โดยถ้าการใช้กฎ การจำแนกข้อมูลแบบ “Extratrees” อาจใช้ตัวทำนายมากกว่าเพื่อให้ได้ค่าความแม่นยำเทียบเท่ากับ แบบ “Gini” ดังรูปที่ 57 ในส่วนของความแม่นยำของอัลกอริทึม “ANN” (Artificial Neural Network) ความแม่นยำเพิ่มขึ้นตามจำนวนของโหนดของชั้นที่ซ่อนอยู่ (Hidden Layer) อย่างไรก็ตาม การเพิ่มจำนวนโหนดของชั้นที่ซ่อนอยู่มากขึ้นจะส่งผลให้ใช้เวลาในการประมวลผลมากขึ้น การปรับแต่งนี้เป็นการแลกเปลี่ยนระหว่างเวลาประมวลผลและจำนวนโหนดของชั้นที่ซ่อนอยู่ซ่อน (Trade-off) ตามรูปที่ 58 อัลกอริทึมสุดท้ายคือ “SVM” (Support Vector Machine) นั้นมีค่าความ แม่นยำที่ลดลงเมื่อค่า “c” เพิ่มขึ้นหลังจากจุดตั้งค่าที่เหมาะสมที่สุด ดังแสดงในรูปที่ 59




รูปที่ 56 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “kNN”



รูปที่ 57 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “RF”



รูปที่ 58 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “ANN”



รูปที่ 59 ผลลัพธ์การปรับค่าไฮเปอร์พารามิเตอร์อัลกอริทึม “SVM”

ตัวชี้วัดการประเมินประสิทธิภาพของอัลกอริทึมในงานวิจัยนี้คือ ค่าความแม่นยำ (Accuracy) เนื่องจากเป็นแบบจำลองการจำแนก (Classification) แต่ทั้งนี้ยังมีการใช้ ค่าความเที่ยงตรง (Precision), ค่ารีคอล (Recall) และ ค่าคะแนนเอฟวันสคอร์ (F1 Score) มาใช้ด้วย เพราะถ้าใช้แค่ ค่าความแม่นยำเพียงอย่างเดียว อาจทำให้ผลการประเมินนั้นคลาดเคลื่อนได้ เนื่องจากสัดส่วนของ ข้อมูลในแต่ละคลาส (Class) นั้นไม่เท่ากัน (Imbalance Class) และมีจำนวนคลาสมากกว่าสองคลาส (Stage A, B และ C) การนำข้อมูลผลการจำแนกมาสรุปในตารางเมทริกซ์ความสับสน (Confusion Matrix) [10] ซึ่งเป็นการรวบรวมจำนวนการจำแนกที่ถูกต้องและไม่ถูกต้องเปรียบเทียบกับสิ่งที่เกิดขึ้นจริง ตารางที่ 16 และรูปที่ 60 ซึ่งเป็นตัวอย่างของตารางความสับสนแบบสองคลาส

		Actual	
		+	-
Predicted	+	TP	FP
	-	FN	TN

รูปที่ 60 “Binary class confusion matrix”

ตารางที่ 16 นิยามของแต่ละ “term” ของ “Confusion Matrix”

Indicator	Predicted	Actual
True Positive (TP)	+	+
True Negative (TN)	-	-
False Positive (FP)	+	-
False Negative (FN)	-	+

ในงานวิจัยนี้สถานะที่สนใจคือ “Stage B” ซึ่งเป็นสถานะที่ไม่เห็นเด่นชัด ต้องใช้การวิเคราะห์ข้อมูลเพื่อระบุสถานะนี้ แบบจำลองนี้จะมีประโยชน์ในการตรวจหาการเสียชีวิตของปัมที่อาจเกิดขึ้นในอนาคต ทดแทนหรือช่วยผู้เชี่ยวชาญในการวิเคราะห์ ดังนั้นการประเมินประสิทธิภาพจึงมุ่งเน้นไปที่ประสิทธิภาพในการระบุสถานะ “Stage B” เป็นหลัก โดยจะเก็บข้อมูลในตารางความสัมพันธ์ดังรูปที่ 61

		Actual		
		A (-)	B (+)	C (-)
Prediction	A (-)	TN_B	FN_B	TN_B
	B (+)	FP_B	TP_B	FP_B
	C (-)	TN_B	FN_B	TN_B

รูปที่ 61 “Multi-class confusion matrix”

บทที่ 4

ผลการดำเนินงานวิจัย

4.1 ผลแบบจำลองพยากรณ์พารามิเตอร์ค่าสภาพของลูกปืน (Forecasting)

ได้นำแบบจำลองการพยากรณ์ที่ได้จากบทที่ 3 มาเปรียบเทียบกับค่าความคลาดเคลื่อนรูปแบบต่างๆ กับชุดข้อมูลทดสอบ (Test Dataset) ดังตารางที่ 17 พบว่าค่าความคลาดเคลื่อนของแบบจำลอง ARIMA (0,1,1) มีค่าความคลาดเคลื่อนต่ำที่สุดในทุกมิติ เนื่องจากลักษณะของข้อมูลที่ลักษณะมีการเพิ่มขึ้นตามแกนเวลาช้าๆในช่วงแรกและค่อยๆเพิ่มเร็วขึ้นในช่วงหลัง ซึ่งแบบจำลอง ARIMA (0,1,1) นั้นเหมาะกับข้อมูลที่มีลักษณะเป็น Trend อยู่เดิม แต่ Naïve (Adjust to rate of change) นั้นก็เหมาะกับข้อมูลที่มีลักษณะนี้เช่นเดียวกัน แต่ที่ค่าความคลาดเคลื่อนที่สูงกว่าเพราะแบบจำลอง Naïve (Adjust to rate of change) นั้นใช้จำนวนของข้อมูลน้อยกว่าในการทำนายโดยผลการพยากรณ์จะอิงกับการเปลี่ยนแปลงที่ช่วงเวลาใกล้ปัจจุบันมากที่สุดทำให้ไม่สามารถพบแนวโน้มใหญ่ของชุดข้อมูล ในส่วนของแบบจำลองจากสมการการถดถอยเชิงเส้นนั้นพบว่ามีความคลาดเคลื่อนสูงสุด อาจเนื่องมาจากตัวแปรพยากรณ์ที่สามารถเก็บข้อมูลได้จากข้อมูลในงานวิจัยนั้นๆ ยังไม่สามารถนำมาทำนายได้ ต้องมีการค้นหาตัวแปรพยากรณ์เพิ่ม อาจจะเป็นการติดตั้งเซนเซอร์เพิ่มเติม หรือนำเทคโนโลยีใหม่ๆมาเพื่อสร้างตัวแปรพยากรณ์ใหม่ เพื่อให้แบบจำลองสมการถดถอยเชิงเส้นสามารถพยากรณ์ได้แม่นยำมากขึ้น


ตารางที่ 17 ผลเปรียบเทียบค่าความคลาดเคลื่อนของแต่ละแบบจำลอง

Indicator	Naïve (Adjust to take trend)	Naïve (Adjust to rate of change)	Regression	ARIMA (0,1,1)
MAD	3.154	2.340	3.924	0.320
MAPE	5%	3%	7%	0.45%
MSE	13.836	0.315	16.201	0.696
RMSE	3.720	0.561	4.025	0.834

จากผลค่าความคาดเคลื่อนของแต่ละแบบจำลองการพยากรณ์นั้น แบบจำลอง ARIMA (0,1,1) ถูกพิจารณานำไปใช้ในการปรับปรุงงานของโรงงานกรณีศึกษาโดยใช้ในการทำนายในช่วงของการตั้งงบประมาณปีถัดไปโดยใช้ผลการพยากรณ์ประกอบว่าปั๊มแบบมอเตอร์พัดพ่นทรายการใดมีแนวโน้มที่จะต้องซ่อมบำรุง หรือกรณีที่พบสถานะผิดปกติของปั๊มในปัจจุบันก็ใช้ในการตอบคำถามว่ามีแนวโน้มการเสียเป็นอย่างไรในอนาคต ควรจะบำรุงรักษาในช่วงเวลาใด เนื่องจากโรงงานในกรณีศึกษานั้นมีรอบการหยุดซ่อมบำรุงเครื่องจักรประจำปี ถ้ากลุ่มปั๊มในงานวิจัยนี้ซึ่งเป็นกลุ่มที่มีความสำคัญสูงกับโรงงานกรณีศึกษาเกิดการเสียนอกช่วงการหยุดซ่อมบำรุงรักษาประจำปีจะส่งผลให้โรงงานต้องหยุดซ่อมบำรุงนอกแผนส่งผลให้เกิดความสูญเสียโอกาสในการผลิต

4.2 สรุปผลแบบจำลองแสดงสถานะปัจจุบันของปั๊ม (Classification)

ในส่วนนี้กล่าวถึงการประเมินประสิทธิภาพของแต่ละอัลกอริทึมที่เลือกพร้อมพารามิเตอร์ที่เหมาะสมที่สุดที่ถูกนำมาเลือกใช้ เพื่อทำนายชุดข้อมูลทดสอบ (Test Dataset) จากผลการทดสอบพบว่าทุกแบบจำลองนั้นไม่มีลักษณะของโอเวอร์ฟิตติ้ง (Overfitting) และอันเดอร์ฟิตติ้ง (Underfitting) เนื่องจากความแม่นยำของแบบจำลองที่ถูกผ่านการสร้างด้วยชุดข้อมูลทดสอบ (Test Dataset) และปรับค่าพารามิเตอร์ที่ดีที่สุดด้วยวิธีการครอสวาเลชัน (Cross Validation แบบ k fold) กับแบบจำลองที่ทดสอบกับชุดข้อมูลทดสอบนั้นได้ผลที่ใกล้เคียงกัน ค่าความแม่นยำไม่เปลี่ยนแปลงไปมากเมื่อพบข้อมูลที่ไม่เคยเจอมาก่อน ดังรูปที่ 62 นอกจากนี้ผลการทำนายแสดงในเมตริกซ์ความสับสน ดังรูปที่ 63 ประสิทธิภาพของแต่ละแบบจำลองนั้นแสดงการเปรียบเทียบในตารางที่ 18



รูปที่ 62 เปรียบเทียบความแม่นยำระหว่างชุดข้อมูลที่ใช้สอนและทดสอบ

		kNN			RF		
		Actual			Actual		
		A (-)	B (+)	C (-)	A (-)	B (+)	C (-)
Prediction	A (-)	254	6	0	252	1	0
	B (+)	5	45	1	7	49	0
	C (-)	0	0	62	0	1	63

		ANN			SVM		
		Actual			Actual		
		A (-)	B (+)	C (-)	A (-)	B (+)	C (-)
Prediction	A (-)	250	16	5	255	15	4
	B (+)	8	27	1	4	33	3
	C (-)	1	8	57	0	3	56

รูปที่ 63 “Multi-class Confusion matrix” ของงานวิจัยนี้

ตารางที่ 18 เปรียบผลลัพธ์ระหว่างอัลกอริทึม

Algorithm	Accuracy	Precision	Recall	F1 Score
kNN	0.96	0.88	0.88	0.88
RF	0.97	0.87	0.96	0.91
ANN	0.89	0.75	0.52	0.62
SVM	0.92	0.82	0.64	0.72

ตามที่แสดงในตารางที่ 18 อัลกอริทึมที่เหมาะสมมีประสิทธิภาพสูง คือ “kNN” และ “RF” ซึ่งมีค่าความแม่นยำ (Accuracy) ของแบบจำลองมีค่าใกล้เคียงกัน อย่างไรก็ตาม ในแง่ของค่ารีคอล (Recall) แบบจำลอง “RF” มีประสิทธิภาพที่สูงกว่า “kNN” ถ้าพิจารณาเฉพาะค่าความแม่นยำเท่านั้นอัลกอริทึม “kNN” อาจเป็นตัวเลือกที่ดีเนื่องจากเวลาในการประมวลผลที่ต่ำกว่าและประสิทธิภาพทัดเทียมกัน แต่เนื่องจากจุดประสงค์ของงานวิจัยนี้คือการจำแนกปมที่มีสัญญาณการเสียซ้อนเร้น ดังนั้น ค่ารีคอลจึงตัวชี้วัดหนึ่งที่สำคัญ ซึ่งสาเหตุที่แบบอัลกอริทึม “RF” มีประสิทธิภาพสูงว่านั้นอาจเนื่องจากเป็นอัลกอริทึมที่สามารถปรับสมดุลชุดข้อมูลได้โดยอัตโนมัติเมื่อคลาสไม่สมดุล สำหรับแบบจำลองที่ใช้อัลกอริทึม “ANN” และ “SVM” นั้นมีค่าความแม่นยำต่ำกว่า “kNN” และ “RF” เล็กน้อย อย่างไรก็ตามค่าความเที่ยงตรง (Precision) และค่ารีคอล (Recall) ค่อนข้างต่ำกว่าอีกสองอัลกอริทึมค่อนข้างมาก โดยโดยอัลกอริทึม “ANN” นั้นที่มีชื่อเสียงเป็นที่รู้จักในฐานะเป็นอัลกอริทึมที่มีประสิทธิภาพสูง แต่ในงานวิจัยนี้การการปรับค่าไฮเปอร์พารามิเตอร์นั้นถูกจำกัดไว้ที่สิบค่าสำหรับการค้นหาแบบกริด (Grid search) โดยถ้าจะปรับปรุงประสิทธิภาพของ “ANN” อาจจะต้องเพิ่มจำนวนโหนดที่ชั้นซ่อน (Hidden Layer) หรือเพิ่มจำนวนชั้นซ่อนซึ่งจะกลายเป็นอัลกอริทึมการศึกษาเชิงลึก (Deep learning) และเปลี่ยนวิธีการสุ่มตัวอย่างจาก CV เป็นวิธีการอื่นเช่น การตรวจสอบข้ามซ้ำหรือกลุ่มอนุภาคสำหรับโครงข่ายประสาทเทียม (Particle swarm optimization, PSO-NN) [31]

4.3 การนำแบบจำลองไปใช้งานผ่านกระดานแสดงผล (Dashboard)

หลังจากได้แบบจำลองหลักในการสร้างระบบผู้เชี่ยวชาญแล้ว ได้นำแบบจำลองไปใช้งานของโรงงานกรณีศึกษาในรูปแบบกระดานแสดงผล (Dashboard) เพื่อให้สามารถเข้าถึงได้ง่าย ไม่จำเป็นต้องใช้ความเชี่ยวชาญในการแปลงผล สามารถนำผลลัพธ์ไปใช้งานต่อไปได้เลย กระดานแสดงผลจะสรุปผลการทำนายสถานะปัจจุบันให้อยู่ในหน้าจอเดียว เพื่อให้ผู้ที่ต้องการทราบข้อมูลสามารถดูข้อมูลแล้วเข้าใจได้ทันที

บทที่ 5

สรุปผลการดำเนินงานวิจัยและมุมมองสำหรับการพัฒนาต่อไป

งานวิจัยนี้มีส่วนช่วยในการพัฒนาระบบผู้เชี่ยวชาญในการทำนายสถานะปั๊มแบบมอเตอร์ปิดผนึก (Canned Motor Pump, CMP) ด้วยชุดข้อมูลกรณีศึกษาและประยุกต์ใช้องค์ความรู้ต่างๆ ในการพยากรณ์พารามิเตอร์ที่สำคัญและจำแนกสถานะของปั๊มแบบปิดผนึก ซึ่งต้องอาศัยความรู้ของผู้เชี่ยวชาญ ร่วมด้วยชุดข้อมูลของโรงงานกรณีศึกษา มาสร้างระบบที่อ้างอิงจากองค์ความรู้ต่างๆ จากการศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องตั้งที่ระบุในเนื้อหาบทที่สองและสาม ซึ่งมีความเกี่ยวข้องกับงานวิจัยนี้ทั้งทางตรงและทางอ้อม มาต่อยอดทำให้เกิดงานวิจัยนี้ โดยเฉพาะงานวิจัยที่เกี่ยวข้องกับการเรียนรู้ของเครื่อง อาทิ เช่น งานวิจัยการทำนายการล่าช้าของสายการบินโดยใช้การเรียนรู้ของเครื่องเชิงลึก [32] ซึ่งทำให้เข้าใจอัลกอริทึมโครงข่ายประสาทเทียม (ANN) มากขึ้น ซึ่งต่อยอดองค์ความรู้ของงานวิจัยที่เกี่ยวข้องมาประยุกต์ใช้ในงานวิจัย ซึ่งในการเรียนรู้ต้องใช้การเรียนรู้ด้วยตนเองค่อนข้างมาก เนื่องจากเป็นองค์ความรู้ที่ค่อนข้างใหม่สำหรับผู้วิจัย

กล่าวโดยสรุปโครงสร้างของงานวิจัย ในส่วนแรกของงานวิจัยจะแนะนำองค์ความรู้ของอุปกรณ์ในการออกแบบและซ่อมบำรุงซึ่งก็คือ ปั๊มแบบมอเตอร์ปิดผนึก (Canned Motor Pump, CMP) ซึ่งมีลักษณะพิเศษสำคัญทั้งในแง่หลักการทำงานและพารามิเตอร์ที่มีความเฉพาะตัวค่าสภาพลูกปืนทรงกระบอกซึ่งได้จากเซนเซอร์ที่ติดตั้งจากผู้ผลิตปั๊ม จากนั้นได้กำหนดแนวคิดการสร้างระบบผู้เชี่ยวชาญ ซึ่งประยุกต์หลักการทางสถิติและใช้การเรียนรู้ของเครื่อง (Machine Learning, ML) ซึ่งได้อธิบายขั้นตอนวิธีรวมถึงขั้นตอนการเตรียมชุดข้อมูล การทดลองแบบจำลองต่างๆ เพื่อหาวิธีที่เหมาะสมมาใช้งาน ไม่ว่าจะเป็นการหาค่าความคลาดเคลื่อน การปรับแต่งไฮเปอร์พารามิเตอร์ และการเปรียบเทียบแบบจำลอง ซึ่งได้ข้อสรุปว่าแบบจำลองการพยากรณ์ค่าเฉลี่ยเคลื่อนที่แบบบูรณาการอัตโนมัติ (Autoregressive integrated moving average) ARIMA (0,1,1) และอัลกอทึมมแรนดอมฟอเรส (Random Forest) หรือ “RF” ได้รับการเสนอให้เป็นแบบจำลองหลักในระบบผู้เชี่ยวชาญนี้

เพื่อรักษาคุณภาพของผลลัพธ์ที่ใกล้เคียงกันหลังนำแบบจำลองไปใช้งาน ควรพิจารณา กำหนดการรอบการทบทวนการสร้างแบบจำลองด้วยชุดข้อมูลใหม่ๆ ในอนาคต เพื่อให้ข้อมูลใหม่ที่แบบจำลองยังไม่เคยพบถูกนำเข้าสู่ระบบ ข้อมูลใหม่บางอย่างอาจแตกต่างจากเดิมชุดข้อมูลที่ได้รับเคยใช้ในงานวิจัยทำให้แบบจำลองมีคุณภาพมากขึ้นในระยะยาว

การนำแนวคิดแบบจำลองไปใช้กับอุปกรณ์อื่นๆ ในโรงงานกรณีศึกษา ถือว่าเป็นประโยชน์อีกด้านหนึ่งของงานวิจัยนี้ ซึ่งความแตกต่างของอุปกรณ์ที่มีระบบการตรวจสอบที่แตกต่างกัน อุปกรณ์

ประเภทที่ซับซ้อน เช่น กังหันก๊าซ หรือ คอมเพรสเซอร์ จะมีเซ็นเซอร์ออนไลน์มากกว่าปั๊ม ซึ่งค่าจากเซ็นเซอร์บางตัวสามารถใช้เป็นตัวทำนายที่เหมาะสมกับแบบจำลองได้ ซึ่งในกรณีแบบนี้แบบจำลองการถดถอยเชิงเส้นสามารถอาจได้ผลลัพธ์ที่ดียิ่งขึ้น ในบางประเภทอุปกรณ์ที่มีระยะเวลาเฉลี่ยที่การเสียหายของอุปกรณ์ (Mean Time Between Failure, MTBF) ค่อนข้างนานทำให้มีข้อมูลการเสียหายค่อนข้างน้อยส่งผลให้เกิดปัญหาการกระจายความไม่สมดุลของชุดข้อมูลอาจจะส่งผลต่อประสิทธิภาพของแบบจำลองในอนาคต การประยุกต์ใช้เทคนิคการสุ่มตัวอย่างมากเกินไปของชนกลุ่มน้อยสังเคราะห์ (Synthetic minority oversampling technique, SMOTE) [32] สามารถช่วยปรับสัดส่วนระหว่างคลาสให้มีความสมดุลขึ้นได้

การประยุกต์ใช้ข้อมูลที่ได้จากการวัดค่าแบบออฟไลน์ก็เป็นตัวเลือกหนึ่งในการเพิ่มตัวแปรทำนาย (Predictor) หรือ ฟีเจอร์ (Feature) ในการสร้างแบบจำลอง แต่ต้องมั่นใจได้ว่าการเก็บข้อมูลที่ดีและสม่ำเสมอ หรือถ้าพิจารณาแล้วข้อมูลนั้นๆ เป็นข้อมูลที่สำคัญอาจจะพิจารณาเปลี่ยนระบบออฟไลน์เป็นออนไลน์ก็เป็นอีกทางเลือกหนึ่งที่ทำให้ข้อมูลมีคุณภาพมากขึ้น

ปัจจัยความสำเร็จที่สำคัญ (Key Success Factor) ประการหนึ่งของงานวิจัยนี้คือปริมาณและคุณภาพของชุดข้อมูล ค่าพยากรณ์จะมีความแม่นยำมากขึ้นเมื่อมีข้อมูลในชุดข้อมูลมากขึ้น ถ้าข้อมูลไม่เพียงพอจะไม่สามารถรองรับการแก้ปัญหาที่ซับซ้อนได้ คุณภาพของแบบจำลองนั้นสัมพันธ์กับคุณภาพของข้อมูล ด้วยข้อมูลคุณภาพต่ำจะเป็นความท้าทายที่จะสร้างแบบจำลองที่สามารถใช้งานได้ โดยทุกวันนี้ ไม่เพียงแต่ปัญหาที่ซับซ้อนเท่านั้นที่สามารถใช้ “ML” เพื่อแก้ปัญหา แต่ปัญหาต่างๆ กับชุดข้อมูลขนาดใหญ่ก็ประยุกต์ใช้ได้เช่นกัน ข้อดีคือลดภาระงานของมนุษย์ในการทำงานประจำ หลายๆ บริษัทมักจะเพิ่มประสิทธิภาพด้วยการหาวิธีลดปริมาณงานของมนุษย์ให้ผลิตผลได้ระดับเดียวกัน ซึ่งการประยุกต์อัลกอริทึมของการเรียนรู้ของเครื่อง หรือการคำนวณเชิงสถิติในองค์กรนั้น เป็นการยาก เพราะมีการตั้งค่าพารามิเตอร์หลายตัว การคำนวณที่ซับซ้อนอาจไม่ใช่เรื่องง่ายสำหรับบุคคลทั่วไป อย่างไรก็ตาม ภาษาโปรแกรมที่ทันสมัยนั้นมีโปรแกรม (Integrated Development Environment , IDE) จำนวนมากรองรับ ซึ่งมีไลบรารีสำเร็จรูปในการสร้างแบบจำลองได้อย่างรวดเร็ว ทำให้การเข้าถึงสิ่งที่ยากๆ ได้มากขึ้น

บรรณานุกรม

- [1] SAE JA1012, (2002). Guide to the RCM Standard. Society of Automotive Engineers–SAE.
- [2] Lau, D. (2005). Compliance to ATEX and API685 for sealless pumps. *World Pumps*, 2005(467), 24-26.
- [3] Orchard, B., Conroy, T. J., Lau, D., Kubota, Y., & Noble, P. (2011). The challenge of leak-free pumping. *World Pumps*, 2011(4), 28-31.
- [4] Karassik, I. J., Messina, J. P., Cooper, P., & Heald, C. C. (2008). *Pump handbook*. McGraw-Hill Education.
- [5] Pasma, H. J. (2015). *Risk analysis and control for industrial processes-gas, oil and chemicals: a system perspective for assessing and avoiding low-probability, high-consequence events*. Butterworth-Heinemann.
- [6] กอบเกียรติ สระอุบล. (2020). เรียนรู้ Data Science และ AI : Machine Learning ด้วย Python. กรุงเทพฯ: สำนักพิมพ์ มีเดีย เนทเวิร์ค
- [7] Mitchell, T. M., & Mitchell, T. M. (1997). *Machine learning* (Vol. 1, No. 9). New York: McGraw-hill.
- [8] Luque, A., Carrasco, A., Martin, A., & de Las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216-231.
- [9] Ruuska, S., Hämäläinen, W., Kajava, S., Mughal, M., Matilainen, P., & Mononen, J. (2018). Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural processes*, 148, 56-62.
- [10] Altaf, I., Butt, M. A., & Zaman, M. (2021, September). A pragmatic comparison of supervised machine learning classifiers for disease diagnosis. In *2021 Third International Conference on Inventive Research in Computing Applications (ICIRCA)* (pp. 1515-1520). IEEE.
- [11] Maliamanis, T. V., & Papakostas, G. A. (2021). Machine learning vulnerability in medical imaging. In *Machine Learning, Big Data, and IoT for Medical*

Informatics (pp. 53-70). Academic Press.

- [12] Hanke, J. E., & Wichern, D. (2013). Business Forecasting: Pearson New International Edition PDF eBook. Pearson Higher Ed.
- [13] Dalzochio, J., Kunst, R., Pignaton, E., Binotto, A., Sanyal, S., Favilla, J., & Barbosa, J. (2020). Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. *Computers in Industry*, 123, 103298.
- [14] Dalzochio, J., Kunst, R., Pignaton, E., Binotto, A., Sanyal, S., Favilla, J., & Barbosa, J. (2020). Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. *Computers in Industry*, 123, 103298.
- [15] Deulgaonkar, V. R., Pawar, K., Kudle, P., Raverkar, A., & Raut, A. (2019). Failure analysis of fuel pumps used for diesel engines in transport utility vehicles. *Engineering Failure Analysis*, 105, 1262-1272.
- [16] Dangut, M. D., Skaf, Z., & Jennions, I. K. (2021). An integrated machine learning model for aircraft components rare failure prognostics with log-based dataset. *ISA transactions*, 113, 127-139.
- [17] Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., & Nandi, A. K. (2020). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587.
- [18] Wiseman, M. (2014). The real meaning of the six RCM curves. *Asset Management & Maintenance Journal*, 27(5), 18-23.
- [19] Barberá, L., Guerrero, A., Crespo, A., González-Prida, V., Guillén, A., Gómez, J., & Sola, A. (2013). State of the art of maintenance applied to wind turbines. *Chemical Engineering*, 33.
- [20] Abid, M., Ayub, S., Wali, H., & Tariq, M. N. (2014). Reliability Centered Maintenance Plan for the Utility Section of a Fertilizer Industry: A Case Study. *International Journal of Science and Advanced Technology*, 4(3), 9-16.
- [21] Ogidan, E. T., Dimililer, K., & Ever, Y. K. (2018, October). Machine learning for expert systems in data analysis. In 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 1-5). IEEE.
- [22] R Core Team (2020). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R->

project.org/.

- [23] RStudio Team (2019). RStudio: Integrated Development for R. RStudio, Inc., Boston, MA. URL <http://www.rstudio.com/>.
- [24] NIKKISO Non-Seal® Pump - LEWA, Inc. URL <http://www.lewa-inc.com>.
- [25] Ho, T. K. (1995, August). Random decision forests. In Proceedings of 3rd international conference on document analysis and recognition (Vol. 1, pp. 278-282). IEEE.
- [26] Varian, H. (2005). Bootstrap tutorial. *Mathematica Journal*, 9(4), 768-775..
- [27] Otchere, D. A., Ganat, T. O. A., Gholami, R., & Ridha, S. (2021). Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ANN and SVM models. *Journal of Petroleum Science and Engineering*, 200, 108182.
- [28] Kimera, D., & Nangolo, F. N. (2020). Predictive maintenance for ballast pumps on ship repair yards via machine learning. *Transportation Engineering*, 2, 100020.
- [29] Herrero-Lopez, S. (2011). Multiclass support vector machine. In *GPU Computing Gems Emerald Edition* (pp. 293-311). Morgan Kaufmann.
- [30] Berrar, D. (2019). Cross-Validation. *Encyclopedia of Bioinformatics and Computational Biology*, Volume 1, pp.542-545
- [31] Rauf, H. T., Bangyal, W. H., Ahmad, J., & Bangyal, S. A. (2018, November). Training of artificial neural network using pso with novel initialization technique. In 2018 international conference on innovation and intelligence for informatics, computing, and technologies (3ICT) (pp. 1-8). IEEE.
- [32] Cheevachaipimol, W., Teinwan, B., & Chutima, P. (2021). Flight Delay Prediction Using a Hybrid Deep Learning Method. *Engineering Journal*, 25(8), 99-112.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	นายคมกริช เกื่อนสุวรรณ
วัน เดือน ปี เกิด	09 พฤษภาคม 2530
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมเครื่องกล สถาบันเทคโนโลยีพระ จอมเกล้าเจ้าคุณทหารลาดกระบัง
ที่อยู่ปัจจุบัน	561/466 ถ.ประชาพัฒนา แขวงทับยาว เขตลาดกระบัง กรุงเทพมหานคร 10520



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY