

Chulalongkorn University

## Chula Digital Collections

---

Chulalongkorn University Theses and Dissertations (Chula ETD)

---

2021

### การพยากรณ์ดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแบบเรียลไทม์ในโรงงานอิโตรเคมี โดยใช้การเรียนรู้ของเครื่อง

วริศรา ขระเขื่อน  
คณะวิศวกรรมศาสตร์

Follow this and additional works at: <https://digital.car.chula.ac.th/chulaetd>



Part of the [Industrial Engineering Commons](#), and the [Operational Research Commons](#)

---

#### Recommended Citation

ขระเขื่อน, วริศรา, "การพยากรณ์ดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแบบเรียลไทม์ในโรงงานอิโตรเคมี โดยใช้การเรียนรู้ของเครื่อง" (2021). *Chulalongkorn University Theses and Dissertations (Chula ETD)*. 5549.  
<https://digital.car.chula.ac.th/chulaetd/5549>

This Thesis is brought to you for free and open access by Chula Digital Collections. It has been accepted for inclusion in Chulalongkorn University Theses and Dissertations (Chula ETD) by an authorized administrator of Chula Digital Collections. For more information, please contact [ChulaDC@car.chula.ac.th](mailto:ChulaDC@car.chula.ac.th).

การพยากรณ์ดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแบบเรียลไทม์ในโรงงานปิโตรเคมี โดยใช้การเรียนรู้  
ของเครื่อง



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมอุตสาหการ ภาควิชาวิศวกรรมอุตสาหการ  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2564  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Real-time Induction Motor Health Index Prediction in A Petrochemical Plant using  
Machine Learning

Miss Waritsara Khrakhuean



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	การพยากรณ์ดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแบบ
	เรียลไทม์ในโรงงานปิโตรเคมี โดยใช้การเรียนรู้ของเครื่อง
โดย	น.ส.วิศรา ชระเชื่อน
สาขาวิชา	วิศวกรรมอุตสาหการ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ศาสตราจารย์ ดร.ปารเมศ ชูติมา

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง  
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

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

วริศรา ขระเชื่อน : การพยากรณ์ดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแบบเรียลไทม์ใน  
โรงงานปิโตรเคมี โดยใช้การเรียนรู้ของเครื่อง. ( Real-time Induction Motor Health  
Index Prediction in A Petrochemical Plant using Machine Learning) อ.ที่  
ปรึกษาหลัก : ศ. ดร.ปารเมศ ชูติมา

เอกสารฉบับนี้นำเสนอการทำนายดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแบบเรียลไทม์ ที่ใช้  
ในโรงงานปิโตรเคมีกรณีศึกษาผ่านการใช้เซ็นเซอร์อัจฉริยะและแบบจำลองการเรียนรู้ของเครื่อง ที่  
ในปัจจุบันวิศวกรซ่อมบำรุง ใช้เทคนิคการบำรุงรักษาตามเวลาและตามเงื่อนไขในการตรวจสอบ  
และวินิจฉัยสภาพของมอเตอร์เหนี่ยวนำเป็นระยะๆ ซึ่งส่งผลต่อมอเตอร์ยังคงขัดข้องเสียหาย โดย  
การพังเสียหายดังกล่าวบางครั้งทำให้กระบวนการผลิตทั้งหมดต้องหยุดเพื่อทำการบำรุงรักษาแบบ  
ฉุกเฉิน ส่งผลให้บริษัทสูญเสียรายได้มหาศาล ดังนั้น ผู้บริหารระดับสูงจึงตัดสินใจเปลี่ยนวิธีในการ  
ปฏิบัติงานเดิมเป็นการบำรุงรักษาเชิงคาดการณ์แบบเรียลไทม์แทน โดยเซ็นเซอร์อัจฉริยะถูกติดตั้ง  
บนมอเตอร์เหนี่ยวนำนี้ใช้เพื่อรวบรวมข้อมูลที่จำเป็นเกี่ยวกับสถานะการทำงานของมอเตอร์และ  
เพื่อระบุความผิดปกติของมอเตอร์ก่อนที่จะเกิดความล้มเหลวขึ้น โดยแบบจำลองการเรียนรู้ของ  
เครื่องทั้งสี่แบบที่ได้สร้างขึ้นมาของงานวิจัย ได้รับการตรวจสอบและเปรียบเทียบประสิทธิภาพ  
ผลลัพธ์เพื่อประเมินว่าแบบจำลองใดดีที่สุด ประกอบด้วย แบบจำลองโครงข่ายประสาทเทียม ,  
แบบจำลองการเพิ่มประสิทธิภาพอนุภาคฝูง, แบบจำลองต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสี  
และแบบจำลองป่าไม้สุ่ม ซึ่งเมตริกประสิทธิภาพมาตรฐานที่ใช้เพื่อเปรียบเทียบประสิทธิภาพ  
สัมพัทธ์ระหว่างแต่ละแบบจำลองการเรียนรู้ของเครื่องต่างๆ ประกอบด้วย ค่าความถูกต้องแม่นยำ  
, ค่าความแม่นยำ , การเรียกคืน , คะแนน F1 และ เส้นโค้ง AUC-ROC ผลการวิจัยพบว่า  
แบบจำลองการเพิ่มประสิทธิภาพอนุภาคฝูง ไม่เพียงแต่ได้ค่าความเที่ยงตรงแบบถ่วงน้ำหนักเฉลี่ย  
สูงสุดเท่านั้น แต่ยังสามารถแยกแยะสถานะดัชนีสุขภาพของมอเตอร์ของมอเตอร์เหนี่ยวนำได้  
ถูกต้องกว่ารุ่นอื่นๆ

สาขาวิชา วิศวกรรมอุตสาหการ

ปีการศึกษา 2564

ลายมือชื่อนิสิต .....

ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6370258621 : MAJOR INDUSTRIAL ENGINEERING

KEYWORD:

Waritsara Khrakhuean : Real-time Induction Motor Health Index Prediction in A Petrochemical Plant using Machine Learning. Advisor: Prof. PARAMES CHUTIMA, Ph.D.

This paper presents real-time health index levels prediction of induction motors (IMs) utilised in a petrochemical plant through intelligent sensors and machine learning (ML) models. At present, maintenance engineers implement time-based and condition-based maintenance techniques in periodically examining and diagnosing IMs' health, which results in sporadic breakdowns to IMs. Such breakdowns sometimes force the entire production process to stop for emergency maintenance resulting in a massive loss in the company's revenue. Hence, top management decides to switch the operational practice to real-time predictive maintenance instead. Intelligent sensors are installed on IMs to collect necessary information about their working statuses and to flag abnormalities of IMs before potential failures are reached. Four ML models are investigated to evaluate and compare the efficiency of which one is the best, i.e., Artificial Neural Network (ANN), Particle Swarm Optimization (PSO), Gradient Boosting Decision Trees (GBT), and Random Forest (RF). Standard performance metrics are used to compare the relative effectiveness among different ML models, including Accuracy, Precision, Recall, F1-score, and AUC-ROC curves. The results reveal that PSO not only obtains the highest average weighted Accuracy but also can differentiate the statuses of health index levels of the IM more correctly than other counterpart models.

Field of Study: Industrial Engineering

Student's Signature .....

Academic Year: 2021

Advisor's Signature .....

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องจากการอนุเคราะห์และสนับสนุนจากอาจารย์ที่ปรึกษาวิทยานิพนธ์ศาสตราจารย์ ดร. ปารเมศ ชูติมา ที่ให้ความรู้และคำแนะนำเกี่ยวกับการสร้างแบบจำลองรวมถึงทฤษฎีและองค์ความรู้ต่างๆที่เกี่ยวข้อง พร้อมทั้งช่วยปรับปรุงแก้ไขจนเป็นผลให้วิทยานิพนธ์ฉบับนี้เสร็จสมบูรณ์

ขอกราบขอบพระคุณรองศาสตราจารย์ จิรพัฒน์ เงามะเสริญวงศ์ ประธานกรรมการสอบวิทยานิพนธ์ รองศาสตราจารย์ ดร. ดาริชา สุธีวงศ์ กรรมการสอบ และรองศาสตราจารย์ ดร. ชูเวช ชาญสง่าเวช กรรมการสอบภายนอกมหาวิทยาลัย ที่สละเวลามาเป็นกรรมการสอบวิทยานิพนธ์ และกรุณาให้คำแนะนำ แนวทางแก้ไขสำหรับข้อบกพร่อง เพื่อให้วิทยานิพนธ์ฉบับนี้มีความเรียบร้อยสมบูรณ์

ขอกราบขอบพระคุณคณาจารย์ทุกท่านนอกเหนือจากที่กล่าวนามมานี้ ที่คอยประสิทธิ์ประสาทองค์ความรู้ทั้งหมดที่เกี่ยวข้องกับงานวิจัย รวมถึงเจ้าหน้าที่ประจำภาควิชาวิศวกรรมอุตสาหการทุกท่านที่ให้ความช่วยเหลือต่างๆตลอดการทำวิทยานิพนธ์

สุดท้ายนี้ขอกราบขอบพระคุณบิดา มารดา และครอบครัวพระเชื่อน ที่ให้การสนับสนุนและให้กำลังใจตลอดการทำวิทยานิพนธ์ รวมถึงเพื่อนๆและรุ่นพี่ที่ทำงานสำหรับการเข้าถึงข้อมูลมอเตอร์เหนี่ยวนำ องค์ความรู้ด้านการสร้างแบบจำลองตลอดจนการจัดทำรูปเล่มวิทยานิพนธ์ ทำให้วิทยานิพนธ์ประสบความสำเร็จลุล่วงไปได้ด้วยดี

## สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญรูปภาพ.....	ฎ
บทที่ 1 บทนำ .....	1
1.1 ที่มาและความสำคัญ.....	2
1.2 การบำรุงรักษามอเตอร์ในอุตสาหกรรมกรณีศึกษา.....	3
1.3 วิเคราะห์ผลการบำรุงรักษา.....	4
1.3.1 การตรวจติดตามค่าการสั่นสะเทือน (Vibration Condition Monitoring) และการ วิเคราะห์ผล.....	4
1.3.2 ค่าที่ได้จากออนไลน์เซ็นเซอร์.....	5
1.4 ปัญหาที่พบของการบำรุงรักษา.....	6
1.4.1 ปัญหาการชำรุดเสียหาย.....	6
1.4.2 คำนวนความน่าเชื่อถือของการบำรุงรักษา.....	9
1.4.3 ปัญหาที่เกิดขึ้นจากเทคนิคที่ใช้ในการบำรุงรักษา .....	11
1.4.4 วางแผนวิธีการแก้ไขปัญหา.....	12
1.5 แนวทางในการจัดทำวิทยานิพนธ์.....	13



1.5.1 แผนภูมิพาเรโต สำหรับพิจารณาหามอเตอร์ที่เกิดการล้มเหลวอย่างมีนัยสำคัญ.....	13
1.5.2 กระบวนการทำงานของมอเตอร์ 701A และ 701R.....	15
1.6 วัตถุประสงค์.....	16
1.7 ขอบเขตของงานวิจัย .....	16
1.8 ขั้นตอนการดำเนินงานวิจัย .....	19
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง .....	20
2.1 ทฤษฎีที่เกี่ยวข้อง.....	20
2.1.1 ประเภทของการบำรุงรักษา.....	20
2.1.2 การบำรุงรักษาแบบพยากรณ์ตามสภาพสำหรับกลุ่มเครื่องจักรหมุน (Rotating Machine).....	21
2.1.3 การวิเคราะห์ความสั่นสะเทือน (Vibration Analysis).....	22
2.1.4 การตรวจวัดรังสีความร้อนด้วยกล้องถ่ายภาพความร้อน .....	25
2.1.5 ผลกระทบที่มีผลต่อมอเตอร์เมื่อแรงดันไฟฟ้าและความถี่เกิดการเปลี่ยนแปลง .....	27
2.1.6 การแยกประเภทความล้มเหลว (Failure Mode) ของมอเตอร์ไฟฟ้า.....	30
2.1.7 เมตริกที่ใช้สำหรับตรวจสอบความพร้อมทำงานของระบบ .....	31
2.1.8 ปัญญาประดิษฐ์ (Artificial Intelligence : AI) และการเรียนรู้ของเครื่อง (Machine Learning).....	32
2.1.9 โครงข่ายประสาทเทียม (Artificial Neural Networks - ANN) .....	35
2.1.10 การเพิ่มประสิทธิภาพของอนุภาคฝูง (Particle Swarm Optimization – PSO) .....	39
2.1.11 ต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสี (Gradient Boosting Decision Trees) .....	42
2.1.12 ป่าไม้สุ่ม (Random Forest) .....	43
2.1.13 ไฮเปอร์พารามิเตอร์ (Hyperparameter) .....	44
2.1.14 ออปทูนา (Optuna) .....	45

2.1.15	การประเมินผลแบบจำลอง (Evaluation Model).....	46
2.1.16	อคติสูง (Under Fitting) / ความแปรปรวนสูง (Over fitting).....	50
2.2	งานวิจัยที่เกี่ยวข้อง .....	52
บทที่ 3	วิธีดำเนินงานวิจัย .....	58
3.1	การออกแบบการทดลอง .....	58
3.1.1	การจัดการข้อมูลก่อนการสร้างแบบจำลอง.....	58
3.1.2	การจัดกลุ่มข้อมูลสำหรับการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ .....	62
3.1.3	การจัดการข้อมูลที่ไม่สมดุล .....	66
3.1.4	การวัดผลการประเมิน (Evaluation Metrics).....	66
3.1.5	การสร้างแบบจำลองโดยใช้การเรียนรู้ของเครื่อง (Machine Learning Model).....	67
3.2	ขั้นตอนการดำเนินการทดลอง .....	70
3.3	การสร้างแบบจำลองโดยใช้โครงข่ายประสาทเทียม (Artificial Neural Network - ANN) ..	71
3.4	การสร้างแบบจำลองโดยใช้การเพิ่มประสิทธิภาพของอนุภาคฝูง (Particle Swarm Optimization - PSO).....	73
3.5	การสร้างแบบจำลองโดยใช้ต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสี (Gradient Boosting Decision Trees - GBT).....	75
3.6	การสร้างแบบจำลองโดยใช้ป่าไม้สุ่ม (Random Forest - RF).....	77
บทที่ 4	ผลการทดลองและการวิเคราะห์ผล .....	80
4.1	การวิเคราะห์ประสิทธิภาพแบบจำลองจากรายงานการจัดหมวดหมู่ (Classification Report)	80
4.2	การวิเคราะห์ประสิทธิภาพแบบจำลองจากค่าความแม่นยำ (Accuracy).....	83
4.3	การวิเคราะห์ประสิทธิภาพแบบจำลองด้วยเมทริกซ์ความสับสน (Confusion Matrix) และเส้นโค้ง AUC-ROC .....	83
บทที่ 5	สรุปและอภิปรายผลการทดลอง .....	88
5.1	สรุปผลที่ได้จากการทดลอง.....	89

5.2 อภิปรายผลการทดลอง.....	90
5.3 ข้อจำกัดและข้อเสนอแนะของการทดลอง .....	90
5.4 ข้อเสนอแนะ.....	91
บรรณานุกรม.....	92
ประวัติผู้เขียน.....	96



## สารบัญตาราง

หน้า

ตารางที่ 1 ระดับความรุนแรงของการประเมินค่าความสั่นสะเทือนของอุตสาหกรรมกรณีศึกษา.....	5
ตารางที่ 2 จำนวนมอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษาแบ่งตามกลุ่ม .....	7
ตารางที่ 3 ผลสำรวจจำนวนครั้งในการล้มเหลวของมอเตอร์ ตั้งแต่ปีค.ศ. 2010 .....	8
ตารางที่ 4 จัดลำดับจำนวนครั้งของการล้มเหลวของมอเตอร์กลุ่ม B.....	14
ตารางที่ 5 ประวัติการล้มเหลวของมอเตอร์ 701A และ 701R .....	14
ตารางที่ 6 การประเมินผลของระดับสุขภาพมอเตอร์ไฟฟ้า.....	18
ตารางที่ 7 ตำแหน่งในการตรวจวัดค่าความสั่นสะเทือน .....	24
ตารางที่ 8 อ้างอิงค่าความสั่นสะเทือนจาก ISO 10816-3 กลุ่ม 2 (ISO 10816-3:2009 Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts 2009).....	25
ตารางที่ 9 มาตรฐาน ANSI/NETA MTS-2019 ที่ใช้ในการประเมินผลภาพถ่ายความร้อน (ANSI/NETA MTS-2019 Standard for Maintenance Testing Specifications for Electrical Power Equipment and Systems 2019) .....	27
ตารางที่ 10 ประเภทความล้มเหลวจากมอเตอร์ไฟฟ้า (ISO 14224:2016 Petroleum, petrochemical and natural gas industries — Collection and exchange of reliability and maintenance data for equipment, 2016) .....	30
ตารางที่ 11 ตารางความสับสน (Confusion Matrix).....	46
ตารางที่ 12 คุณลักษณะ/พารามิเตอร์ที่นำเข้ามาสำหรับการทำนายสุขภาพของมอเตอร์เหนี่ยวนำ..	60
ตารางที่ 13 มาตรฐานและข้อกำหนดที่ใช้อ้างอิงในการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำในงานวิจัย.....	62
ตารางที่ 14 การแบ่งกลุ่มดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ.....	63
ตารางที่ 15 การประเมินดัชนีสุขภาพของมอเตอร์เหนี่ยวนำจากแต่ละคุณลักษณะ .....	65
ตารางที่ 16 การวิเคราะห์ความแปรปรวน (ANOVA) .....	69

ตารางที่ 17 พารามิเตอร์สุดท้าย ที่ใช้เป็นข้อมูลนำเข้าสำหรับการสร้างแบบจำลอง .....	70
ตารางที่ 18 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับปรุงในแบบจำลอง ANN รวมถึงพิสัยที่ใช้พิจารณา....	72
ตารางที่ 19 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง ANN ในงานวิจัย ....	73
ตารางที่ 20 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับปรุงในแบบจำลอง PSO รวมถึงพิสัยที่ใช้พิจารณา ....	74
ตารางที่ 21 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง PSO ในงานวิจัย.....	75
ตารางที่ 22 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับปรุงในแบบจำลอง GBT รวมถึงพิสัยที่ใช้พิจารณา ....	76
ตารางที่ 23 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง GBT ในงานวิจัย.....	76
ตารางที่ 24 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับปรุงในแบบจำลอง GBT รวมถึงพิสัยที่ใช้พิจารณา ....	78
ตารางที่ 25 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง RF ในงานวิจัย.....	78
ตารางที่ 26 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง ANN.....	81
ตารางที่ 27 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง PSO .....	81
ตารางที่ 28 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง GBT .....	82
ตารางที่ 29 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง RF .....	82
ตารางที่ 30 เปรียบเทียบค่าเปอร์เซ็นต์ความถูกต้องของแต่ละแบบจำลอง .....	83

## สารบัญรูปภาพ

	หน้า
รูปที่ 1 กิจกรรมการบำรุงรักษามอเตอร์ไฟฟ้าของอุตสาหกรรมกรณีศึกษา .....	4
รูปที่ 2 ตัวอย่างการประเมินค่าความสั่นสะเทือนของเครื่องจักร .....	5
รูปที่ 3 ตัวอย่างข้อมูลที่ได้จากออนไลน์เซ็นเซอร์ .....	6
รูปที่ 4 สัดส่วนจำนวนมอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษา .....	7
รูปที่ 5 จำนวนครั้งในการล้มเหลวของมอเตอร์กลุ่ม A .....	8
รูปที่ 6 จำนวนครั้งในการล้มเหลวของมอเตอร์กลุ่ม B .....	8
รูปที่ 7 แผนภูมิแกงปลาสาเหตุของการล้มเหลวของมอเตอร์ .....	12
รูปที่ 8 แผนภูมิพาเรโตจำนวนการล้มเหลวของมอเตอร์กลุ่ม B .....	13
รูปที่ 9 ตำแหน่งมอเตอร์ไฟฟ้าเลขที่ 701A และ 701R ในระบบ .....	15
รูปที่ 10 การเปลี่ยนแปลงแรงดันและความถี่ที่ส่งผลกระทบต่อสมรรถนะของมอเตอร์ .....	28
รูปที่ 11 เมตริกที่ใช้ตรวจสอบความพร้อมทำงานของงานบริหารงานซ่อมบำรุง (นายช่างมาแซร์, 2020).....	31
รูปที่ 12 ประเภทของการเรียนรู้ของเครื่อง (วิชาน, 2018) .....	33
รูปที่ 13 สถาปัตยกรรมโครงข่ายประสาทเทียม .....	36
รูปที่ 14 แบบจำลองการทำงานของโครงข่ายประสาทเทียม .....	37
รูปที่ 15 ตัวอย่างวิธีการค้นหาพื้นที่ที่ดีที่สุดของอนุภาคฝูง (Clark, 2017) .....	40
รูปที่ 16 ตัวอย่างกระบวนการทำงานของอัลกอริทึมป่าไม้สุ่ม (วิชัยพงศ์, 2018) .....	44
รูปที่ 17 เส้นโค้ง AUC-ROC (Narkhede, 2018).....	49
รูปที่ 18 เปรียบเทียบค่า AUC และเส้นโค้ง ROC ที่แสดงผลออกมาตามค่า AUC (Narkhede, 2018) .....	50
รูปที่ 19 อ้างอิงจุดวัดสำหรับเก็บค่าพารามิเตอร์ของมอเตอร์ .....	59
รูปที่ 20 ข้อมูลดิบในรูปแบบไฟล์ Excel จากฐานข้อมูลของระบบ .....	61

รูปที่ 21 ตัวอย่างขั้นตอนการประเมินการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนียวนำ .....	64
รูปที่ 22 การจัดกลุ่มดัชนีสุขภาพของมอเตอร์เหนียวนำก่อนการนำเทคนิค Synthetic Minority Over-sampling Technique เข้ามาปรับใช้.....	64
รูปที่ 23 การจัดกลุ่มดัชนีสุขภาพของมอเตอร์เหนียวนำหลังการนำเทคนิค Synthetic Minority Over-sampling Technique เข้ามาปรับใช้.....	66
รูปที่ 24 ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่าง 17 พารามิเตอร์ที่แตกต่างกัน .....	68
รูปที่ 25 ขั้นตอนการดำเนินการสร้างแบบจำลอง .....	71
รูปที่ 26 ความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาปรับจูนเพื่อให้เหมาะสมกับแบบจำลอง ANN .	73
รูปที่ 27 ความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาปรับจูนเพื่อให้เหมาะสมกับแบบจำลอง GBT..	77
รูปที่ 28 ความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาปรับจูนเพื่อให้เหมาะสมกับแบบจำลอง RF ....	79
รูปที่ 29 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง ANN .....	85
รูปที่ 30 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง PSO .....	85
รูปที่ 31 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง GBT.....	86
รูปที่ 32 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง RF .....	87

## บทที่ 1

### บทนำ

ในปัจจุบันที่โลกถูกเร่งด้วยเทคโนโลยี ดังนั้นการปรับเปลี่ยนให้รวดเร็วคือกลไกสำคัญในการทำธุรกิจในยุคนี้และในอนาคตที่ใกล้เข้ามา เมื่อไม่กี่ปีที่ผ่านมาเรามักได้ยินถึงกระแสของอุตสาหกรรม 4.0 ซึ่งเป็นจุดเปลี่ยนของตลาดแรงงานเดิมที่ต้องปรับเปลี่ยนบทบาทให้มีทักษะและสอดคล้องกับการพัฒนาทางเทคโนโลยี รวมทั้งพัฒนาทักษะอื่นๆที่จำเป็น ดังนั้นอุตสาหกรรม 4.0 จึงเรียกได้ว่าเป็นยุคที่ระบบการผลิตถูกบูรณาการเข้ากับเครือข่ายอินเทอร์เน็ตในทุกสิ่ง (Internet of Things - IoT) ส่งผลให้ระบบการผลิตสินค้าและบริการถูกเชื่อมต่อเข้ากับเทคโนโลยีดิจิทัลและยังมีการใช้ปัญญาประดิษฐ์ (Artificial Neural Network : AI) เข้ามาช่วยเสริมให้ระบบการผลิตเกิดความสะดวกรวดเร็วและประหยัดต้นทุนค่าใช้จ่ายมากกว่าเดิม

เทคโนโลยีบางอย่างที่จะก่อให้เกิดการปฏิวัติอุตสาหกรรมในยุคปัจจุบันและอนาคต อาทิเช่น ปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง (Machine Learning) , อินเทอร์เน็ตในทุกสิ่ง , ข้อมูลมหัต (Big Data) เป็นต้น ทำให้ในขณะนี้มีการนำแนวคิดอุตสาหกรรม 5.0 ที่คนทำงานโดยเป็นส่วนหนึ่งของเทคโนโลยีและผนวกกับการทำงานร่วมกับปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง ส่งผลต่อการนำไปสู่การเปลี่ยนแปลงของอุตสาหกรรมภาคการผลิตที่จะมีความแตกต่างจากโรงงานในปัจจุบันอย่างสิ้นเชิง

ในยุคที่แนวโน้มอุตสาหกรรมถูกปรับเปลี่ยนไปจากรูปแบบแรงงานสู่ความเป็นอัตโนมัติมากขึ้น ทำให้ประสิทธิภาพการบำรุงรักษาไม่เพียงแต่เป็นศูนย์ต้นทุนแต่ได้กลายเป็นอาวุธสำคัญในการแข่งขัน การวางแผนบำรุงรักษาเครื่องจักรกลจึงมีความสำคัญต่อการป้องกันและลดปัญหาการชำรุดเสียหาย โดยเฉพาะธุรกิจภาคการผลิตจะเกิดความสูญเสียหลายประการ ดังนั้นผู้ประกอบการควรพิจารณาปัจจัยและประเมินผลกระทบการบำรุงรักษา เพื่อลดความสูญเสียโอกาสทางธุรกิจ

ความสำคัญของการบำรุงรักษา ประกอบด้วย

1. เพื่อให้เครื่องจักรทำงานได้อย่างมีประสิทธิภาพตรงตามวัตถุประสงค์ที่วางไว้ และใช้งานได้เต็มกำลังความสามารถ
2. เพื่อให้เครื่องจักรมีสมรรถนะการทำงานสูงขึ้น ซึ่งการบำรุงรักษาจะเป็นการช่วยยืดอายุการใช้งาน โดยอาศัยการปรับแต่งหรือซ่อมบำรุง
3. เพื่อให้เครื่องจักรมีความเที่ยงตรงน่าเชื่อถือ ในการผลิตสินค้า โดยการบำรุงรักษาจะมีผลโดยตรงต่อการทำงานของเครื่องจักรในส่วนที่เกี่ยวข้องกับความละเอียด ความ



เที่ยงตรง และมาตรฐานของสินค้า ซึ่งจะส่งผลต่อการยอมรับหรือความพึงพอใจของลูกค้าที่มีต่อสินค้า

4. เพื่อให้มีความปลอดภัย จัดว่าเป็นปัจจัยที่สำคัญเพราะถ้ามีการใช้งานเครื่องจักรที่ชำรุดหรือไม่พร้อมใช้งาน อาจก่อให้เกิดอุบัติเหตุและการบาดเจ็บต่อผู้ใช้งานได้ (ประดิษฐ์ หมู่เมืองสอง, 2013)

## 1.1 ที่มาและความสำคัญ

หนึ่งในเครื่องจักรกลที่ถูกใช้งานในอุตสาหกรรมคือมอเตอร์ไฟฟ้า ซึ่งเป็นเครื่องกลไฟฟ้า (Electromechanically Energy) ทำหน้าที่เปลี่ยนจากพลังงานไฟฟ้าเป็นพลังกลในรูปของการหมุนเคลื่อนที่ ถูกนำมาใช้งานอย่างกว้างขวางและมากที่สุดในภาคอุตสาหกรรมการผลิต จึงทำให้มอเตอร์ไฟฟ้ามีบทบาทสำคัญในการรักษาการทำงานให้ดำเนินต่อไปอย่างราบรื่นมีประสิทธิภาพ โดยเฉพาะมอเตอร์เหนี่ยวนำชนิดกรงกระรอก (Squirrel cage 3-phase motor) ซึ่งมีใช้งานมากที่สุดในอุตสาหกรรม ยกตัวอย่างมอเตอร์ที่ถูกนำไปใช้งานในอุตสาหกรรมกรณีศึกษาสำหรับหมุนขับเคลื่อนเครื่องจักร เช่น หม้อต้มไอน้ำ (Boiler) , เครื่องกำเนิดไฟฟ้า , ปั๊มชนิดต่างๆ , เครื่องเขย่าและผสม (Agitator) หรือสำหรับเครื่องจักรกลขนาดใหญ่ (Turbo-machinery) เป็นต้น ดังนั้นการรักษาการทำงานของมอเตอร์ให้ทำงานได้เป็นปกติและมีประสิทธิภาพอยู่ตลอดเวลาจึงมีความสำคัญมากและเป็นประเด็นสำคัญที่ต้องนำมาพิจารณา

สาเหตุการพังเสียหายของมอเตอร์ ส่วนใหญ่แล้วมอเตอร์มักไม่ได้เสียหรือชำรุดเพราะเก่าหรือมีชั่วโมงการทำงานมานาน แต่เกิดขึ้นได้จากหลายสาเหตุ เช่น

- ความร้อน
- ความชื้น
- การปนเปื้อนของสิ่งสกปรก
- การหล่อลื่นที่ตลับลูกปืน (Bearing) ไม่เหมาะสม
- ความผิดปกติของโหลดทางกล
- ความผิดปกติของแหล่งจ่ายไฟฟ้า

ดังนั้น มอเตอร์สามารถมีอายุการใช้งานที่ยืนยาวหากปัจจัยจากสิ่งเหล่านี้เกิดขึ้นกับมอเตอร์น้อยที่สุด เพื่อให้ครอบคลุมการตรวจสอบปัญหาที่จะส่งผลต่อการพังเสียหายของมอเตอร์ในปัจจุบัน จึงมีวิธีการในการบำรุงรักษาที่นิยมใช้ แบ่งออกได้เป็น 4 ประเภท ประกอบด้วย

1. การบำรุงรักษาโดยการซ่อมแซมเมื่อเสีย (Breakdown Maintenance)

2. การบำรุงรักษาเชิงป้องกัน (Preventive Maintenance: PM)
3. การบำรุงรักษาเชิงพยากรณ์ (Predictive Maintenance : PdM)
4. การบำรุงรักษาเชิงรุก (Proactive Maintenance)

จากระบบการบำรุงรักษาที่นิยมใช้ดังที่กล่าวไปในข้างต้นนี้ นอกจากนั้นในปัจจุบันยังมีการพัฒนาบูรณาการวิศวกรรมการซ่อมบำรุง การวิเคราะห์ข้อมูลและข้อมูลมหัต เพื่อนำข้อมูลที่ได้มาใช้เพื่อการวิเคราะห์และทำนายผลล่วงหน้าถึงแนวโน้มของปัญหาที่อาจเกิดขึ้น เพื่อให้ทราบถึงข้อมูลสภาพการทำงานของเครื่องจักรและเหตุการณ์ผิดปกติ ทำให้ดำเนินการแก้ไขป้องกันปัญหาได้อย่างรวดเร็ว และมีประสิทธิภาพ


จากข้อมูลของมอเตอร์แต่ละตัวที่เป็นลักษณะเฉพาะการใช้งานในแต่ละพื้นที่ หรือใช้ในการขับเคลื่อนอุปกรณ์ที่แตกต่างกัน สามารถนำมาใช้สร้างแบบจำลองเพื่อวิเคราะห์และแสดงถึงพฤติกรรมการทำงานในสถานะที่ปกติหรือผิดปกติไปจากค่าฐาน(Baseline) หรือใช้เพื่อการทำนายผลที่จะเกิดขึ้นในอนาคต ใช้เพื่อช่วยในการตัดสินใจ นำมาใช้ในการบริหารจัดการระบบหรือการซ่อมบำรุงเพื่อลดปัญหาการหยุดกระทันหันของระบบได้

## 1.2 การบำรุงรักษามอเตอร์ในอุตสาหกรรมกรณีศึกษา

อ้างอิงจากประวัติการบำรุงรักษามอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษา ใช้การผสมผสานเทคนิคการบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance: PdM) กับการบำรุงรักษาเชิงป้องกัน (Preventive Maintenance: PM) ประกอบด้วย

- 1) การตรวจวิเคราะห์ความสั่นสะเทือน (Vibration Analysis) โดยเฉลี่ยเท่ากับหนึ่งครั้งต่อสองสัปดาห์ หรือทุกๆรอบเดือน เป็นต้น เป็นการตรวจวัดในรูปแบบที่คนนำเครื่องมือไปตรวจวัดค่าและนำมาวิเคราะห์ผลในด้านความผิดปกติที่เกี่ยวข้องกับการสั่นสะเทือน
- 2) เทคโนโลยีภาพความร้อนอินฟราเรด (Infrared Thermography) โดยเฉลี่ยแล้วปีละ 1 ครั้งเพื่อวิเคราะห์หาความผิดปกติที่เกิดขึ้นจากอุณหภูมิ จากนั้นนำผลตรวจวัดมาวิเคราะห์หาสาเหตุแก้ไข
- 3) การวิเคราะห์ค่าน้ำมัน (Oil Analysis) สำหรับวิเคราะห์หาสารปนเปื้อนต่างๆของน้ำมันภายในเป็นประจำ ทุกๆ 1 ปี
- 4) การบำรุงรักษาเชิงป้องกัน ทุกๆ 1 ปี
- 5) การยกเครื่อง (Overhaul) สำหรับการซ่อมบำรุงครั้งใหญ่ ทุกๆ 3 ปี
- 6) มอเตอร์บางตัวมีการติดตั้งเซอร์ตรวจวัดแบบออนไลน์ (Online) เพื่อทำการเฝ้าติดตามควบคุมหรือการเฝ้าสังเกต (Monitor) ค่าพารามิเตอร์ตามเวลาจริง (Real time) เช่น ค่าความ

สั่นสะเทือนโดยรวม (Overall vibration), ค่าแรงดัน (Voltage), ค่ากระแส (Current) และ ค่าอุณหภูมิพื้นผิว เป็นต้น สำหรับใช้แจ้งเตือนเมื่อค่าสูงเกินเกณฑ์ที่ทำการตั้งค่าไว้ โดยกิจกรรมการบำรุงรักษามอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษาแสดงดังรูปที่ 1



รูปที่ 1 กิจกรรมการบำรุงรักษามอเตอร์ไฟฟ้าของอุตสาหกรรมกรณีศึกษา

### 1.3 วิเคราะห์ผลการบำรุงรักษา

#### 1.3.1 การตรวจติดตามค่าการสั่นสะเทือน (Vibration Condition Monitoring) และการวิเคราะห์ผล

สำหรับการตรวจติดตามค่าการสั่นสะเทือนนั้นมีการจัดระดับความรุนแรง (Criteria assessment) โดยทั่วไปแล้วจะอ้างอิงจาก ISO 10816 – การประเมินผลค่าความสั่นสะเทือนของเครื่องจักรบนชิ้นส่วนที่ไม่มีการหมุน (Part 1: แนวปฏิบัติทั่วไป) ที่ใช้กำหนดเกณฑ์ในการประเมินระดับความรุนแรงเบื้องต้นด้วยค่าความสั่นสะเทือน นอกจากนั้นยังมีการจัดทำสัญญาณเตือนทางสถิติเป็นการนำค่าความสั่นสะเทือนของตัวเครื่องจักรเองมาใช้ในการกำหนดเกณฑ์ระดับความรุนแรงของเครื่อง

จากมาตรฐานที่ใช้อ้างอิง สามารถสรุปผลค่าการประเมินระดับความรุนแรงของค่าความสั่นสะเทือนได้ดังตารางที่ 1 และตัวอย่างผลการประเมินจริงที่ถูกรับบันทึกไว้ในระบบแสดงดังรูปที่ 2

ตารางที่ 1 ระดับความรุนแรงของการประเมินค่าความสั่นสะเทือนของอุตสาหกรรมกรณีศึกษา

ระดับความรุนแรง	ความหมายของการจัดระดับ
ระยะ A	สถานะปกติ : ค่าความสั่นสะเทือนของเครื่องจักรที่ถูกติดตั้งใหม่หรืออยู่ในสภาพปกติ
ระยะ B	อยู่ในเกณฑ์ที่ยอมรับได้ เครื่องจักรมีค่าความสั่นสะเทือนที่ถือว่ายอมรับได้ในการเดินเครื่องระยะยาว
ระยะ C (แจ้งเตือนระดับ 1)	ปกติแล้วเครื่องจักรที่มีการสั่นสะเทือนภายในโซนนี้จะถือว่าไม่น่าพอใจสำหรับการทำงานต่อเนื่องในระยะยาว โดยทั่วไป เครื่องจักรควรดำเนินการวางแผนหยุดเพื่อรับการแก้ไข
ระยะ D (แจ้งเตือนระดับ 2)	ค่าความสั่นสะเทือนในโซนนี้รุนแรงพอที่จะทำให้เครื่องจักรเสียหาย ควรดำเนินการหยุดเพื่อซ่อมบำรุงทันที

Plant Name						Condition monitoring Plan							Running Plan				Condition monitoring Plan									
						May-2021						May-2021	May-2021			May-2021	May-2021			June-2021	June-2021			June-2021		
						25Apr-30Apr	01May-08May	09May-15May	16May-22May	23May-29May	30May-31May	Summary of severity	01May-08May	09May-15May	16May-22May	23May-29May	30May-31May	01Jun-05Jun	06Jun-12Jun	13Jun-19Jun	20Jun-26Jun	27Jun-30Jun				
No.	Eq. Tag	Name Machine	Machine Class	Area	Route	W18	W18	W19	W20	W21	W22		W18	W19	W20	W21	W22	W23	W24	W25	W26	W27				
01			A	Area 3	22W-01		Can't check			Can't check		Can't check							Can't check							
02			A	Area 3	22W-01		Can't check			Can't check		Can't check							Can't check			Pin				
03			A	Area 3	22W-01		Can't check			Can't check		Can't check							Can't check			Pin				
04			A	Area 3	22W-01		12-May-21			12-May-21		Stage A							01-Jun-21			Pin				
05			A	Area 4	22W-01		12-May-21			12-May-21		Stage A							01-Jun-21			Pin				
06			A	Area 4	22W-01		12-May-21			12-May-21		Stage A							01-Jun-21			Pin				
07			B	Area 3	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
08			B	Area 3	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
09			B	Area 4	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
10			B	Area 4	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
11			B	Area 4	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
12			B	Area 4	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
13			B	Area 4	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
14			B	Area 4	22W-01		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
15			B	Area 5	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
16			B	Area 5	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
17			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
18			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
19			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
20			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
21			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
22			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
23			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
24			A	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
25			B	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
26			B	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
27			B	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				
28			B	Area 2	22W-02		12-May-21			12-May-21		Stage B							01-Jun-21			Pin				

รูปที่ 2 ตัวอย่างการประเมินค่าความสั่นสะเทือนของเครื่องจักร

### 1.3.2 ค่าที่ได้จากออนไลน์เซ็นเซอร์


มอเตอร์ส่วนใหญ่จะมีออนไลน์เซ็นเซอร์ ทำหน้าที่เก็บค่าพารามิเตอร์ ประกอบด้วย แรงดันไฟฟ้า , กระแสไฟฟ้า , ค่าความสั่นสะเทือน , อุณหภูมิ เพื่อนำมาใช้ในการแจ้งเตือน กรณีค่าพารามิเตอร์ต่างๆเหล่านี้อยู่ในระดับที่เกินกว่าเกณฑ์ที่ได้กำหนดค่าไว้ ตัวอย่างข้อมูลที่ได้จากออนไลน์เซ็นเซอร์แสดงดังรูปที่ 3



3. มอเตอร์กลุ่ม B คือ มอเตอร์ที่ถูกกำหนดให้อยู่ในกลุ่มระบบที่เมื่อเกิดความผิดปกติเกิดขึ้น จะทำให้เกิดผลกระทบต่อผลิตภัณฑ์ที่ผิดข้อกำหนดแต่ไม่กะทันหัน หรือทำให้เกิดความยุ่งยากในการควบคุมกระบวนการซึ่งมีแนวโน้ม(ความเสี่ยงสูง) ที่นำไปสู่ผลิตภัณฑ์ที่ไม่เป็นไปตามข้อกำหนด เกิดการลดลงของกำลังการผลิตหรือทำให้เกิดการหยุดชะงักของกระบวนการผลิตแต่ไม่กะทันหัน แต่ทำให้เกิดต้นทุนที่เพิ่มขึ้นอย่างมีนัยสำคัญ มอเตอร์กลุ่ม B มีจำนวนทั้งหมด 148 ตัว หรือคิดเป็น 44%

4. มอเตอร์กลุ่ม C คือ มอเตอร์ที่ถูกกำหนดให้อยู่ในกลุ่มระบบที่เมื่อเกิดความผิดปกติเกิดขึ้น ไม่ก่อให้เกิดผลกระทบโดยตรงต่อข้อกำหนดเฉพาะของผลิตภัณฑ์ และไม่ก่อให้เกิดผลกระทบต่อผลผลิตโดยตรงต่อการหยุดชะงักของผลิตภัณฑ์ มอเตอร์กลุ่ม C มีจำนวนทั้งหมด 96 ตัว หรือคิดเป็น 28%

เมื่อนำกลุ่มของมอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษามาแยกสัดส่วนแสดงดังรูปที่ 4 และตารางที่ 2 สำหรับจำนวนมอเตอร์ไฟฟ้าแยกตามกลุ่ม



รูปที่ 4 สัดส่วนจำนวนมอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษา


ตารางที่ 2 จำนวนมอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษาแบ่งตามกลุ่ม

กลุ่ม	จำนวน
S	10
A	83
B	148
C	96
รวม	337


จากข้อมูลการซ่อมบำรุงพบว่าในแต่ละปีนั้นมีจำนวนมอเตอร์ที่เกิดเหตุการณ์ลัมเหลวที่ก่อให้เกิดการหยุดชะงักของกระบวนการผลิต โดยประวัติจำนวนครั้งในการเกิดเหตุการณ์ลัมเหลวของมอเตอร์ไฟฟ้าแยกตามกลุ่ม ตั้งแต่ปีค.ศ. 2010 แสดงได้ดังตารางที่ 3 และเมื่อนำมาแยกจำนวนการลัมเหลวของกลุ่ม A และกลุ่ม B แสดงได้ดังรูปที่ 5 และรูปที่ 6 ตามลำดับ

ตารางที่ 3 ผลสำรวจจำนวนครั้งในการลัมเหลวของมอเตอร์ ตั้งแต่ปีค.ศ. 2010

กลุ่ม	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	รวม
S					3	1			1	2	1	8
A	8	16	7	10	8	17	4	5	2	2	7	86
B	10	17	19	14	18	11	16	14	12	13	11	155
C	12	13	5	8	2	7	6	7	2	3	5	70
รวม	30	46	31	32	31	36	26	26	17	20	24	319



รูปที่ 5 จำนวนครั้งในการลัมเหลวของมอเตอร์กลุ่ม A



รูปที่ 6 จำนวนครั้งในการลัมเหลวของมอเตอร์กลุ่ม B

### 1.4.2 คำนวณความน่าเชื่อถือของการบำรุงรักษา

ในการคำนวณค่าความน่าเชื่อถือของการบำรุงรักษาในงานวิจัยฉบับนี้ มองภาพรวมเป็นกลุ่มของเครื่องจักร โดยการนำจำนวนทั้งหมดของมอเตอร์ที่อยู่ในกลุ่มใดๆนำมาคำนวณ

#### 1. มอเตอร์กลุ่ม S

มอเตอร์กลุ่ม S โดยส่วนใหญ่แล้วทำงานในการขับเคลื่อนปั๊มระดับเพลิงและระบบป้องกันไฟไหม้ ดังนั้นจึงไม่นำมาพิจารณาในงานวิจัยฉบับนี้

#### 2. มอเตอร์กลุ่ม A

นำจำนวนครั้งในการล้มเหลวและจำนวนมอเตอร์ทั้งหมดจำนวน 83 ตัว มีค่าเท่ากับ 88 ครั้งในระยะเวลาเมื่อมองในแง่ของดัชนีชี้วัดความสำเร็จ (Key Performance Indicator : KPI) หรือดัชนีตัวชี้วัดในงานบริหารงานซ่อมบำรุงและหาค่าระยะเวลาเฉลี่ยที่อุปกรณ์ทำงานได้ในสภาวะปกติ (Mean Time to Failure : MTTF) นำมาคำนวณหาความน่าเชื่อถือของการบำรุงรักษา กำหนดให้คิดเป็นระยะเวลาตั้งแต่ปีค.ศ. 2010-2020 ดังต่อไปนี้

งานวิจัยฉบับนี้ ได้กำหนดให้แทนด้วยค่าเฉลี่ยที่เครื่องจักรทำงาน 24 ชั่วโมง เป็นระยะเวลา 365 วัน และทุกๆ 3 ปี (ในระยะเวลา 10ปี มีการยกเครื่องเพื่อทำการตรวจสอบ ทั้งหมด 3 ครั้ง) จะหยุดเพื่อทำการยกเครื่องเฉลี่ยเป็นระยะเวลา 30 วัน นอกจากนั้นในแต่ละปียังมีการหยุดเพื่อทำการบำรุงรักษาเชิงป้องกัน ระยะเวลาเฉลี่ยของการหยุดของมอเตอร์ในการบำรุงรักษาเชิงป้องกัน รวบรวมเวลารอกระบวนการในการผลิตอื่นๆเพื่อเริ่มเดินเครื่องจักรเฉลี่ยประมาณ 30 วัน และในกรณีการล้มเหลว จะใช้เวลาในการหยุดซ่อมแซมแต่ละครั้ง ประมาณ 7 วัน

ระยะเวลาที่เฉลี่ยที่มอเตอร์ทำงาน	= ระยะเวลา 10ปีที่มอเตอร์ทำงาน - เวลาที่
	เครื่องหยุดซ่อม - เวลาที่เครื่องหยุดเพื่อ
	บำรุงรักษาเชิงป้องกัน - เวลาที่เครื่องหยุดเพื่อ
	ยกเครื่อง
	$= (24 \times 365 \times 10 \times 83) - (24 \times 7 \times 86) -$
	$(24 \times 30 \times 83 \times 10) - (24 \times 30 \times 83 \times 3)$
	$= 6,479,472 \text{ ชั่วโมง/class}$
จะได้	$\text{MTTF\_A} = 6,479,472 / 86$
	$= 75,342.7 \approx 75,342 \text{ ชั่วโมง}$
	$\text{MTTR\_A} = (24 \times 7 \times 86) / 86 = 168 \text{ ชั่วโมง}$
ดังนั้น	$\text{Available\_A} = (75,342 / (75,342 + 168)) \times 100 = 99.76\%$



### 3. มอเตอร์กลุ่ม B

ในหนึ่งระบบ จะประกอบไปด้วยมอเตอร์ไฟฟ้าจำนวน 2-3 ตัว คือ A,R หรือ A,B,C ที่สลับกันทำงานคือทำงานและในช่วงที่มีความต้องการของดีมานจำนวนมาก จะมีการทำงานแบบเต็มคาปาซิตี คือทำการพร้อมกันทั้งระบบ โดยเฉลี่ยแล้วมอเตอร์ทำงานเท่ากับ 70% ของระยะเวลาการทำงาน

ระยะเวลาที่เฉลี่ยที่มอเตอร์ทำงาน	= ระยะเวลา 10ปีที่มอเตอร์ทำงาน - เวลาที่เครื่องหยุดซ่อม - เวลาที่เครื่องหยุดเพื่อบำรุงรักษาเชิงป้องกัน - เวลาที่เครื่องหยุดเพื่อยกเครื่อง
	= $(24*365*10*148*0.7) - (24*7*155) - (24*30*148*10) - (24*30*148*3)$
	= 7,664,040
จะได้	MTTF_B = 7,664,040/155
	= 49,445.4 $\approx$ 49,445 ชั่วโมง
	MTTR_B = $(24*7*155)/155 = 168$ ชั่วโมง
ดังนั้น	Available_B = $(49,445 / (49,445 + 168)) * 100 = 99.66\%$

### 4. มอเตอร์กลุ่ม C

ไม่นำมาพิจารณาเนื่องจากการจัดระดับความสำคัญที่ส่งผลกระทบต่อกระบวนการผลิตน้อยที่สุด

จากการเทียบประสิทธิภาพการนำเชื้อถือของการบำรุงรักษาที่ชีวิตด้วยค่าความพร้อมใช้งานของมอเตอร์พบว่าค่าที่ค่อนข้างสูง >90% เนื่องจากการทำงานของมอเตอร์มีเวลาเฉลี่ยเกือบ 24 ชั่วโมง ดังนั้นเมื่อนำมาเทียบระหว่างระยะเวลาในการล้มเหลวและซ่อมบำรุงแล้วมีสัดส่วนที่มากกว่า จึงส่งผลให้ค่าความพร้อมใช้งานมีค่าสูง แต่ทั้งนั้นแล้วจะพบว่าหากเกิดการล้มเหลวจะส่งผลกระทบต่อกระบวนการผลิตยาวนานถึง 7 วัน ซึ่งกระทบต่อการสูญเสียโอกาสในการผลิต, ค่าความเสียหายที่เกิดขึ้นและค่าใช้จ่ายในการซ่อมแซมแก้ไขที่มากมายมหาศาล เมื่อเปรียบเทียบแล้วพบว่ามอเตอร์กลุ่ม B มีค่าความพร้อมใช้งานของเครื่องที่น้อยกว่ามอเตอร์กลุ่ม A ดังนั้นแล้วสำหรับการพิจารณาในวิทยานิพนธ์ฉบับนี้จึงมุ่งเน้นไปที่มอเตอร์กลุ่ม B ก่อน

### 1.4.3 ปัญหาที่เกิดขึ้นจากเทคนิคที่ใช้ในการบำรุงรักษา

พบปัญหาของช่องว่างในการวิเคราะห์ผลของเทคนิคที่ใช้ในการบำรุงรักษาประกอบด้วย

1. รูปแบบการพังเสียหายของมอเตอร์ไฟฟ้า (Motor Failure Mode) ประกอบด้วย
  - 1.1 ความเสียหายทางกล (Mechanical Faults)
  - 1.2 ความเสียหายทางไฟฟ้า (Electrical Faults)

ปัจจุบันอุตสาหกรรมกรณีศึกษา ยังไม่ได้มีการนำค่าพารามิเตอร์อื่นที่วัดได้จากออนไลน์เซ็นเซอร์มาร่วมวิเคราะห์หาสุขภาพมอเตอร์

2. ช่องว่างที่เกิดขึ้นในการตรวจสอบ


การตรวจวิเคราะห์ค่าความสั่นสะเทือนเป็นแบบงานประจำ (ทุกๆ 2 สัปดาห์หรือทุกๆ 1 เดือนขึ้นอยู่กับอุปกรณ์) โดยอาศัยคนในการเก็บข้อมูลและเป็นการวิเคราะห์ผลแบบจุดเฉพาะวันที่ทำการบันทึกค่า ซึ่งหากในระหว่างวันหรือระหว่างรอบการเก็บค่า มีสภาพแวดล้อมการทำงานที่เปลี่ยนแปลง หรือช่วงระหว่างที่ไม่มีการตรวจวัดแต่เครื่องจักรเกิดการเปลี่ยนแปลงของสถานะสภาพ ก็จะทำให้ไม่สามารถตรวจวัดปัญหาได้อย่างต่อเนื่อง จึงเป็นปัญหาในด้านความต่อเนื่องของการวิเคราะห์ผล และในการตรวจสอบปัจจุบันยังไม่ได้มีการนำข้อมูลที่ได้นำมาวิเคราะห์ผลรวมกัน

3. ความผิดพลาดของคน เช่น คนที่เข้าตรวจวัดทำการตั้งค่าเครื่องมือผิดพลาดหรือแม้กระทั่งคนที่ทำการตีความหรือวิเคราะห์ผลการตรวจสอบที่มีจำนวนมาก ก่อให้เกิดการวิเคราะห์ผลแต่ละครั้งแตกต่างกันและอาจเกิดความผิดพลาดเกิดขึ้นได้

4. ปัญหาอื่นๆ

การบำรุงรักษามอเตอร์ไฟฟ้า ใช้แผนการบำรุงรักษาเชิงป้องกันโดยมีตัวแปรสำคัญคือ เวลาและระยะเวลาใช้งาน ของเครื่องจักร และอุปกรณ์ ที่จะเป็นตัวกำหนดการวางแผนสำหรับบำรุงรักษา ซึ่งอาจไม่ได้ใช้ข้อมูลอื่นของเครื่องจักรหรืออุปกรณ์ ณ สภาพเวลาปัจจุบันที่ทำงานอยู่นั้น มาช่วยในการกำหนดแผนการซ่อมบำรุง ซึ่งบางครั้งการหยุดเครื่องจักรเพื่อทำการบำรุงรักษา ก็ไม่ได้รับประกันได้ว่าอุปกรณ์ที่ทำการแก้ไขเปลี่ยนแปลงนั้นจะสามารถทำงานได้ดีและมีประสิทธิภาพ จนกว่าจะถึงรอบการบำรุงรักษาถัดไป หรือแม้กระทั่งหากการบำรุงรักษานั้นถูกกระทำในขณะที่เครื่องจักรยังคงมีประสิทธิภาพที่สามารถทำงานได้ปกติอยู่แล้ว การหยุดเครื่องจักรหรืออุปกรณ์เพื่อบำรุงรักษาดังกล่าว ก็อาจทำให้สูญเสียค่าใช้จ่ายที่เกินความจำเป็นได้ นอกจากนั้นยังมีปัญหาอื่นๆที่เกิดขึ้นภายนอกกระบวนการ และปัญหาจากเซ็นเซอร์ที่ผิดปกติ เป็นต้น

จากปัญหาที่เกิดขึ้นนำมาวิเคราะห์หาสาเหตุของการบำรุงรักษาที่ยังคงก่อให้เกิดการล้มเหลวของมอเตอร์ แสดงผลดังแผนภูมิแกงปลาในรูปที่ 7



รูปที่ 7 แผนภูมิแก๊งปลาสาเหตุของการล้มเหลวของมอเตอร์

#### 1.4.4 วางแผนวิธีการแก้ไขปัญหา

##### 1. หัวข้อปัญหา: รูปแบบความเสียหายและช่องว่างในการตรวจสอบ

วิธีแก้ไข: นำค่าที่ตรวจวัดได้จากออนไลน์เซ็นเซอร์ทุกพารามิเตอร์มาใช้ในการวิเคราะห์ร่วมด้วย โดย การสร้างแบบจำลองเพื่อวิเคราะห์ผลจากพฤติกรรมการทำงาน เพื่อให้สามารถตรวจติดตามสภาพ สุขภาพของมอเตอร์ไฟฟ้าได้ตามเวลาจริง (Real time)

เครื่องมือ: การเรียนรู้ของเครื่อง (Machine Learning)

##### 2. หัวข้อปัญหา: ความผิดพลาดของคน

วิธีแก้ไข: เปลี่ยนจากการใช้คนในการวิเคราะห์เพื่อจัดระดับความรุนแรงของปัญหามาใช้การเรียนรู้ของเครื่องเพื่อเทียบเคียงประวัติความเสียหายจากข้อมูลสถิติในอดีต

เครื่องมือ: การเรียนรู้ของเครื่อง (Machine Learning)

##### 3. ปัญหาอื่นๆ: ยังไม่ได้ถูกนำมาพิจารณาในงานวิจัยฉบับนี้

ดังนั้นในงานวิจัยฉบับนี้จึงเลือกที่จะใช้เครื่องมือในการแก้ปัญหาคือการประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning) นำมาสร้างแบบจำลองเพื่อประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ


## 1.5 แนวทางในการจัดทำวิทยานิพนธ์

เพื่อทำการสร้างแบบจำลองสำหรับพยากรณ์ระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ ด้วยการจัดระดับความรุนแรงโดยประยุกต์ใช้การเรียนรู้ของเครื่อง ซึ่งตัวอย่างมอเตอร์ไฟฟ้าที่จะมีการนำค่าพารามิเตอร์ไปใช้ในการสร้างแบบจำลอง จะต้องทำการวิเคราะห์หามอเตอร์ที่มีนัยสำคัญทั้งต่อกระบวนการผลิตและประวัติความเสียหาย ดังต่อไปนี้

### 1.5.1 แผนภูมิพารेटโต สำหรับพิจารณาหามอเตอร์ที่เกิดการล้มเหลวอย่างมีนัยสำคัญ

สำหรับพิจารณาเลขที่ของมอเตอร์ที่เกิดการล้มเหลว เรียงลำดับจากมากไปหาน้อย ในงานวิจัยฉบับนี้ ด้วยการพิจารณามอเตอร์กลุ่ม B เนื่องจากมีความพร้อมใช้งานของอุปกรณ์ที่น้อยกว่าเมื่อเทียบกับกลุ่ม A

หมายเหตุ: เนื่องจากเลขที่ของมอเตอร์ เป็นข้อมูลความลับของอุตสาหกรรมตัวอย่างทางผู้จัดทำจึงไม่ได้นำมาเป็นข้อมูลในแผนภูมิภาพ โดยแผนภูมิพารेटโตแสดงจำนวนครั้งของการล้มเหลวของมอเตอร์ไฟฟ้าในอุตสาหกรรมกรณีศึกษาแสดงดังรูปที่ 8



รูปที่ 8 แผนภูมิพารेटโตจำนวนการล้มเหลวของมอเตอร์กลุ่ม B

จากแผนภูมิพารेटโต สามารถนำเลขที่ของมอเตอร์ มาจัดลำดับได้ดังตารางที่ 4

ตารางที่ 4 จัดลำดับจำนวนครั้งของการล้มเหลวของมอเตอร์กลุ่ม B

กลุ่ม	เลขที่	คำบรรยาย	จำนวนการล้มเหลว
B	XXXXX01C	N/A	6
	XXXX701A	TRANSFER PUMP MOTOR	6
	XXXX401D	N/A	6
	XXXX401B	N/A	5
	XXXX5701	N/A	5
	XXXX02R	N/A	4
	XXXX06R	N/A	4
	XXXX40A	N/A	4
	XXXX701R	TRANSFER PUMP MOTOR	4
	XXXX601A	N/A	4
	XXXX01-56	N/A	4
	XXXX02-56	N/A	4

จากการพิจารณาเลือกตามปัญหาของการล้มเหลวในแต่ละครั้ง พบว่ามอเตอร์เลขที่ XXXX701A และ XXXX701R พบปัญหาการเกิดความเสียหายที่มีนัยสำคัญเนื่องจากในจำนวนครั้งของการล้มเหลว เกิดจากทั้งปัญหาทางกลและปัญหาทางไฟฟ้า โดยทั้งสองตัวนี้มีเซ็นเซอร์ที่สามารถนำพารามิเตอร์ที่เกี่ยวข้องมาใช้ในการพิจารณา

แทนที่ชื่อมอเตอร์เลขที่ XXXX701A และ XXXX701R ด้วย 701A และ 701R ตามลำดับ จากประวัติการล้มเหลวที่ถูกบันทึกของมอเตอร์เลขที่ 701A และ 701R แสดงดังตารางที่ 5

ตารางที่ 5 ประวัติการล้มเหลวของมอเตอร์ 701A และ 701R


เลขที่	คำบรรยาย	กลุ่ม
701A	ยกเครื่องมอเตอร์ (Overhaul)	B
	แกนหมุนสั้นโยก	B
	มอเตอร์ล๊อค	B
	ค่าความสั่นสะเทือนสูง	B
	สั่งซื้อตลับลูกปืน	B

	วัดความเสื่อมสภาพของฉนวน (Partial Discharge)	B
701R	ถ่ายภาพถ่ายความร้อน	B
	ยกเครื่องมอเตอร์ (Overhaul)	B
	ปลดสาย 701R	B
	วัดความเสื่อมสภาพของฉนวน (Partial Discharge)	B

จากแผนภูมิพาเรโตเพื่อหาเครื่องจักรที่มีนัยสำคัญทั้งปัญหาในการพังเสียหายและจำนวนครั้งในการล้มเหลว จึงได้ตัวอย่างมอเตอร์ที่จะนำมาใช้ในการพิจารณาคือมอเตอร์เลขที่ 701A และ 701R

### 1.5.2 กระบวนการทำงานของมอเตอร์ 701A และ 701R

ภาพแสดงตำแหน่งของมอเตอร์ไฟฟ้าเลขที่ 701A และ 701R ในระบบ แสดงดังรูปที่ 9



รูปที่ 9 ตำแหน่งมอเตอร์ไฟฟ้าเลขที่ 701A และ 701R ในระบบ

กระบวนการทำงานของมอเตอร์ ประกอบด้วย

1. มอเตอร์เลขที่ 701A และ 701R เป็นมอเตอร์ที่อยู่ในระบบถังเก็บสารเคมี ทำหน้าที่ขับปั๊มสำหรับส่งผลิตภัณฑ์คือเคมีภัณฑ์จากถังเก็บส่งให้ลูกค้า

2. โดยทั่วไปแล้วมอเตอร์ 2 ตัว มีการทำงานสลับกันโดยที่ตัวหนึ่งทำงาน และมีอีกตัวหนึ่งทำหน้าที่สำรองหรือสแตนด์บายระบบ (standby mode) และในช่วงเวลาที่มีความต้องการสินค้าสูงนั้น มอเตอร์ทั้ง 2 ตัว จะทำงานพร้อมกันและทำงานตลอด 24 ชั่วโมง
3. การทำงานของมอเตอร์ภายใต้เส้นโค้งมาตรฐานของการทำงานคืออยู่ภายใต้ขีดความสามารถของเครื่อง
4. ข้อมูลจำเพาะของมอเตอร์ประกอบด้วย
  - ชนิดของมอเตอร์: มอเตอร์เหนี่ยวนำหรืออินดักชันมอเตอร์ ชนิดมอเตอร์กรงกระรอก (Squirrel Cage)
  - กำลัง 475 กิโลวัตต์, 2 ขั้ว, 50 เฮิร์ต, 3 เฟส, 6.6 กิโลโวลต์
  - ความเร็วรอบ: 2,950 รอบต่อนาที (rpm)
  - น้ำหนักของมอเตอร์: 697.5 กิโลกรัม
  - กระแสขณะไม่มีโหลดมีค่าตั้งแต่ 48 แอมป์ , 26 แอมป์, 37 แอมป์และ 11 แอมป์

## 1.6 วัตถุประสงค์

สร้างแบบจำลองเพื่อพยากรณ์ระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแบบเรียลไทม์ในโรงงานปิโตรเคมีโดยใช้การเรียนรู้ของเครื่องภายใต้เงื่อนไขค่าพารามิเตอร์ที่ได้จากการเก็บค่าโดยเซ็นเซอร์

จุฬาลงกรณ์มหาวิทยาลัย

## 1.7 ขอบเขตของงานวิจัย

1. แบบจำลองที่ได้จากข้อมูลของมอเตอร์เหนี่ยวนำ ขนาดกำลัง กำลัง 475 กิโลวัตต์, 2 ขั้ว, 50 เฮิร์ต, 3 เฟส, 6.6 กิโลโวลต์ความเร็วรอบ 2,950 รอบต่อนาที จำนวน 2 ตัวที่มีคุณสมบัติเหมือนกันและใช้งานสำหรับขับโหลดที่สภาพแวดล้อมเดียวกัน
2. ข้อมูลที่นำเข้ามาในการสร้างแบบจำลองก่อนการทำความสะอาดข้อมูล (Cleaning Data) ประกอบด้วย (ค่าอินพุตของแบบจำลอง : X)
  - กระแสไฟฟ้า
  - แรงดันไฟฟ้า
  - ค่าความสั่นสะเทือน
  - อุณหภูมิในหน่วยองศาเซลเซียส

3. ในการเลือกมอเตอร์ที่มีนัยสำคัญเพื่อนำมาพิจารณาสร้างแบบจำลองนั้น พิจารณาเลือกจากจากมอเตอร์กลุ่ม A และกลุ่ม B เท่านั้น
4. อัลกอริทึม (Algorithm) ที่นำมาสร้างแบบจำลองต้องมีอย่างน้อย 4 อัลกอริทึม แล้วเปรียบเทียบผลความแม่นยำจากค่าเฉลี่ยความแม่นยำและความถูกต้อง (F1 score) ,ค่าความแม่นยำ (Precision) และค่าความถูกต้อง (Recall) นอกจากนั้นยังต้องพิจารณาจากเส้นโค้ง AUC-ROC เพื่อหาแบบจำลองที่เหมาะสมที่สุดสำหรับมอเตอร์กลุ่มที่มีคุณสมบัติดังที่ได้เลือกมา
5. การประเมินผลระดับความรุนแรงของสุขภาพของมอเตอร์หนึ่งยวนำถูกแบ่งออกเป็น 4 กลุ่มประกอบด้วย (ค่าเอาต์พุตของแบบจำลอง : Y)
  - ระดับ 0 คือ สถานะปกติ: มอเตอร์ไฟฟ้าอยู่ในสภาพปกติ
  - ระดับ 1 คือ อยู่ในเกณฑ์ที่ยอมรับได้ : มอเตอร์มีสุขภาพที่สามารถยอมรับได้ในการเดินเครื่องระยะยาว
  - ระดับ 2 (แจ้งเตือนระดับ 1) คือ ระดับสุขภาพของมอเตอร์ถือว่าไม่น่าพอใจสำหรับการทำงานต่อเนื่องในระยะยาว มอเตอร์ควรดำเนินการวางแผนหยุดเพื่อรับการแก้ไข
  - ระดับ 3 (แจ้งเตือนระดับ 2) คือ ค่าพารามิเตอร์ต่างๆมีค่าที่สูงเกินเกณฑ์ที่กำหนดและส่งผลกระทบทำให้มอเตอร์เกิดความเสียหาย(พังเสียหาย) ควรดำเนินการหยุดเพื่อซ่อมบำรุงทันที
6. เกณฑ์ในการประเมินระดับสุขภาพของข้อมูลที่จะใช้สำหรับการเรียนรู้แบบมีการสอนนั้นจะพิจารณาจากปัจจัยคือค่ากระแสไฟฟ้าที่จะส่งผลต่อการเกิดความผิดปกติทางด้านไฟฟ้าและค่าความสั่นสะเทือนที่จะส่งผลกระทบต่อความผิดปกติทางกล การประเมินจะถูกแบ่งออกเป็นทั้งหมด 16 กรณีแสดงดังตารางที่ 6



ตารางที่ 6 การประเมินผลของระดับสุขภาพมอเตอร์ไฟฟ้า

กรณีของการประเมิน	ระดับการประเมิน		
	ระดับการประเมินทางไฟฟ้า	ระดับการประเมินทางกล	ผลสรุประดับการประเมิน
1	0	0	0
2	0	1	1
3	0	2	2
4	0	3	3
5	1	0	1
6	1	1	1
7	1	2	2
8	1	3	3
9	2	0	2
10	2	1	1
11	2	2	2
12	2	3	3
13	3	0	3
14	3	1	3
15	3	2	3
16	3	3	3

7. ใช้โปรแกรมจูปิเตอร์โน้ตบุ๊ก (Jupyter Notebook) ในการเขียนโปรแกรมเพื่อสร้างแบบจำลอง และภาษาที่ใช้คือไพธอน (Python)
8. อัลกอริทึมที่ใช้ในแบบจำลองของเครื่องเลือกใช้ประเภทการเรียนรู้แบบมีผู้สอน (Supervised Learning)

## 1.8 ขั้นตอนการดำเนินงานวิจัย

1. วิเคราะห์หาสาเหตุการล้มเหลวของมอเตอร์เหนี่ยวนำที่ใช้งานในอุตสาหกรรมกรณีศึกษา
2. ศึกษาเครื่องมือและเทคนิคที่จะนำมาแก้ไขปัญหา เพื่อลดอัตราการล้มเหลวของมอเตอร์เหนี่ยวนำ
3. ศึกษาการทำงานของอุปกรณ์ที่ใช้การเรียนรู้ของเครื่อง รวมถึงภาษาที่ใช้ในการเขียนโปรแกรมคอมพิวเตอร์ ในงานวิจัยฉบับนี้ใช้ภาษาไพธอน (Python) ในการสร้างแบบจำลอง
4. วิเคราะห์หาเลขที่ของมอเตอร์เหนี่ยวนำ ที่มีอัตราการล้มเหลวที่มากและมีนัยสำคัญในด้านปัญหาของการล้มเหลว เพื่อนำมาใช้สร้างแบบจำลองสำหรับพยากรณ์ระดับดัชนีสุขภาพ
5. ค้นคว้าทฤษฎีและงานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้การเรียนรู้ของเครื่องเพื่อนำมาแก้ไขปัญหาประเภทการจัดกลุ่ม (Classification) รวมถึงศึกษาอัลกอริทึมต่างๆที่เกี่ยวข้องเพื่อใช้สำหรับสร้างแบบจำลอง
6. รวบรวมค่าพารามิเตอร์ของมอเตอร์(เลขที่ของมอเตอร์ตามที่ได้เลือกในข้อ3.) ที่ถูกบันทึกมาจากเซ็นเซอร์ จากนั้นทำความสะอาดข้อมูล (Data Cleansing) และให้ป้ายฉลากกำกับ (Label) ของค่าพารามิเตอร์ต่างๆ ที่จะส่งผลกระทบต่อระดับความรุนแรงของสุขภาพมอเตอร์เหนี่ยวนำ
7. เลือกอัลกอริทึมที่จะใช้สำหรับการทดลอง
8. สร้างแบบจำลองโดยใช้อัลกอริทึมที่เลือกมา โดยแบ่งข้อมูลจากประวัติเดิมออกเป็นชุดข้อมูล ประกอบด้วย ชุดข้อมูลการฝึก (Training Set), ชุดข้อมูลชีว (Cross validation) และชุดข้อมูลทดสอบ (Test Set) โดยใช้ชุดข้อมูลการฝึกในการสร้างแบบจำลอง และทำการปรับค่าภายในแบบจำลองให้เหมาะสมเพื่อให้ได้ค่าความถูกต้องของการพยากรณ์ที่เหมาะสมที่สุดกับชุดข้อมูล
9. เลือกแบบจำลองจากผลของการทดสอบโดยชุดข้อมูลชีว
10. นำชุดข้อมูลทดสอบที่เหลือคือชุดข้อมูลทดสอบมาใช้ประเมินผลอีกครั้งสำหรับใช้เป็นการประเมินผลสุทธิ
11. วิเคราะห์ผลที่ได้จากการทดลอง
12. สรุปผลการดำเนินงานวิจัยและข้อเสนอแนะเพิ่มเติม
13. จัดทำรูปเล่มวิทยานิพนธ์

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### 2.1 ทฤษฎีที่เกี่ยวข้อง

งานวิจัยฉบับนี้ได้ศึกษาทฤษฎีและนำเสนอแนวทางการสร้างแบบจำลองในการประเมินผลระดับความรุนแรงหรือดัชนีสุขภาพของมอเตอร์เหนี่ยวนำโดยประยุกต์ใช้การเรียนรู้ของเครื่อง ซึ่งมีทฤษฎีและงานวิจัยที่เกี่ยวข้องกับงานวิจัยฉบับนี้ ดังต่อไปนี้

##### 2.1.1 ประเภทของการบำรุงรักษา

โดยทั่วไปแล้วได้แบ่งประเภทของการบำรุงรักษาออกเป็น 4 ประเภท ประกอบด้วย

- การบำรุงรักษาโดยการซ่อมแซมเมื่อเสีย (Breakdown Maintenance)
- การบำรุงรักษาเชิงป้องกัน (Preventive Maintenance: PM)
- การบำรุงรักษาเชิงพยากรณ์ (Predictive Maintenance : PdM)
- การบำรุงรักษาเชิงรุก (Proactive Maintenance)

##### 1. การบำรุงรักษาโดยการซ่อมแซมเมื่อเสีย (Breakdown Maintenance)

การบำรุงรักษาวิธีนี้ถือได้ว่าเป็นแนวคิดในงานการบำรุงรักษาที่เก่าแก่ บางครั้งการบำรุงรักษาประเภทนี้ถูกนิยามว่าเป็นการดำเนินการโดยไร้การบำรุงรักษา เพราะในความเป็นจริงฝ่ายซ่อมบำรุงจะไม่ต้องปฏิบัติงานใดๆเลยจนกว่าจะมีรายงานว่าเครื่องจักรชำรุดใช้งานต่อไปไม่ได้ อย่างไรก็ตามการบำรุงรักษาประเภทนี้ก็ยังคงมีใช้ในบางสถานการณ์ เช่น เมื่อเกิดการพังเสียหายของเครื่องจักรโดยไม่มีสัญญาณใดๆบอกที่จะเป็นการเตือนล่วงหน้าเมื่อเครื่องจักรเริ่มชำรุด

##### 2. การบำรุงรักษาเชิงป้องกัน (Preventive Maintenance: PM)

เป็นการบำรุงรักษาก่อนที่อุปกรณ์จะชำรุดเสียหาย กล่าวคือทำการ “เปลี่ยน” หรือ “บำรุงรักษา” เพื่อ “ป้องกัน” ความเสียหายที่อาจจะเกิดขึ้น โดยการบำรุงรักษาในลักษณะนี้จะมีการตั้งชั่วโมงการทำงาน เช่น ใช้งานไปแล้วก็ชั่วโมงจึงจะมีการหยุดเพื่อการบำรุงรักษา โดยส่วนใหญ่มักจะใช้เวลาเป็นตัวกำหนดในการซ่อม แต่ปัญหาที่อาจเกิดขึ้นได้ในการบำรุงรักษาชนิดนี้คือเหตุการณ์ที่ถูกระบุให้ทำในแผนการบำรุงรักษาเชิงป้องกัน เกิดขึ้นก่อนเวลาที่ตั้งไว้ เช่น การพังเสียหายของอุปกรณ์ก่อนถึงรอบในการเปลี่ยน เป็นต้น

##### 3. การบำรุงรักษาเชิงพยากรณ์ (Predictive Maintenance : PdM)

การบำรุงรักษาลักษณะนี้ นอกจากการตั้งเวลาในการเข้าตรวจสอบแล้ว ยังนำผลการตรวจวัดที่ได้ ไปวิเคราะห์หาปัญหาที่อาจจะเกิดขึ้น เพื่อหาแนวทางในการป้องกันความเสียหายที่คาดว่าจะเกิดขึ้นได้ ข้อดีคือช่วยให้เราทราบถึงประวัติของมอเตอร์และแนวโน้มของปัญหาที่จะเกิดหรือเคยเกิดขึ้นในอดีต รวมถึงการวางแผนแก้ไขในระยะยาวเพื่อลดปัญหาการหยุดเดินของมอเตอร์โดยไม่จำเป็น

#### 4. การบำรุงรักษาเชิงรุก (Proactive Maintenance)

เป็นการบำรุงรักษาที่มุ่งเน้นการพิจารณาที่รากของปัญหา (Root Causes Failure) โดยนำเอาข้อบกพร่องที่ตรวจพบไปทำการวิเคราะห์หาสาเหตุที่แท้จริงของปัญหาซึ่งกระทำการโดยผู้เชี่ยวชาญที่มีประสบการณ์ แล้วนำข้อมูลที่ได้ไปปรับปรุงเครื่องจักรหรือหาวิธีป้องกันไม่ให้เกิดเหตุการณ์เหล่านั้นซ้ำขึ้นอีกหรือทำให้เกิดขึ้นซ้ำน้อยที่สุด เป็นต้น (ประดิษฐ์ หมู่เมืองสอง, 2013)

#### 2.1.2 การบำรุงรักษาแบบพยากรณ์ตามสภาพสำหรับกลุ่มเครื่องจักรหมุน (Rotating Machine)

กลุ่มเครื่องจักรหมุนในโรงงานอุตสาหกรรมทั่วไป ประกอบด้วย เครื่องสูบลม (Pump), มอเตอร์ไฟฟ้า (Motor), เครื่องอัดลม (Blower), พัดลม (Fan), กังหัน (Turbine), เครื่องกำเนิดไฟฟ้า (Generator), ชุดเกียร์ (Gearbox) เป็นต้น โดยทั่วไปแล้วเทคนิคการบำรุงรักษาแบบตามสภาพที่เหมาะสม ประกอบด้วย

##### 1. การวิเคราะห์ความสั่นสะเทือน (Vibration Analysis)

ซึ่งปัญหาของเครื่องจักรกลหมุนหลายรูปแบบจะถูกวิเคราะห์ออกมาได้จากการเฝ้าระวัง ด้วยการตรวจวัดการสั่นสะเทือน จากปัญหาที่แสดงออกมาในรูปแบบทางกล ที่จะส่งผลกระทบต่อ การสูญเสียพลังงานและสมรรถนะการทำงานของเครื่องจักรที่ลดลง ปัญหาที่สามารถตรวจพบได้จากการผิดปกติของค่าความสั่นสะเทือน เช่น การไม่สมดุล (Unbalance), การเยื้องแกนเพลลา (Misalignment), การหลวมคลอนทางกล (Mechanical Looseness), การชำรุดของฟันเกียร์ (Gear Tooth Defect), การชำรุดของตลับลูกปืน (Bearing Defect) การคดของเพลลา (Bent Shaft) เป็นต้น (ประดิษฐ์ หมู่เมืองสอง, 2013)

##### 2. การตรวจสภาพความร้อน (Thermal Monitoring)

โดยทั่วไปเมื่อเครื่องจักรทำงานอยู่ในสภาวะปกติ จะต้องมีความร้อนเกิดขึ้น เรียกว่าอุณหภูมิการทำงานปกติของเครื่องจักร แต่เมื่ออุณหภูมิเปลี่ยนแปลงไปจากเดิมที่เป็นอยู่ แสดงถึงเป็นไปได้ที่จะเกิดความผิดปกติบางอย่างขึ้นกับเครื่องจักรนั้นๆ จุดที่นิยมทำการตรวจวัดความร้อนของเครื่องจักรกลหมุนคือตัวเรือนของแบร์ริง (Bearing Housing) หรือตำแหน่งที่มีการเสียดสีกันมาก

ที่สุด หรือตรวจวัดอุณหภูมิของสารหล่อลื่นภายในเครื่องจักร เช่น ภายในกล่องเกียร์ (Gearbox) เป็นต้น

### 3. การวิเคราะห์น้ำมันหล่อลื่น (Oil Analysis)

เพราะน้ำมันหล่อลื่นเปรียบเสมือนเลือดที่สูบฉีดไหลเวียนไปหล่อเลี้ยงส่วนต่างๆ ของเครื่องจักร ซึ่งการตรวจวิเคราะห์คุณภาพน้ำมันจะสามารถบ่งชี้สมรรถนะและสภาพของเครื่องจักร เพื่อเพิ่มความพร้อมในการทำงานของเครื่องจักรและช่วยประหยัดค่าใช้จ่ายในการบำรุงรักษาที่เกิดจากน้ำมันหล่อลื่น ความสูญเสียโอกาสจากการหยุดเดินเครื่องของเครื่องจักร และอื่นๆ การตรวจวิเคราะห์น้ำมันหลังการใช้งาน (Used Oil Analysis) สามารถบอกถึงสมรรถนะ หรือสภาพของเครื่องจักรและอุปกรณ์ สภาวะการสึกหรอ การเสื่อมสภาพของน้ำมันหล่อลื่นและสิ่งสกปรกปนเปื้อนต่างๆ โดยการนำตัวอย่างน้ำมันหล่อลื่นที่ใช้งานแล้วไปวิเคราะห์ เพื่อตรวจสอบความหนืด จุดวาบไฟ ปริมาณเศษโลหะ เช่น เหล็ก ตะกั่ว ทองแดง โครเมียม ที่ผสมหรือปะปนในสารหล่อลื่นที่ใช้แล้ว เพราะเศษโลหะเหล่านี้จะบ่งบอกถึงการสึกหรอของชิ้นส่วนต่างๆ เป็นต้น (พาราติน, 2017)

### 4. การวิเคราะห์การไหล (Flow Analysis)

การวิเคราะห์การไหลเป็นการวัดอัตราการไหลที่มีอยู่ในระบบทั้งหมด เพื่อจะสามารถประเมินสมรรถนะและข้อบกพร่องรวมของระบบได้ เช่น ประสิทธิภาพและสมรรถนะการทำงานของเครื่องสูบลม การอุดตันของระบบท่อต่างๆ เป็นต้น

### 5. การวิเคราะห์คลื่นเสียง (Sound Analysis)

เป็นการใช้คลื่นเสียงเพื่อตรวจวัดสิ่งผิดปกติภายในชิ้นส่วน หรือการตรวจรับด้วยคลื่นเสียงความถี่สูงเพื่อหาความผิดปกติของอุปกรณ์ เป็นต้น

### 6. การตรวจวัดรังสีความร้อนด้วยกล้องอินฟราเรด (Thermal Infrared Testing)

ส่วนใหญ่แล้วการติดตามสภาพความร้อนที่ใช้งานในปัจจุบันจะใช้ภาพถ่ายที่แสดงความแตกต่างของอุณหภูมิที่ผิวเรียกว่าภาพถ่ายความร้อนเป็นที่รู้จักกันในชื่อเทอร์โมกราฟี (Thermal Imager) จะอาศัยหลักการแผ่รังสีอินฟราเรดที่ออกจากวัตถุ ซึ่งเป็นการวัดอุณหภูมิแบบไม่สัมผัสและไม่ทำลายวัตถุ และเป็นการวัดอุณหภูมิแบบพื้นที่ ซึ่งจะช่วยให้ตรวจหาปัญหาหรือความเสียหายที่อาจเกิดขึ้นได้อย่างรวดเร็ว ทำให้สามารถลดเวลาในการแก้ไขปัญหาและการบำรุงรักษาได้ เป็นต้น

## 2.1.3 การวิเคราะห์ความสั่นสะเทือน (Vibration Analysis)

การวิเคราะห์การสั่นสะเทือนเป็นกระบวนการที่ตรวจสอบระดับการสั่นสะเทือนและตรวจสอบรูปแบบในสัญญาณการสั่นสะเทือน โดยทั่วไปจะดำเนินการทั้งในรูปแบบคลื่นเวลา (Time

waveform) ของสัญญาณการสั่นสะเทือนโดยตรง เช่นเดียวกับในสเปกตรัมความถี่ (Frequency Spectrum) ซึ่งได้มาจากการใช้การแปลงฟูเรียร์ (Fourier Transform) ของรูปคลื่นเวลา

การสั่นสะเทือน (Vibration) คือการเคลื่อนที่ของวัตถุในลักษณะการแกว่งหรือการสั่นของวัตถุรอบๆจุดสมดุลเมื่อสมดุลนั้นถูกรบกวน การสั่นสะเทือนสามารถแสดงได้ในรูปแบบต่างๆ รวมถึงการกระจัด (Displacement) ความเร็ว (Velocity) และความเร่ง (Acceleration)

#### 2.1.3.1 การวัดการสั่นสะเทือน

##### 1. การวัดระยะทาง (Displacement)

- เป็นการวัดระยะทางของการเคลื่อนที่ของวัตถุที่มีการเคลื่อนที่ไปจากจุดอ้างอิง ด้วยระยะทางเท่าใดในการสั่นสะเทือนแต่ละรอบ

- หน่วยที่นิยมใช้ในการวัดคือมิลลิเมตร (mm) หรือนิ้ว (inch)
- ลักษณะการวัดรูปแบบเต็มคลื่น (Peak to Peak)
- ใช้กับการวัดการเคลื่อนที่ที่มีความเร็วรอบไม่เกิน 1200 rpm หรือ

20Hz

##### 2. การวัดความเร็ว (Velocity)

- เป็นการวัดความเร็วในการเคลื่อนที่ของวัตถุที่สั่นสะเทือนว่า มีความเร็วเท่าไรในแต่ละรอบของการสั่นสะเทือน

- โดยปกตินิยมวัดในหน่วยเป็นมิลลิเมตร/วินาที (mm/s) และนิ้ว/วินาที (inch/sec) ในการวัดความเร็วเรามักจะวัดแบบค่าเฉลี่ยกำลังสอง (Root mean square - RMS)

- นิยมใช้กับการวัดการสั่นสะเทือนที่มีความถี่ระหว่าง 20Hz -1,000Hz

##### 3. การวัดอัตราเร่ง (Acceleration)

- เป็นการวัดการเปลี่ยนแปลงอัตราส่วนของความเร็วในการเคลื่อนที่ต่อหน่วยเวลาของวัตถุที่มีการสั่นสะเทือน

- ใช้สำหรับวัดการสั่นสะเทือนที่ความถี่สูงคือตั้งแต่ 10,000 Hz ขึ้นไป
- การสั่นสะเทือนที่ความถี่สูงนั้นระยะทางการเคลื่อนที่จะน้อยและในขณะเดียวกันความเร็วในการเคลื่อนที่จะสูงมากจึงนิยมเปลี่ยนรูปแบบการวัดมาเป็นในลักษณะการวัดอัตราเร่ง และถูกนำไปใช้อย่างกว้างขวางสำหรับการวิเคราะห์ข้อบกพร่องแบบพลวัต (Dynamic)

การวัดการสั่นสะเทือนสามารถวัดผ่านเซ็นเซอร์ประเภทต่างๆ ตามประเภทของการสั่นสะเทือน มีเซ็นเซอร์ที่ออกแบบมาเพื่อวัดการกระจัด ความเร็ว และความเร่ง ด้วยเทคโนโลยีการวัดที่แตกต่างกัน เช่น เซ็นเซอร์เพียโซอิเล็กทริก (Piezoelectric - PZT), เซ็นเซอร์ไมโครไฟฟ้า

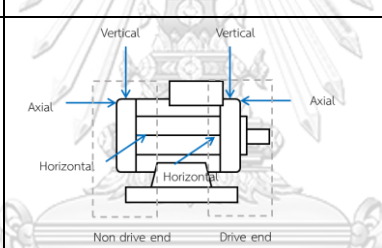
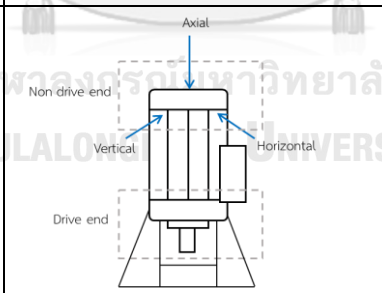
เครื่องกล (Microelectromechanical Sensors - MEMS), หัววัดระยะใกล้ (Proximity Probes), เลเซอร์ดอปเพลอร์ไวบ्रोมิเตอร์ (Laser Doppler Vibrometer) และอื่นๆ อีกมากมาย

การติดตั้งเซ็นเซอร์มีความสำคัญอย่างยิ่งต่อการบันทึกข้อมูลคุณภาพสูง วิธีการที่แนะนำสำหรับการติดตั้งเซ็นเซอร์คือการติดตั้งเซ็นเซอร์แบบสตั๊ด (Stud Mount) บนพื้นผิวที่เรียบและสะอาดบนตัวเครื่อง เพื่อให้แน่ใจว่าได้บันทึกสเปกตรัมความถี่ที่กว้างและราบรื่น

### 2.1.3.2 วิธีการและตำแหน่งในการวัด

จุดที่จะทำการตรวจวัดในเครื่องจักรกลที่ประเภทหรือรูปแบบที่ต่างจากกัน จะเป็นในลักษณะเดียวกัน ดังแสดงในตารางที่ 7

ตารางที่ 7 ตำแหน่งในการตรวจวัดค่าความสั่นสะเทือน

รูปแบบการติดตั้ง เครื่องจักร	ตำแหน่งการวัด	หน่วยการวัด
- แนวระดับ (Horizontal)		ความเร็ว (Velocity) - mm/s <sub>rms</sub>
		ความเร่ง (Acceleration) - mm/s <sup>2</sup> <sub>rms</sub>
- แนวตั้ง (Vertical)		ระยะทาง (Displacement) - μm/s <sub>rms</sub>

หมายเหตุ : การอ่านค่าอาจแตกต่างกันไปตามแต่ละยี่ห้อของเครื่องมือวัด ในหน่วย peak (pk) , root mean square (r.m.s) หรือ peak to peak (p-p)

### 2.1.3.3 มาตรฐานอ้างอิงที่ใช้ในการประเมินผลค่าความสั่นสะเทือน

ISO 10816-3 กลุ่ม 2 เป็นค่ามาตรฐานที่นำมาใช้สำหรับการประเมินค่าความสั่นสะเทือนของมอเตอร์เหนี่ยวนำที่เลือกมาทำงานวิจัยแสดงดังตารางที่ 8

ตารางที่ 8 อ้างอิงค่าความสั่นสะเทือนจาก ISO 10816-3 กลุ่ม 2 (ISO 10816-3:2009 Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts 2009)

Support class	Zone boundary	R.M.S displacement (um)	R.M.S. Velocity (mm/s)
Rigid	A/B	29	2.3
	B/C	57	4.5
	C/D	90	7.1
Flexible	A/B	45	3.5
	B/C	90	7.1
	C/D	140	11.0

### 2.1.4 การตรวจวัดรังสีความร้อนด้วยกล้องถ่ายภาพความร้อน

#### 2.1.4.1 พื้นฐานภาพถ่ายความร้อน

กล้องถ่ายภาพความร้อน (Thermal Imager หรือ Thermal Image Camera) หรือกล้องถ่ายภาพอินฟราเรด หรือ กล้องอินฟราเรด (Infrared Thermography) เป็นเครื่องมือวัดอุณหภูมิที่ผิวของวัตถุ หลักการทำงานคือตัวเซ็นเซอร์ในกล้องจะรับรังสีอินฟราเรด (Infrared Radiation) ที่แผ่ออกจากวัตถุ ผ่านตัวกล้องแล้วแปลงออกมาเป็นสัญญาณทางไฟฟ้า จากนั้นจะนำสัญญาณไฟฟ้านั้นแปลงผ่านวงจรอิเล็กทรอนิกส์และถูกประมวลผลออกมาทางจอภาพหรือส่วนแสดงผลของตัวกล้องและแบ่งมาตราส่วน (Scale) ค่าอุณหภูมิออกเป็นสีของภาพ ส่วนประกอบสำคัญของกล้องถ่ายภาพความร้อน ประกอบด้วย เลนส์ (Lens) ตัวตรวจจับรังสีอินฟราเรด (Infrared detector) หรือเซ็นเซอร์ชนิดอินฟราเรด (Infrared sensor) วงจรอิเล็กทรอนิกส์ (Electronic circuit) และส่วนแสดงผล (Display)



กล้องถ่ายภาพความร้อนประกอบด้วยเซนเซอร์ชนิดอินฟราเรดหลายตัว แต่ละตัวแสดงผลออกมาในรูปแบบของสีที่แตกต่างกันตามอุณหภูมิของจุดที่ตรวจวัดนั้นๆ โดยทั่วไป สีแดงแสดงผลของบริเวณที่มีอุณหภูมิสูงและสีน้ำเงินแสดงผลของบริเวณที่มีอุณหภูมิต่ำ หรือโทนสีสว่างแสดงผลของบริเวณที่มีอุณหภูมิสูง และโทนสีมืดแสดงผลของบริเวณที่มีอุณหภูมิต่ำ ผลของแต่ละจุดที่ได้จากเซนเซอร์แต่ละตัว เมื่อนำมารวมกันจะประกอบขึ้นเป็นภาพ เรียกว่า "ภาพถ่ายความร้อน (Thermal Image) " ซึ่งการแปลงรังสีอินฟราเรดที่เซนเซอร์ตรวจจับได้ให้อยู่ในหน่วยของอุณหภูมิอาศัยกฎของ Planck (Planck's law) และ กฎของ Stefan-Boltzmann (Stefan-Boltzman's law) (นวกัทร หนูนาค, 2012)

#### 2.1.4.2 เกณฑ์มาตรฐานสากลในการตรวจสอบภาพถ่ายความร้อน

เกณฑ์ที่ผู้ตรวจภาพถ่ายความร้อนใช้ในการตัดสินใจปัญหาที่เกิดขึ้นจากการถ่ายภาพ จะถูกแบ่งออกเป็นเกณฑ์ตามระดับความรุนแรง ซึ่งเกณฑ์ที่นิยมใช้โดยทั่วไปกำหนดขึ้นจาก 3 แหล่งข้อมูล ดังต่อไปนี้

1. ผู้ตรวจสอบเองเป็นคนกำหนด (Thermographer Inspector)
2. ผู้ผลิตเป็นผู้กำหนด (Manufacturer Specification)
3. หน่วยงานมาตรฐานสากล (International standard) หรือหน่วยงานมาตรฐานระดับชาติ (National standard) กำหนด เช่น กฎหมาย, ระเบียบ หรือ ข้อบังคับ เป็นต้น (Certify Level 1 Infrared Thermographer Book, 2020)

#### 2.1.4.3 มาตรฐานอ้างอิงที่ใช้ในการประเมินผลภาพถ่ายความร้อน


ANSI/NETA MTS-2019 Standard for Maintenance Testing Specifications for Electrical Power Equipment and Systems เป็นมาตรฐานที่นิยมใช้ในการประเมินผลภาพถ่ายความร้อนที่จะเป็นการพิจารณาค่าความแตกต่างระหว่างอุปกรณ์ชนิดเดียวกันภายใต้โหลดใช้งานที่เหมือนหรือคล้ายคลึงกัน หรือพิจารณาจากค่าความแตกต่างอุณหภูมิของอุปกรณ์กับค่าอุณหภูมิแวดล้อม (Ambient air temperature) ตารางค่าความแตกต่างของอุณหภูมิอ้างอิงมาตรฐาน ANSI/NETA MTS-2019 แสดงดังตารางที่ 9

ตารางที่ 9 มาตรฐาน ANSI/NETA MTS-2019 ที่ใช้ในการประเมินผลภาพถ่ายความร้อน  
(ANSI/NETA MTS-2019 Standard for Maintenance Testing Specifications for Electrical  
Power Equipment and Systems 2019)

Temperature difference ( $\Delta T$ ) based on comparisons between similar components under similar loading	Temperature difference ( $\Delta T$ ) based upon comparisons between component and ambient air temperatures	Recommendation Action
1°C - 3°C	1°C - 10°C	Possible deficiency; warrants investigation
4°C - 15°C	11°C - 20°C	Indicates probable deficiency; repair as time permits
....	21°C - 40°C	Monitor until corrective measures can be accomplished
> 15°C	> 40°C	Major discrepancy; repair immediately

### 2.1.5 ผลกระทบที่มีผลต่อมอเตอร์เมื่อแรงดันไฟฟ้าและความถี่เกิดการเปลี่ยนแปลง

โดยทั่วไปแล้วเมื่อเกิดการเปลี่ยนแปลงของแรงดันไฟฟ้าและความถี่จะมีผลต่อสมรรถนะของมอเตอร์โดยตรงซึ่งสามารถอธิบายได้ในรูปที่ 10 ซึ่งได้อธิบายเกี่ยวกับการเปลี่ยนแปลงแรงดันและความถี่ที่มีต่อแรงบิดเริ่มเดิน, กระแสเริ่มเดิน และอื่นๆ



รูปที่ 10 การเปลี่ยนแปลงแรงดันและค่าที่ส่งผลกระทบต่อสมรรถนะของมอเตอร์

#### 2.1.5.1 ผลกระทบต่อมอเตอร์ไฟฟ้ากรณีแรงดันไฟฟ้าไม่อยู่ในเกณฑ์มาตรฐาน

##### 1. กรณีมอเตอร์ทำงานที่แรงดันไฟฟ้าต่ำกว่าปกติ

เมื่อมีการใช้งานมอเตอร์ในสภาวะแรงดันไฟฟ้าต่ำกว่าปกติจะมีผลทำให้กระแสไฟฟ้าที่ป้อนให้มอเตอร์เพิ่มขึ้น ซึ่งจะทำให้เกิดความร้อนเพิ่มขึ้นในขดลวดสเตเตอร์และโรเตอร์ ซึ่งจากผลดังกล่าวจะทำให้อุณหภูมิของขดลวดสูงขึ้นและจะทำให้ความเป็นฉนวนของขดลวดลดลงและมีอายุการใช้งานสั้นลงที่สุดในที่สุด อย่างไรก็ตามถ้ามอเตอร์มีการใช้งานไม่หนักหรือมีโหลดน้อย การเพิ่มขึ้นของกระแสไฟฟ้าที่มีผลจากการลดลงของแรงดันไฟฟ้าก็จะมีค่าต่ำกว่ากระแสปกติของมอเตอร์ ซึ่งจากผลดังกล่าวก็จะไม่ทำให้เกิดความร้อนหรืออุณหภูมิที่ขดลวดมอเตอร์สูงขึ้นแต่อย่างใด

สำหรับกรณีซึ่งโครงข่ายมอเตอร์ที่มีการใช้ไฟฟ้ากระแสตรง (DC) ที่ถูกแปลงจากแหล่งไฟฟ้ากระแสสลับเดียวกับแหล่งจ่ายไฟฟ้ากระแสสลับ 3 เฟส ที่ป้อนให้มอเตอร์ไฟฟ้า ในกรณีที่เกิดแรงดันต่ำกว่าปกติ ก็จะเป็นสาเหตุให้แรงดันไฟฟ้ากระแสตรงต่ำกว่าปกติไปด้วย จากผลดังกล่าวก็จะทำให้สนามแม่เหล็กไฟฟ้าที่ถูกสร้างขึ้นก็จะลดลงตามไปด้วย ซึ่งจะทำให้มีผลต่อการทำงานของมอเตอร์โดยตรง

##### 2. กรณีมอเตอร์ทำงานที่แรงดันไฟฟ้าสูงกว่าปกติ

เมื่อมอเตอร์มีการใช้งานที่แรงดันไฟฟ้าสูงกว่าปกติ กระแสไฟฟ้าในขดลวดของสเตเตอร์จะมีค่าลดลง และถ้าแรงดันที่ป้อนให้มอเตอร์มีค่าสูงเพียงพอ ก็อาจจะทำให้สนามแม่เหล็กไฟฟ้าของแกนเหล็กเกิดการอิ่มตัวได้ จากการเกิดเหตุการณ์ดังกล่าวขึ้นก็จะส่งผลให้

กระแสไฟฟ้ากระตุ้น (Exciting Current) มีค่าสูงขึ้นเป็นอย่างมาก ก็จะมีผลทำให้เกิดความร้อนสูงในขดลวด ซึ่งโดยทั่วไปแล้วการเกิดสนามแม่เหล็กไฟฟ้าอิมตัวอาจจะเกิดขึ้นที่แรงดันไฟฟ้าสูงกว่าพิกัดประมาณ 110 เปอร์เซ็นต์

เพื่อให้่ายต่อการคำนวณ จึงสมมติให้ค่ากำลังโหลดของเพลลา (Shaft-Power Load) มีค่าคงที่และจะไม่นำผลการสูญเสียภายในมอเตอร์มาพิจารณา ดังนั้นกำลังไฟฟ้าขาเข้าของมอเตอร์จึงมีค่าเท่ากับกำลังโหลดขาออกของเพลลา ดังแสดงในสมการ

$$\sqrt{3}V_{\text{line}}I_{\text{line}}F_p = HP_{\text{shaft}} \times 746 \quad (1)$$

เมื่อค่ากำลังโหลดของเพลลามีค่าคงที่ กำลังไฟฟ้าขาเข้าที่ป้อนให้มอเตอร์ที่มีค่าสูงกว่าพิกัดจะสามารถประมาณค่าได้เท่ากับค่ากำลังไฟฟ้าขาเข้าที่แรงดันไฟฟ้าตามพิกัด โดยจะไม่พิจารณาผลของการเปลี่ยนแปลงของแรงลมและความฝืด (Windage and Friction) ซึ่งจะมีผลเพียงเล็กน้อยต่อความเร็วของมอเตอร์ไฟฟ้า ดังนั้นจึงได้แสดงตามสมการ

$$\sqrt{3}V_2I_2F_p \approx \sqrt{3}V_{\text{rated}}I_{\text{rated}}F_p \quad (2)$$

เมื่อไม่นำค่าตัวประกอบ (Power Factor) มาประกอบการพิจารณา ดังนั้นจะได้สมการของกระแสไฟฟ้าเมื่อแรงดันไฟฟ้าสูงกว่าพิกัด ดังต่อไปนี้

$$I_2 \approx \frac{V_{\text{rated}}I_{\text{rated}}}{V_2} \quad (3)$$

เมื่อ	$I_2$	= กระแสไฟฟ้าเมื่อแรงดันไฟฟ้าสูงกว่าพิกัด (A)
	$I_{\text{rated}}$	= กระแสไฟฟ้าพิกัดของมอเตอร์ (A)
	$V_{\text{rated}}$	= แรงดันไฟฟ้าพิกัดของมอเตอร์ (V)
	$V_2$	= แรงดันไฟฟ้าสูงกว่าพิกัดของมอเตอร์ (V)

#### 2.1.5.2 ผลกระทบต่อมอเตอร์ไฟฟ้ากรณีความถี่ไม่อยู่ในเกณฑ์มาตรฐาน

การที่เกิดความถี่ลดลงจะทำให้กระแสไฟฟ้ากระตุ้นมีค่าสูงขึ้น(ซึ่งเป็นส่วนประกอบในสถานะไม่มีโหลดของกระแสไฟฟ้าของมอเตอร์) ด้วยเหตุนี้ก็จะทำให้กระแสไฟฟ้าโดยรวมของ

มอเตอร์มีค่าสูงขึ้น และถ้าความถี่มีค่าต่ำมากก็อาจจะเป็นสาเหตุให้เกิดสนามแม่เหล็กไฟฟ้าในแกนเหล็กเกิดการอิ่มตัวได้เช่นกัน และก็จะทำให้เกิดกระแสไฟฟ้ากระตุ้นมีค่าพุ่งสูงขึ้นเป็นอย่างมาก ก็จะทำให้ขดลวดของมอเตอร์มีอุณหภูมิสูงกว่าปกติได้เช่นกัน

### 1. เปอร์เซ็นต์ความร้อนที่เพิ่มขึ้นเนื่องจากกระแสไฟฟ้าเกินพิกัด

เปอร์เซ็นต์ของความร้อนที่เกิดขึ้นของขดลวดในมอเตอร์เนื่องจากกระแสไฟฟ้าเกินพิกัดนั้น ส่วนใหญ่ก็จะมีสาเหตุมาจาก แรงดันไฟฟ้า และความถี่ที่ป้อนให้มอเตอร์ไม่อยู่ในเกณฑ์มาตรฐานของพิกัด หรืออาจจะเกิดจากการใช้โหลดเกินพิกัดก็ได้ ซึ่งเราสามารถคำนวณหาได้ดังต่อไปนี้ (ยูทอร์พังก์, 2019)

$$\% \text{heating} \approx \left[ \frac{I_2}{I_{\text{rated}}} \right]^2 \times 100 \quad (4)$$

เมื่อ  $I_2$  = ค่ากระแสไฟฟ้าที่เกิดขึ้นเมื่อแรงดันไฟฟ้ามีค่าเกินพิกัด

## 2.1.6 การแยกประเภทความล้มเหลว (Failure Mode) ของมอเตอร์ไฟฟ้า

1. อ้างอิงประเภทความล้มเหลวของมอเตอร์ไฟฟ้า ตามมาตรฐาน ISO14224:2016 Petroleum, petrochemical and natural gas industries — Collection and exchange of reliability and maintenance data for equipment แสดงดังตารางที่ 10

ตารางที่ 10 ประเภทความล้มเหลวจากมอเตอร์ไฟฟ้า (ISO 14224:2016 Petroleum, petrochemical and natural gas industries — Collection and exchange of reliability and maintenance data for equipment, 2016)

Table B.6 — Rotating equipment — Failure modes


Failure mode code	Description	Equipment class code	CE	CO	EG	EM	GT	PU	ST	TE
		Examples	Combustion engines	Compressors	Electric generators	Electric motors	Gas turbines	Pumps	Steam turbines	Turbo-expanders
AIR	Abnormal instrument reading	False alarm, faulty instrument indication	X	X	X	X	X	X	X	X
BRD	Breakdown	Serious damage (seizure, breakage)	X	X	X	X	X	X	X	X
ERO	Erratic output	Oscillating, hunting, instability	X	X		X	X	X	X	X
ELF	External leakage - fuel	External leakage of supplied fuel/gas	X				X		X	
ELP	External leakage - process medium	Oil, gas, condensate, water		X			X	X	X	X
ELU	External leakage - utility medium	Lubricant, cooling water	X	X	X	X	X	X	X	X
FTS	Failure to start on demand	Doesn't start on demand	X	X	X	X	X	X	X	X
HIO	High output	Overspeed/output above acceptance	X	X		X	X	X	X	X
INL	Internal leakage	Leakage internally of process or utility fluids	X	X			X	X	X	X
LOO	Low output	Delivery/output below acceptance	X	X	X	X	X	X	X	X
NOI	Noise	Abnormal noise	X	X	X	X	X	X	X	X
OHE	Overheating	Machine parts, exhaust, cooling water	X	X	X	X	X	X	X	X
PDE	Parameter deviation	Monitored parameter exceeding limits, e.g. high/low alarm	X	X	X	X	X	X	X	X
PLU	Plugged/ choked	Flow restriction(s)	X	X			X	X	X	X
SER	Minor in-service problems	Loose items, discoloration, dirt	X	X	X	X	X	X	X	X
STD	Structural deficiency	Material damages (cracks, wear, fracture, corrosion)	X	X	X	X	X	X	X	X
STP	Failure to stop on demand	Doesn't stop on demand	X	X	X	X				
OTH	Other	Failure modes not covered above	X	X	X	X	X	X	X	X
UNK	Unknown	Too little information to define a failure mode	X	X	X	X	X	X	X	X
UST	Spurious stop	Unexpected shutdown	X	X	X	X	X	X	X	X
VIB	Vibration	Abnormal vibration	X	X	X	X	X	X	X	X

2. อ้างอิงประเภทความล้มเหลวของมอเตอร์จากอุตสาหกรรมกรณีศึกษาประกอบด้วย

- สเตอ์เตอร์เสียหาย (ไหม้)
- โรเตอร์เสียหาย (สึกหรอและแตกหัก)
- ตลับลูกปืนเสียหาย (สึกหรอและแตกหัก)
- ก่อ่งเทอมินอลเสียหาย (ไหม้)
- ก่อ่งเทอมินอล (ซีลเสียหาย)
- พัฒลระบายความร้อนเสียหาย (สึกหรอและแตกหัก)

### 2.1.7 เมตริกที่ใช้สำหรับตรวจสอบความพร้อมทำงานของระบบ

เมตริกที่ตรวจสอบความพร้อมทำงานของระบบการหยุดทำงานเนื่องจากการหยุดทำงานและวิธีการแก้ไขปัญหาที่รวดเร็วและมีประสิทธิภาพหรือดัชนีตัวชี้วัดในงานบริหารงานซ่อมบำรุง ประกอบด้วย ค่าเวลาเฉลี่ยก่อนการเสียหาย เวลาเฉลี่ยในการซ่อมแซม ระยะเวลาเฉลี่ยก่อนการเสียหายแต่ละครั้ง (Mean Time Between Failures – MTBF) เป็นต้น โดยคาบเวลาที่เป็นคาบเกี่ยวของเมตริกได้แสดงดังรูปที่ 11 (นายช่างมาแซร์, 2020)



รูปที่ 11 เมตริกที่ใช้ตรวจสอบความพร้อมทำงานของงานบริหารงานซ่อมบำรุง (นายช่างมาแซร์, 2020)

#### 2.1.7.1 ค่าเวลาเฉลี่ยก่อนการเสียหาย (Mean Time to Failure: MTTF)

เป็นเวลาที่เครื่องจักรสามารถทำงานได้ปกติ ก่อนที่จะเกิดความเสียหาย ค่า MTTF ยิ่งมากยิ่งดี

$$MTTF = \frac{\text{เวลาที่เครื่องจักรทำงานได้ก่อนการล้มเหลว}}{\text{จำนวนครั้งที่เครื่องจักรล้มเหลว}} \quad (5)$$

### 2.1.7.2 เวลาเฉลี่ยในการซ่อมแซม (Mean Time to Repair : MTTR)

คือ ระยะเวลาเฉลี่ยที่ต้องใช้ในการซ่อมแซมเพื่อให้กลับคืนสู่สภาวะปกติ โดยที่ MTTR จะเริ่มขึ้นเมื่อการซ่อมแซมเริ่มขึ้นและจะดำเนินต่อไปจนกว่าการที่หยุดชะงักจะได้รับการกู้คืนอย่างสมบูรณ์รวมถึงเวลาทดสอบที่จำเป็น เพื่อบอกถึงเวลาโดยเฉลี่ยที่ใช้ในการหยุดทำงานแต่ละครั้ง ค่า MTTR ยิ่งน้อยยิ่งดี

$$MTTR = \frac{\text{เวลาทั้งหมดที่ใช้ในการซ่อมแซม}}{\text{จำนวนการซ่อมแซม}} \quad (6)$$

### 2.1.7.3 ดัชนีความพร้อมใช้งาน (Availability)

คือ ค่าความพร้อมใช้งานของเครื่องจักร/อุปกรณ์

$$Availability = \frac{MTTF}{MTTF + MTTR} \times 100 \quad (7)$$

## 2.1.8 ปัญญาประดิษฐ์ (Artificial Intelligence : AI) และการเรียนรู้ของเครื่อง (Machine Learning)

ปัญญาประดิษฐ์ (Artificial Intelligence : AI) เป็นศาสตร์แขนงหนึ่งที่ทำการศึกษาวิจัยและพัฒนาคอมพิวเตอร์ให้มีความสามารถอันชาญฉลาด เช่น การสร้างหุ่นยนต์ การสร้างระบบประสาทรับรู้เลียนแบบมนุษย์ สร้างระบบการมองเห็นภาพ การประมวลผลภาษาธรรมชาติของมนุษย์ เป็นต้น ส่วนการเรียนรู้ของเครื่อง (Machine Learning) เป็นสาขาย่อยแขนงหนึ่งของปัญญาประดิษฐ์ (กอบเกียรติ, 2020)


การเรียนรู้ของเครื่อง (Machine Learning) หมายถึง การให้เครื่อง (ในที่นี้หมายถึงเครื่องคำนวณที่สามารถทำงานตามชุดคำสั่งได้ เช่น คอมพิวเตอร์) เรียนรู้งานใดงานหนึ่ง (Task) จากตัวอย่างหรือประสบการณ์จำนวนหนึ่ง เพื่อให้ทำงานนั้นได้อย่างมีประสิทธิภาพ อีกทั้งยังสามารถเพิ่มประสิทธิภาพได้จากการเรียนรู้จากตัวอย่างหรือประสบการณ์ที่เพิ่มขึ้นได้

การเรียนรู้ของเครื่อง เป็นเครื่องมือของปัญญาประดิษฐ์ที่มุ่งเน้นในการใช้ตัวอย่างหรือประสบการณ์เพิ่มการเรียนรู้ โดยมนุษย์มีส่วนร่วมเพียงการออกแบบระบบเท่านั้น หลังจากนั้นระบบจะสกัดสาระสำคัญจากตัวอย่างเหล่านี้เอง หลังจากการเรียนรู้เสร็จสิ้นด้วยตัวอย่างจำนวนหนึ่งอย่างเพียงพอ เครื่องหรือระบบที่เรียนรู้แล้วนี้ สามารถนำไปใช้ในการประมวลผลของตัวอย่างใหม่ที่ไม่เคยพบมาก่อนได้อย่างมีประสิทธิภาพ (ปริญญา, 2019)

### 2.1.8.1 ประเภทของการเรียนรู้ของเครื่อง ประกอบด้วย

- เรียนรู้โดยมีผู้สอน (Supervised Learning)
- เรียนรู้โดยไม่มีผู้สอน (Unsupervised Learning)
- เรียนรู้ด้วยการป้อนกลับผลลัพธ์ (Reinforcement Learning)

ประเภทของการเรียนรู้ของเครื่อง แสดงดังรูปที่ 12



รูปที่ 12 ประเภทของการเรียนรู้ของเครื่อง (วิธาน, 2018)

#### 1. การเรียนรู้แบบมีการสอน (Supervised Learning)

เป็นการเรียนรู้แบบที่ต้องมีการสอน (Train) คือให้คอมพิวเตอร์เรียนรู้จากข้อมูลที่เข้าไปสอน (ข้อมูลที่นำเข้าไปสอน เรียกว่าชุดข้อมูลสอน)

อัลกอริทึมจำเป็นต้องใช้ข้อมูลในส่วนสำหรับฝึกฝน (Training data) และส่วนที่รับกลับมาเพื่อปรับปรุง (Feedback) จากมนุษย์เพื่อที่จะเรียนรู้ความสัมพันธ์ระหว่างข้อมูลที่ถูกป้อนเข้ามาสู่ข้อมูลที่ออกไป เราสามารถใช้เมื่อผลลัพธ์ของข้อมูลเป็นสิ่งที่รู้อยู่แล้ว อัลกอริทึมนี้ก็จะทำนายข้อมูลใหม่ได้

หลักการของการเรียนรู้แบบมีการสอน สามารถนำไปประยุกต์ใช้และแก้ไขปัญหาได้ 2 รูปแบบคือการถดถอย (Regression) ทำนายผลลัพธ์ที่เป็นจำนวนจริง และการจัดกลุ่ม (Classification) ทำนายผลลัพธ์เพื่อแยกกลุ่มข้อมูล

อัลกอริทึมของการเรียนรู้แบบมีการสอน ประกอบด้วย



1. การถดถอยเชิงเส้น (Linear Regression)
2. การถดถอยโลจิสติก (Logistic Regression)
3. โครงข่ายประสาทเทียม (Artificial Neural Network : ANN)
4. Support Vector Machine (SVM)
5. Classification and Regression Tree (CART)
6. Naïve Bayes
7. K-nearest Neighbors (KNN)
8. ป่าไม้สุ่ม (Random Forest)
9. อื่นๆ

## 2. การเรียนรู้แบบไม่มีการสอน (Unsupervised Learning)

เป็นการเรียนรู้แบบที่ไม่ต้องมีการสอน ไม่จำเป็นต้องใช้ข้อมูลที่มีเอาต์พุต (Output) ในทางเทคนิคเรียกว่าไม่ต้องมีข้อมูลป้ายหรือเป้าหมาย จึงเรียกว่าการเรียนรู้แบบไม่มีการสอน ลักษณะการทำงานคือป้อนข้อมูลที่ต้องการทำนาย จากนั้นระบบจะทำการประมวลผลข้อมูลให้เอง

การเรียนรู้ประเภทนี้แบ่งออกเป็น การจัดกลุ่ม (Clustering) และการหาความสัมพันธ์ (Association)

อัลกอริทึมของการเรียนรู้แบบไม่ต้องการสอน ประกอบด้วย

1. K-means Clustering
  2. Hierarchical Clustering
  3. Autoencoders (Artificial Neural Network)
  4. Local Outlier Factor (Anomaly Detection)
  5. Principal Component Analysis (PCA)
  6. Non-negative Matrix Factorization
  7. Density-Based Spatial Clustering of Applications with Noise (DBSCAN)
  8. Expectation-Maximization Algorithm
  9. อื่นๆ (นันทชัย, 2021)
- ## 3. การเรียนรู้ด้วยการป้อนกลับผลลัพธ์ (Reinforcement Learning)

เป็นระบบการเรียนรู้ที่อาศัยการป้อนกลับแล้วให้ระบบเรียนรู้แล้วปรับปรุงตัวเอง เช่น ระบบการทรงตัวของหุ่นยนต์ เริ่มแรกตัวหุ่นอาจล้มในตอนแรกๆ ระบบจะทำการป้อนกลับแล้วนำค่าข้อมูลต่างๆในการทรงตัวมาปรับปรุงตัวเอง จนในที่สุดสามารถทรงตัวได้อย่างเสถียรภาพ เป็นต้น

ตามหลักของการเรียนรู้ที่อาศัยการป้อนกลับผลลัพธ์จะมีการตั้งค่าเป้าหมายหรือรางวัลของคอมพิวเตอร์เอาไว้ว่าเราต้องการจะให้คอมพิวเตอร์ตัวนี้ทำงานอะไรหรือแต่ละการกระทำมีค่ารางวัลเท่าไร จากนั้นก็ทำการให้มันเรียนรู้ตามสภาพแวดล้อมซึ่งอาจจะมาจากเซ็นเซอร์หรืออินพุตในรูปแบบต่างๆว่า ถ้าเกิดอินพุตเข้ามาแบบนี้แล้วเราเลือกกระทำแบบนี้จะทำให้เราเข้าใกล้เป้าหมายหรือได้รับ รางวัลเป็นค่าเท่าไร เพื่อหาทางเลือกพื้นฐานของการกระทำตามสถานะการนั้นๆ (วิธาน, 2018)

### 2.1.9 โครงข่ายประสาทเทียม (Artificial Neural Networks - ANN)


โครงข่ายประสาทเทียม (Artificial Neural Networks) ใช้หลักการเบื้องต้นมาจากการจำลองการทำงานของเซลล์ประสาท (Neuron) ของมนุษย์ โดยแต่ละเซลล์ประสาทจะมีหลักการสื่อสารกันผ่านการกระตุ้นด้วยศักย์ไฟฟ้า กล่าวคือ กระแสประสาทเริ่มต้นส่งสัญญาณจากตัวเซลล์ (Cell Body) ผ่านแกนประสาทนำออก (Axon) ไปยังจุดประสาท หรือไซแนปส์ (Synapses) ซึ่งจะสื่อสารเชื่อมต่อกับเซลล์ประสาทอื่นผ่านใยประสาทนำเข้า (dendrite) ณ จุดที่เซลล์ประสาททำการสื่อสารกันนี้เองที่เป็นหลักการนำไปประยุกต์ใช้ในโครงข่ายประสาทเทียม (ปริญญ, 2019)

แบบจำลองเซลล์ประสาทเทียม นำเสนอรูปแบบของกราฟที่แสดงเซลล์ประสาทหรือนิวรอน (Neuron) ด้วยปม (Node) และการเชื่อมต่อไซแนปส์ด้วยเส้นเชื่อม (Edge) ที่กำกับน้ำหนัก (Weight)

สำหรับในคอมพิวเตอร์ นิวรอนประกอบด้วยอินพุตและเอาต์พุตเหมือนกัน โดยจำลองให้อินพุตแต่ละอันมีน้ำหนักเป็นตัวกำหนดน้ำหนักของอินพุตโดยนิวรอนแต่ละหน่วยจะมีค่าเกณฑ์ (Threshold) เป็นตัวกำหนดว่าน้ำหนักรวมของอินพุตต้องมากขนาดไหนจึงจะสามารถส่งเอาต์พุตไปยังนิวรอนตัวอื่นได้ เมื่อนำนิวรอนแต่ละหน่วยมาต่อกันให้ทำงานร่วมกันการทำงานนี้ในทางตรรกะแล้วก็จะเหมือนกับปฏิกิริยาเคมีที่เกิดในสมอง เพียงแต่ในคอมพิวเตอร์ทุกอย่างเป็นตัวเลขเท่านั้นเอง

การทำงานของโครงข่ายประสาทเทียม คือเมื่อมีอินพุตเข้ามายังโครงข่าย (Network) ก็เอาอินพุตมาคูณกับน้ำหนักของแต่ละขา ผลที่ได้จากอินพุตทุกขาของนิวรอนจะเอามารวมกันแล้วก็เอามาเทียบกับค่าเกณฑ์ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่าค่าเกณฑ์แล้ว นิวรอนก็จะส่งเอาต์พุตออกไป เอาต์พุตนี้ก็จะถูกส่งไปยังนิวรอนของนิวรอนอื่นๆที่เชื่อมกันในโครงข่าย ถ้าค่าน้อยกว่าค่า

เกณฑ์ก็จะไม่เกิดเอาต์พุต สิ่งสำคัญคือเราต้องทราบค่าน้ำหนักและค่าเกณฑ์ สำหรับสิ่งที่เราต้องการเพื่อให้คอมพิวเตอร์รู้จำ ซึ่งเป็นค่าที่ไม่แน่นอน แต่สามารถกำหนดให้คอมพิวเตอร์ปรับค่าเหล่านั้นได้ โดยการสอนให้มันรู้จักรูปแบบของสิ่งที่เราต้องการให้มันรู้จำ เรียกว่า การถ่ายทอดแบบย้อนกลับ (Back Propagation) ซึ่งเป็นกระบวนการย้อนกลับของการรู้จำ ในการฝึกฟิตไปข้างหน้าของโครงข่ายประสาทเทียม (Feed-forward Neural Networks) จะมีการใช้อัลกอริทึมแบบการถ่ายทอดย้อนกลับ (Back-Propagation) เพื่อใช้ในการปรับปรุงน้ำหนักคะแนนของเครือข่าย (Network Weight) หลังจากใส่รูปแบบข้อมูลสำหรับฝึกให้แก่เครือข่ายในแต่ละครั้งแล้ว ค่าที่ได้รับ (Output) จากเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวัง แล้วทำการคำนวณค่าความผิดพลาด ซึ่งค่าความผิดพลาดนี้จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้แก้ไขค่าน้ำหนักคะแนนต่อไป สถาปัตยกรรมพื้นฐานของโครงข่ายประสาทเทียม แสดงดังรูปที่ 13




รูปที่ 13 สถาปัตยกรรมโครงข่ายประสาทเทียม

ในงานวิจัยฉบับนี้จะใช้การเรียนรู้สำหรับโครงข่ายประสาทเทียม ชนิดการเรียนรู้แบบมี การสอน เป็นการเรียนแบบที่มีการตรวจคำตอบเพื่อให้โครงข่ายประสาทเทียมปรับตัว ชุดข้อมูลที่ใช้ สอนโครงข่ายประสาทเทียมจะมีคำตอบไว้คอยตรวจดูว่าโครงข่ายประสาทเทียมให้คำตอบที่ถูกหรือไม่ ถ้าตอบไม่ถูก โครงข่ายประสาทเทียมก็จะปรับตัวเองเพื่อให้ได้คำตอบที่ดีขึ้น (เปรียบเทียบกับคน เหมือนกับการสอนนักเรียนโดยมีครูผู้สอนคอยแนะนำ) (วิทยา, 2008)

โครงข่ายประสาทเทียมจะมีการป้อนข้อมูลเข้าและการกำหนดค่าน้ำหนักซึ่งแบ่งชั้น (Layer) การทำงานออกเป็น 3 ชั้น ประกอบด้วย

1. ชั้นข้อมูลนำเข้า (Input layer) ทำหน้าที่นำเข้าข้อมูลเข้าสู่โครงข่ายประสาทเทียม โดยข้อมูลนี้จะนำไปประมวลผลในแต่ละโหนด (Node) ของชั้นถัดไป
2. ชั้นซ่อน (Hidden layer) ทำหน้าที่รับข้อมูลจากชั้นนำเข้าโดยการกำหนดค่าน้ำหนักของข้อมูลจากชั้นนำเข้าก่อนรับข้อมูลเข้าสู่ชั้นซ่อน ชั้นซ่อนจะทำหน้าที่เพิ่มประสิทธิภาพในการจัดกลุ่มข้อมูลก่อนจะส่งต่อข้อมูลไปยังชั้นต่อไป
3. ชั้นข้อมูลส่งออก (Output layer) ทำหน้าที่ส่งออกข้อมูลโดยผ่านการประมวลผลจากฟังก์ชันผลรวม (Summation function:  $\Sigma$ ) โดยที่  $\varphi$  หมายถึงฟังก์ชันกระตุ้น (Activation Function) หรือถ่ายโอน,  $N$  หมายถึงจำนวนเซลล์ประสาทอินพุต,  $w_{kj}$  หมายถึงน้ำหนัก  $x_j$  หมายถึงอินพุตไปยังเซลล์ประสาทอินพุต และ  $T_k^{\text{hid}}$  หมายถึงเงื่อนไขเกณฑ์ของเซลล์ประสาทที่ซ่อนอยู่ จะได้ผลลัพธ์ดังสมการที่ 8

รูปแบบจำลองการทำงานของโครงข่ายประสาทเทียมแสดงดังรูปที่ 14



รูปที่ 14 แบบจำลองการทำงานของโครงข่ายประสาทเทียม

$$y_k = (\varphi \sum_{j=1}^N w_{kj} x_j + T_k^{\text{hid}}) \quad (8)$$

ฟังก์ชันกระตุ้น (Activation Function) หรือเรียกอีกชื่อว่า “ฟังก์ชันการส่งต่อ (Transfer function)” เป็นฟังก์ชันในการคำนวณเพื่อทำนายค่าของข้อมูลออก ฟังก์ชันกระตุ้นมีหลายรูปแบบ ดังต่อไปนี้

1. ฟังก์ชันการแปลงเชิงเส้น เป็นฟังก์ชันที่สามารถเรียนรู้เพียงความสัมพันธ์เชิงเส้นระหว่างชั้นข้อมูลป้อนเข้าและชั้นข้อมูลส่งออก ดังนั้นจะไม่สามารถหาคำตอบได้สำหรับบางกรณีที่ไม่ใช่เส้นตรง ค่าผลลัพธ์ที่ได้จากการคำนวณจะมีค่าเท่ากับค่าที่ได้จากฟังก์ชันการแปลงเสมอเหมาะสำหรับผลลัพธ์ที่ไม่มีการกำหนดขอบเขตค่าเป้าหมาย เช่น ฟังก์ชันสเต็ป (Step function) ฟังก์ชันเครื่องหมาย (Sign function) ฟังก์ชันการแปลงฮาร์ดลิมิต (Hard limit activation function)

2. ฟังก์ชันซิกมอยด์ (Sigmoid function) เป็นฟังก์ชันทางคณิตศาสตร์ที่มีลักษณะเป็นตัวเอส “S-curve” หรือเรียกว่า “Sigmoid curve” ฟังก์ชันการแปลงซิกมอยด์จะบีบช่วงข้อมูลป้อนเข้าที่ไม่จำกัดให้เป็นช่วงของข้อมูลส่งออกที่จำกัด โดยที่ช่วงของข้อมูลส่งออกจะอยู่ในช่วง 0 ถึง 1 โดยฟังก์ชันนี้จะใช้เมื่อต้องการทำนายความน่าจะเป็น (Probability) ที่เกิดขึ้นของข้อมูล

3. ฟังก์ชันไฮเพอร์โบลิคแทนเจนต์ (Hyperbolic tangent function) มีลักษณะเช่นเดียวกับฟังก์ชันการแปลงซิกมอยด์ แต่ต่างกันเพียงช่วงของข้อมูลส่งออกจะอยู่ในช่วง -1 ถึง +1 สามารถคำนวณได้ ดังสมการ

$$f(s) = \frac{2}{1+e^{-2s}} - 1 \quad (9)$$

4. ฟังก์ชันเรกติไฟด์ไลน์เนียยูนิต (Rectified Linear Units – ReLu) ถูกนำมาใช้ในโครงข่ายประสาทเทียมตั้งแต่ปี 2011 ด้วยโครงสร้างที่เรียบง่ายแต่กลับใช้ได้ผลดีจึงกลายเป็นฟังก์ชันกระตุ้นที่เป็นที่นิยมใช้ที่สุด โดยค่าฟังก์ชันนี้จะอยู่ระหว่าง  $[-\infty, \infty]$  หมายถึงถ้าข้อมูลเข้ามีค่ามากกว่าศูนย์ ข้อมูลออกจะเป็นมีค่าเป็นบวก และถ้าข้อมูลเข้ามีค่าศูนย์หรือติดลบ ข้อมูลออกจะมีค่าเป็นศูนย์ สมการ ReLu แสดงดังสมการที่ 14 (ไกรศักดิ์, 2021)

$$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases} \quad (10)$$

โครงข่ายประสาทเทียมสามารถแบ่งได้ 3 แบบ ได้แก่

1. โครงข่ายประสาทแบบป้อนไปข้างหน้าชั้นเดียว (Single-layer feed forward neural networks) ประกอบด้วยชั้นสัญญาณประสาทขาเข้าและชั้นสัญญาณประสาทขาออกเท่านั้น
2. โครงข่ายประสาทแบบป้อนไปข้างหน้าหลายชั้น (Multi-layer feed forward neural networks) มีลักษณะเช่นเดียวกับโครงข่ายประสาทแบบป้อนไปข้างหน้าชั้นเดียว แต่จะมีชั้นซ่อนเพิ่มขึ้น โดยอยู่ระหว่างชั้นข้อมูลนำเข้าและชั้นส่งออก

3. โครงข่ายประสาทแบบแพร่ย้อนกลับ (Back propagation neural networks) มีลักษณะเช่นเดียวกับโครงข่ายประสาทแบบป้อนไปข้างหน้า ซึ่งมีชั้นซ่อนอย่างน้อย 1 ชั้น และมีการวนซ้ำแบบป้อนย้อนกลับอย่างน้อยหนึ่งครั้ง โครงข่ายประสาทเทียมมีขั้นตอนการเรียนรู้ที่แตกต่างกัน สำหรับการวิจัยนี้ใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

โดยมีขั้นตอนการดำเนินการ ดังนี้

3.1 กำหนดชั้นข้อมูลนำเข้า ชั้นซ่อนและชั้นข้อมูลส่งออก อัตราการเรียนรู้ จำนวนรอบ ค่าความคลาดเคลื่อนและค่าน้ำหนักให้โครงข่ายประสาท

3.2 คำนวณค่าผลลัพธ์ของโครงข่าย และปรับค่าน้ำหนักในกรณีที่เพอร์เซปตรอนจำแนกข้อมูลผิดพลาด

3.3 ทำซ้ำชุดข้อมูลการเรียนรู้ (Learning data set) จนกระทั่งเพอร์เซปตรอนจำแนกข้อมูลได้ผลลัพธ์ตามค่าเป้าหมายที่กำหนดไว้ (อกนิษฐ์ ทองจิตร์, 2018)

#### 2.1.10 การเพิ่มประสิทธิภาพของอนุภาคฝูง (Particle Swarm Optimization – PSO)


##### 2.1.10.1 พื้นฐานการเพิ่มประสิทธิภาพของอนุภาคฝูง

ในปี 1995 Kennedy และ Eberhart ได้เขียนรายงานการวิจัยเกี่ยวกับพฤติกรรมทางสังคมของกลุ่มสัตว์ โดยพวกเขาว่าการแบ่งปันข้อมูลระหว่างกลุ่มจะเพิ่มความได้เปรียบในการเอาชีวิตรอด เช่นเดียวกับที่นกกลุ่มหาอาหารสามารถเพิ่มประสิทธิภาพการค้นหาของพวกเขาได้ หากทำงานกันเป็นฝูง ข้อดีของการทำงานคือการแบ่งปันข้อมูลที่ดีที่สุดร่วมกัน ซึ่งจะช่วยให้ฝูงค้นพบสถานที่ที่ดีที่สุดของเป้าหมาย

ดังนั้นการเพิ่มประสิทธิภาพของอนุภาคฝูง จึงเป็นเทคนิคการเพิ่มประสิทธิภาพสู่การเคลื่อนไหวและความฉลาดของฝูง ใน PSO นั้นใช้แนวคิดของปฏิสัมพันธ์ทางสังคมสำหรับการแก้ปัญหา โดยการใช้อนุภาคจำนวนหนึ่ง (ตัวแทน) ที่ก่อตัวเป็นฝูงที่เคลื่อนที่ไปมาในพื้นที่ค้นหา โดยมองหาทางออกที่ดีที่สุด อนุภาคแต่ละตัวในฝูงจะมองหาทิศทางตำแหน่งของมันในพื้นที่เพื่อแก้ไขปัญหา ซึ่งสัมพันธ์กับวิธีแก้ปัญหาที่ดีที่สุดที่อนุภาคนั้นทำได้ในรอบปัจจุบันนั้นๆ

สัญชาตญาณของการเพิ่มประสิทธิภาพฝูงอนุภาค คือ การเคลื่อนไหวไปสู่พื้นที่ที่มีแนวโน้มเพื่อให้ได้เป็นทางออกที่เหมาะสมที่สุดในโลก (global optimum) อนุภาคแต่ละตัวจะปรับความเร็วในการเดินทางแบบไดนามิกตามประสบการณ์การบินที่อนุภาคมีรวมถึงไปถึงประสบการณ์ของเพื่อนในกลุ่มหรือทีมด้วย ซึ่งแต่ละอนุภาคพยายามติดตามผลลัพธ์ที่ดีที่สุดสำหรับพวกเขา หรือที่รู้จักในชื่อค่าที่ดีที่สุดระดับบุคคล (Personal best) หรือ pbest และค่าที่ดีที่สุดของอนุภาคใด ๆ ในกลุ่มจะถูกเรียกว่าค่าที่ดีที่สุดระดับโลก (Global best) หรือ gbest นอกจากนั้นแล้วแต่ละอนุภาค

ปรับเปลี่ยนตำแหน่งตามตำแหน่งปัจจุบัน ความเร็วปัจจุบัน ระยะห่างระหว่างตำแหน่งปัจจุบันกับ pbest และระยะห่างระหว่างตำแหน่งปัจจุบันกับ gbest รูปแสดงตัวอย่างวิธีการค้นหาของอนุภาคฝูง แสดงดังรูปที่ 15



รูปที่ 15 ตัวอย่างวิธีการค้นหาพื้นที่ที่ดีที่สุดของอนุภาคฝูง (Clark, 2017)

#### 2.1.10.2 อัลกอริทึมการเพิ่มประสิทธิภาพฝูง (Particle Swarm Optimization Algorithm)

กำหนดให้พารามิเตอร์สำหรับสมการอัลกอริทึม ดังต่อไปนี้

$f$	คือ ฟังก์ชันวัตถุประสงค์
$V_1$	คือ ความเร็วของอนุภาคหรือตัวแทน
$A$	คือ ประชากรของตัวแทน
$W$	คือ น้ำหนักความเฉื่อย
$c_1$	คือ ค่าคงที่ทางปัญญา
$U_1, U_2$	คือ ตัวเลขสุ่ม
$c_2$	คือ ค่าคงที่ทางสังคม
$X_1$	คือ ตำแหน่งของอนุภาคหรือตัวแทน
$P_b$	คือ Personal Best
$g_b$	คือ global Best

จะได้รูปแบบและการทำงานของ PSO อัลกอริทึม ดังต่อไปนี้

1. สร้าง 'จำนวน' ของตัวแทน (อนุภาค) ซึ่งกระจายอย่างสม่ำเสมอทั่ว  $X$
2. ประเมินตำแหน่งของแต่ละอนุภาคโดยพิจารณาจากฟังก์ชันวัตถุประสงค์  
จะได้สมการดังต่อไปนี้

$$z = f(x, y) = \sin x^2 + \sin y^2 + \sin x \sin y \quad (11)$$

3. หากตำแหน่งปัจจุบันของอนุภาคดีกว่าตำแหน่งที่ดีที่สุดก่อนหน้านี้ ให้ปรับปรุง (Update) ข้อมูลเป็นค่าปัจจุบัน
4. ค้นหาอนุภาคที่ดีที่สุด (ตามตำแหน่งที่ดีที่สุดของอนุภาคก่อนหน้านี้)
5. ปรับปรุงความเร็วของอนุภาค

จะได้สมการปรับปรุงความเร็วของอนุภาค ดังต่อไปนี้

$$V_i^{t+1} = W \cdot V_i^t + c_1 U_1^t (P_{b1}^t - P_i^t) + c_2 U_2^t (g_b^t - P_i^t) \quad (12)$$

6. ทำการย้ายอนุภาคไปยังตำแหน่งใหม่ ดังสมการ

$$P_i^{t+1} = P_i^t + v_i^{t+1} \quad (13)$$

7. ทำซ้ำตั้งแต่ขั้นตอนที่ 2 จนกว่าจะถึงเกณฑ์การหยุดที่กำหนดไว้

เพิ่มเติมสำหรับคำอธิบายของแต่ละพารามิเตอร์ในสมการ ประกอบด้วย

- สำหรับการกำหนดค่าตัวแปรคงที่ในสมการ ถ้า  $W=1$  การเคลื่อนที่ของอนุภาคจะได้รับอิทธิพลจากการเคลื่อนที่ครั้งก่อนทั้งหมด ดังนั้นอนุภาคอาจยังคงไปในทิศทางเดียวกัน ในทางกลับกัน ถ้า  $0 \leq W < 1$  อิทธิพลดังกล่าวจะลดลง ซึ่งหมายความว่าอนุภาคนั้นๆจะสามารถไปยังพื้นที่ค้นหาส่วนอื่นๆ ในโดเมนของการค้นหาได้
- $P_{b1}^t$  และตำแหน่งปัจจุบันของ  $P_i^t$  นั้นจากสมการจะสังเกตได้ว่าเมื่ออนุภาคอยู่ห่างจากตำแหน่ง  $P_{b1}^t$  (Personal best) มากขึ้น ความแตกต่าง  $P_{b1}^t - P_i^t$  จะต้องเพิ่มขึ้น ดังนั้นค่าที่เพิ่มขึ้นนี้จะเป็นการดึงดูดอนุภาคให้อยู่ในตำแหน่งที่ดีที่สุด
- สำหรับพารามิเตอร์  $c_1$  ที่มีอยู่เป็นผลิตภัณฑ์ที่เป็นค่าคงที่บวก และเป็นพารามิเตอร์การรับรู้รายบุคคล มันชี้แนะถึงความสำคัญของประสบการณ์ก่อนหน้านี้ของอนุภาคเอง
- ไฮเปอร์พารามิเตอร์อื่นๆ ที่ประกอบกันเป็นผลคูณของเทอมที่สองคือ  $U_1^t$  เป็นพารามิเตอร์ค่าสุ่มที่มีช่วง  $[0,1]$  พารามิเตอร์สุ่มนี้มีบทบาทสำคัญในการหลีกเลี่ยงการบรรจบกันก่อนเวลาอันควร ซึ่งจะเป็นการเพิ่มประสิทธิภาพโดยรวมที่มีแนวโน้มมากที่สุด
- ความแตกต่างของ  $g_b^t - P_i^t$  ทำงานเป็นแรงดึงดูดสำหรับอนุภาคไปยังจุดที่ดีที่สุดจนกว่าจะพบที่การวนซ้ำ ในทำนองเดียวกัน  $c_2$  ก็เป็นพารามิเตอร์การ



เรียนรู้ทางสังคมเช่นกัน และให้น้ำหนักกับความสำคัญของการเรียนรู้ทั่วโลกของฝูง และ  $U_2^t$  มีบทบาทและทำงานคล้ายคลึงกันกับ  $U_1^t$

- ในกรณีที่  $c_1 = c_2 = 0$  อนุภาคทั้งหมดยังคงบินหรือเคลื่อนที่ต่อไปด้วยความเร็วปัจจุบันจนกว่าจะถึงขอบเขตของพื้นที่ค้นหา
- ในกรณีที่  $c_1 > 0$  และ  $c_2 = 0$  อนุภาคทั้งหมดจะเป็นอิสระจากกัน
- ในกรณีที่  $c_2 > 0$  และ  $c_1 = 0$  อนุภาคทั้งหมดจะถูกดึงดูดไปยังจุดเดียวในฝูงทั้งหมด
- ในกรณีที่  $c_1 = c_2 \neq 0$  อนุภาคทั้งหมดจะถูกดึงดูดเข้าหาค่าเฉลี่ยของ pbest และ gbest (Sanyal, 2021)

### 2.1.11 ต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสี (Gradient Boosting Decision Trees)

การส่งเสริมการไล่ระดับสี (Gradient Boosting) เป็นเทคนิคการเรียนรู้ของเครื่องสำหรับปัญหาการถดถอย (Regression) และการจำแนกประเภท (Classification) ซึ่งสร้างแบบจำลองการทำนายในรูปแบบของกลุ่มของแบบจำลองที่รวบรวมผู้เรียนที่อ่อนแอจำนวนมากเข้าด้วยกันเพื่อสร้างผู้เรียนที่เข้มแข็งเพียงคนเดียว ต้นไม้ทั้งหมดจะถูกเชื่อมต่อกันเป็นชุด และต้นไม้แต่ละต้นจะพยายามลดข้อผิดพลาดของต้นไม้ก่อนหน้าให้เหลือน้อยที่สุด หรืออธิบายได้ว่า โครงสร้างการตัดสินใจแต่ละต้นจะเรียนรู้ข้อผิดพลาดจากแผนผังก่อนหน้าและใช้ประโยชน์จากข้อมูลนี้เพื่อปรับปรุงความแม่นยำในการทำนาย เมื่อการเรียนรู้ของโครงสร้างการตัดสินใจลึกพอ แบบจำลองจะหยุดเพราะไม่มีรูปแบบข้อผิดพลาดจากต้นไม้ก่อนหน้าให้เรียนรู้อีกต่อไป เนื่องจากการเชื่อมต่อนี้ อัลกอริทึมการเพิ่มประสิทธิภาพมักจะเรียนรู้ได้ช้า แต่มีความแม่นยำสูง ในการเรียนรู้ทางสถิติ ตัวแบบที่เรียนรู้ซ้ำจะทำงานได้ดีกว่า

ฟังก์ชันการสูญเสียถูกใช้เพื่อตรวจจับค่าความผิดพลาด (residual) ตัวอย่างเช่นสามารถใช้หาค่าความผิดพลาดกำลังสองเฉลี่ย (Mean Square Error - MSE) สำหรับงานถดถอย, และสามารถใช้ในการหาการสูญเสียลอการิทึมหรือลอการิทึม (logarithmic loss - log loss) สำหรับงานจัดประเภท เป็นที่น่าสังเกตว่าต้นไม้ที่มีอยู่ในแบบจำลองจะไม่เปลี่ยนแปลงเมื่อมีการเพิ่มต้นไม้ใหม่ โครงสร้างการตัดสินใจที่เพิ่มเข้ามาจะพอดีกับค่าความผิดพลาดจากแบบจำลองปัจจุบัน

ให้  $x$  เป็นชุดของรูปแบบอินพุต  $x = \{x_1, \dots, x_n\}$  และเอาต์พุตถูกกำหนดเป็น  $y$  โดยที่  $y = \{y_1, \dots, y_n\}$  ดังนั้น ข้อมูลอินพุตที่ใช้สำหรับการฝึกคือ  $\{x_i, y_i\}_{i=1}^n$  ฟังก์ชันการสูญเสียถูกกำหนดไว้ในสมการ โดย  $p$  หมายถึงความน่าจะเป็นที่คาดการณ์ไว้ และ  $N$  คือจำนวนตัวอย่าง

$$L(y_i, F(x)) = -\sum_{i=1}^N y_i \cdot \log(p) + (1 - y_i) \cdot \log(1 - p) \quad (14)$$

รูปแบบสมการสุทธิของแบบจำลองต้นไม้การส่งเสริมการไล่ระดับสี แสดงดังสมการ


$$F_0(x) = \underset{\gamma}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, \gamma) \quad (15)$$

การทำงานของเกรเดียนต์บูสติงหรือการส่งเสริมการไล่ระดับสี สามารถใช้ “GradientBoostingRegressor” หรือ “GradientBoostingClassifier class” ใน โมดูล “sklearn.ensemble” ของไลบรารี “scikit-learn” ได้เลย

อัตราการเรียนรู้ (learning rate) และ n\_estimators เป็นไฮเปอร์พารามิเตอร์ (Hyperparameters) ที่เป็นส่วนสำคัญของอัลกอริทึมการเรียนรู้ ที่ส่งผลต่อประสิทธิภาพและความแม่นยำของแบบจำลอง อัตราการเรียนรู้และ n\_estimators เป็นไฮเปอร์พารามิเตอร์ที่สำคัญ 2 ตัว สำหรับการไล่ระดับต้นไม้การตัดสินใจ อัตราการเรียนรู้ ซึ่งแสดงเป็น  $\alpha$  หมายถึงความรวดเร็วของแบบจำลองที่ใช้เรียนรู้ ต้นไม้แต่ละต้นที่เพิ่มเข้ามาจะปรับเปลี่ยนแบบจำลองโดยรวม ขนาดของการปรับเปลี่ยนถูกควบคุมโดยอัตราการเรียนรู้ ยิ่งอัตราการเรียนรู้ต่ำ แบบจำลองก็จะยิ่งเรียนรู้ช้าลง ข้อดีของอัตราการเรียนรู้ที่ช้าลงคือ แบบจำลองมีความแข็งแกร่งและมีประสิทธิภาพมากขึ้น ในการเรียนรู้ทางสถิติ ตัวแบบที่เรียนรู้ช้าจะทำงานได้ดีกว่า อย่างไรก็ตาม การเรียนรู้ช้าๆ มีค่าใช้จ่าย ต้องใช้เวลามากขึ้นในการฝึกแบบจำลองซึ่งนำไปสู่ไฮเปอร์พารามิเตอร์ที่สำคัญอื่นๆ นอกจากนั้นแล้ว n\_estimator คือจำนวนต้นไม้ที่ใช้ในแบบจำลอง หากอัตราการเรียนรู้ต่ำ เราต้องการต้นไม้ที่เพิ่มขึ้นเพื่อฝึกแบบจำลอง อย่างไรก็ตาม เราต้องระวังในการเลือกจำนวนต้นไม้ให้มาก เพราะจะสร้างความเสี่ยงสูงที่จะใช้ต้นไม้มากเกินไป

### 2.1.12 ป่าไม้สุ่ม (Random Forest)

ป่าไม้สุ่ม เป็นหนึ่งในกลุ่มของแบบจำลองที่เรียกว่า การเรียนรู้ทั้งมวล (Bagging หรือ Ensemble Learning) หลักการของป่าไม้สุ่มคล้ายกับต้นไม้ตัดสินใจปกติ แต่จะสุ่มเอาข้อมูล (Instance) ไปสร้างเป็นต้นไม้หลายๆต้น แต่ละต้นเรียกว่าซัพเซต (Subset) ต้นที่ 1,2,3,... สร้างได้แบบร้อยนับพันต้น เหมือนกับว่ามีป่าที่มีต้นไม้จำนวนมากๆ ซึ่งแต่ละต้นจะมีรูปแบบสุ่มไม่เหมือนกัน (ตามชื่ออัลกอริทึม) โดยในตอนการใช้งานทำนายแต่ละต้นก็ทำการทำนายแล้วเลือกผลที่ได้จากการโหวตที่มากที่สุดมาเป็นผลลัพธ์ แผนผังแสดงอัลกอริทึมป่าไม้สุ่ม แสดงดังรูปที่ 16



รูปที่ 16 ตัวอย่างกระบวนการทำงานของอัลกอริทึมป่าไม้สุ่ม (วิชญ์พงศ์, 2018)

จากภาพหลักการในการทำป่าไม้สุ่ม คือ

1. ตัวอย่างข้อมูล (Bootstrapping) จากชุดข้อมูลทั้งหมด ให้ได้ข้อมูลออกมา  $n$  ชุดที่ไม่เหมือนกัน ตามจำนวนต้นไม้ตัดสินใจในป่าไม้สุ่ม เช่น ชุดข้อมูลตั้งต้นมีอยู่ 10 รูปแบบ ( $X_1, X_2, \dots, X_{10}$ ) แต่ละต้นไม้ตัดสินใจจะได้รูปแบบที่ไม่เหมือนกันและจะได้ข้อมูลไม่ครบทุกแถว ด้วยจากชุดข้อมูลทั้งหมดด้วย ( $X_1 \rightarrow X_1', X_2 \rightarrow X_2', \dots$ )
2. สร้างแบบจำลองต้นไม้ตัดสินใจ สำหรับแต่ละชุดข้อมูล
3. ทำการรวมผลลัพธ์ จากแต่ละแบบจำลอง (Bagging) เช่น โหวตในกรณีการแบ่งกลุ่ม (Classification) หรือ หาค่าเฉลี่ย (Mean) ในกรณีเป็นการถดถอย (Regression)

### 2.1.13 ไฮเปอร์พารามิเตอร์ (Hyperparameter)

ไฮเปอร์พารามิเตอร์ เปรียบเสมือนปุ่มหรือแถบเครื่องมือที่สามารถปรับค่าหรือปรับหมุนขึ้นลง เพื่อใช้ในการควบคุมการทำงานของอัลกอริทึมการเรียนรู้ของเครื่อง โดยไฮเปอร์พารามิเตอร์จะส่งผลโดยตรงกับการฝึกฝนแบบจำลอง (Model) เกี่ยวกับเวลาที่ใช้ในการฝึกสอนแบบจำลอง ข้อกำหนดเกี่ยวกับข้อมูลจำเพาะ (Specification) ของเครื่องคอมพิวเตอร์ที่ต้องใช้สำหรับการสร้างแบบจำลอง นอกจากนี้แล้วยังส่งผลโดยตรงกับค่าการมาบรรจบกัน (Convergence) และ ค่าความแม่นยำ (Accuracy) ของแบบจำลอง

การสร้างแบบจำลองการเรียนรู้ของเครื่องมักประกอบไปด้วยพารามิเตอร์ที่แตกต่างกัน 2 ชนิด ได้แก่

1. พารามิเตอร์ของแบบจำลอง (Model Parameters) คือ พารามิเตอร์ที่ได้มาระหว่างขั้นตอนการเรียนรู้ข้อมูลของแบบจำลอง (Model Training) เช่น ค่าน้ำหนัก (Weights) ที่ใช้

ในโครงข่ายประสาทเทียม (Neural Network) หรือค่าสัมประสิทธิ์ (Coefficients) ที่ได้จากการทำการถดถอยเชิงเส้น (Linear Regression) เป็นต้น

2. ไฮเปอร์พารามิเตอร์ (Hyperparameters) คือ พารามิเตอร์ต่าง ๆ ที่ผู้ใช้สามารถกำหนดเองได้ก่อนที่แบบจำลองจะทำการเรียนรู้ เช่น ค่าอัตราการเรียนรู้ (Learning Rate) ที่ใช้ในการควบคุมว่าใน 1 ลำดับชั้นของการเรียนรู้จะปรับค่าน้ำหนักของโครงข่ายประสาทเทียมเป็นอย่างไร หรือค่า  $n\_estimators$  ซึ่งกำหนดจำนวนต้นไม้สำหรับการสร้างแบบจำลองป่าไม้สุ่ม เป็นต้น ซึ่งไฮเปอร์พารามิเตอร์นี้สามารถปรับได้เองตามผู้ใช้หรือผู้สร้างแบบจำลอง หรือจะปรับให้เหมาะสมที่สุดอย่างอัตโนมัติโดยใช้แหล่งที่มาของห้องสมุด (Library source code) ที่ปัจจุบันมีผู้คนคิดค้นขึ้นมาเพื่อช่วยในการเข้ามาปรับปรุง

แบบจำลองพารามิเตอร์ จะเป็นตัวกำหนดว่าจะใช้ข้อมูลในการเรียนรู้อย่างไรเพื่อให้ได้ผลลัพธ์ที่ต้องการโดยจะได้มาระหว่างการเรียนรู้ของแบบจำลอง แต่สำหรับไฮเปอร์พารามิเตอร์นั้น จะกำหนดโครงสร้างของแบบจำลองตั้งแต่ต้นแล้วใช้ค่านั้นในการสร้างแบบจำลองขึ้นมา

สำหรับงานวิจัยฉบับนี้ ทางผู้จัดทำได้ใช้ออฟฟุ่่น่า เข้ามาช่วยในการปรับปรุงไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดของแต่ละแบบจำลอง ดังจะแสดงให้เห็นในบทที่ 3

#### 2.1.14 ออปทูนา (Optuna)

ออปทูนา เป็นกรอบ/เค้าโครง (Framework) ของการเพิ่มประสิทธิภาพของไฮเปอร์พารามิเตอร์หรือใช้สำหรับปรับแต่งไฮเปอร์พารามิเตอร์แบบอัตโนมัติ ออกแบบมาโดยเฉพาะสำหรับการเรียนรู้ของเครื่อง มีคุณลักษณะเป็น Application Programming Interface (API) หรือการเชื่อมต่อจากระบบหนึ่งไปสู่อีกระบบหนึ่ง เพื่อให้ซอฟต์แวร์ภายนอกเข้าถึงและอัปเดตข้อมูลนั้นๆได้ แต่ยังคงอยู่ในขอบเขตที่ถูกกำหนดไว้ หรืออธิบายอีกนัยหนึ่งก็คือ API เป็นตัวกลางที่จะทำให้คอยรับคำสั่งต่าง ๆ จากนั้นทำการประมวลผลและกระทำกับข้อมูลและส่งกลับคืนไปยังคนสั่งโดยอัตโนมัติ

สำหรับโค้ดที่เขียนด้วยออปทูนานั้น จะมีความเป็นโมดูลสูงและใช้งานออปทูนาสามารถสร้างช่องว่างหรือพื้นที่การค้นหา (Search Space) สำหรับค้นหาไฮเปอร์พารามิเตอร์แบบพลวัต (Dynamic) ได้ โดยสรุปแล้วคุณสมบัติหลักของออปทูนา คือ การค้นหาไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดโดยอัตโนมัติ ค้นหาพื้นที่ขนาดใหญ่อย่างมีประสิทธิภาพและตัดการทดลองที่ไม่มีใครคาดคิดเพื่อให้ได้ผลลัพธ์ที่เร็วขึ้นและทำให้การค้นหาไฮเปอร์พารามิเตอร์แบบคู่ขนานกันในหลายกระบวนการ (Lu, 2021)

งานวิจัยฉบับนี้จะใช้หลักการอุปนุในการค้นหาไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดในแต่ละแบบจำลอง ดังจะแสดงให้เห็นผลของค่าไฮเปอร์พารามิเตอร์ที่ได้ในแต่ละแบบจำลองดังบทที่ 3 ต่อไป

### 2.1.15 การประเมินผลแบบจำลอง (Evaluation Model)

การเรียนรู้ของเครื่อง มีเมตริกซ์ที่ใช้วัดความถูกต้องของแบบจำลอง เพื่อในการประเมินผลลัพธ์ของการทำนายจากแบบจำลองที่เราสร้างขึ้นมา แบ่งเป็นสองกลุ่มใหญ่สำหรับปัญหาประเภทการถดถอยและการจัดกลุ่ม

ในงานวิจัยฉบับนี้ จะยกตัวอย่างเมตริกซ์ที่จะใช้สำหรับการทำนายกลุ่มปัญหาการจัดกลุ่มโดยใช้ตารางความสับสน (Confusion Matrix) เป็นตารางที่ใช้ประเมินผลลัพธ์การทำนาย หรือผลลัพธ์จากโปรแกรม (Prediction) เปรียบเทียบกับค่าจริง ๆ (Actual) ของตัวเอง ตารางความสับสนแสดงไว้ดังตารางที่ 11

ตารางที่ 11 ตารางความสับสน (Confusion Matrix)

#### Confusion Matrix

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

ทำนายถูกต้องสำหรับผลในทางบวก (True Positive :TP) = สิ่งที่ทำนาย ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณี ทำนายว่าจริงและสิ่งที่เกิดขึ้นก็คือ จริง

ทำนายถูกต้องสำหรับผลในทางลบ (True Negative :TN) = สิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้น ในกรณีทำนายว่า ไม่จริง และสิ่งที่เกิดขึ้น ก็คือ ไม่จริง

ทำนายผิดโดยให้ผลเป็นบวก (False Positive :FP) = สิ่งที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้น คือทำนายว่าจริง แต่สิ่งที่เกิดขึ้น คือ ไม่จริง

ทำนายผิดโดยให้ผลเป็นลบ (False Negative :FN) = สิ่งที่ทำนายไม่ตรงกับที่ที่เกิดขึ้นจริง คือทำนายว่าไม่จริง แต่สิ่งที่เกิดขึ้น คือ จริง

โดย TP,TN,FP,FN ในตารางจะแทนด้วยค่าความถี่

เราสามารถใช้ตารางความสับสนมาคำนวณการประเมินประสิทธิภาพของการทำนาย ด้วยแบบจำลองของเรา ในรูปแบบค่าต่างๆได้หลายค่า ได้แก่

1. ความถูกต้อง (Accuracy) คือสัดส่วนเปอร์เซ็นต์ความถูกต้อง คือ จำนวนที่ทำนายถูก/จำนวนทั้งหมด

$$Accuracy = \frac{TP+TN}{All} \quad (16)$$

หรือกล่าวได้ว่า ความถูกต้อง = ผลรวมของตัวเลขบนเส้นทแยงมุมในตารางความสับสน / จำนวนข้อมูลกลุ่มนั้นทั้งหมด

โดย ความเป็นจริงแล้วตารางความสับสนไม่จำเป็นต้องเป็นแบบ 2x2 หรือมีผลลัพธ์แค่ 2 แบบ เสมอไป โดยอาจเป็น 3x3, 4x4, nxn ก็ได้ โดยวิธีการหาความถูกต้อง ก็ใช้แบบเดิม คือ ผลรวมของตัวเลขบนเส้นทแยงมุมในตารางความถูกต้อง / จำนวนข้อมูลกลุ่มนั้นทั้งหมด

2. ความแม่นยำ (Precision)

คือความแม่นยำผลทำนาย (สนใจผลทำนาย) คำนวณโดยสัดส่วนที่ทำนายว่าเป็นบวกกับลบที่เปอร์เซ็นต์ เป็นการเปรียบเทียบการทำนายที่ถูกต้องว่าจริงและที่เกิดขึ้นจริง (TP) กับการทำนายว่าจริงแต่สิ่งที่เกิดขึ้นคือไม่จริง (FP)

$$Precision = \frac{TP}{TP+FP} \quad (17)$$

3. การเรียกคืน (Recall)

คือการวัดความแม่นยำอีกมิติที่สนใจผลลัพธ์เทียบกับที่เป็นของจริง (Actual) ด้วย ทำนองว่าของจริงมี 5 ชิ้นนั้น ระบบทำนายถูกว่าเป็นของดีกี่เปอร์เซ็นต์หรือทำนายถูกต้องว่าเป็นของเสียกี่เปอร์เซ็นต์

$$Recall = \frac{TP}{TP+FN} = TPR (Sensitivity) \quad (18)$$

4. คะแนนเอฟวัน (F1 score)

เป็นค่าที่แสดงประสิทธิภาพโดยการนำความแม่นยำกับการเรียกคืน มาคำนวณหาค่าเฉลี่ย (ในทางเทคนิคเรียกว่า ค่าเฉลี่ยฮามอนิกส์) ซึ่งค่าสูงๆถือว่าแบบจำลองมีประสิทธิภาพดี (กอบเกียรติ, 2020)

$$F1 = 2 * \left( \frac{Precision * Recall}{Precision + Recall} \right) \quad (19)$$

นอกจากนั้นแล้วงานวิจัยฉบับนี้ยังนำการประเมินผลโดยใช้หลักการ AUC ROC เข้าร่วมประกอบการพิจารณาในการเลือกแบบจำลองด้วย


#### 5. AUC - ROC

เมื่อพูดถึงปัญหาการจำแนกประเภท เราสามารถใช้ AUC - ROC Curve สำหรับการตรวจสอบหรือแสดงภาพประสิทธิภาพของปัญหาประเภทแบบจำลองการจัดหมวดหมู่ โดยใช้เส้นโค้ง Area Under The Curve (AUC) ที่เป็นพื้นที่ใต้เส้นโค้งของ Receiver Operating Characteristics (ROC) เข้ามาเป็นหนึ่งในตัวชี้วัด นอกจากนี้ยังสามารถเขียนเป็นพื้นที่ภายใต้ลักษณะการทำงานของผู้รับหรือ Area Under the Receiver Operating Characteristics (AUROC)

เส้นกราฟ AUC - ROC คือการวัดประสิทธิภาพสำหรับปัญหาการจำแนกประเภทที่การตั้งค่าเกณฑ์ต่างๆ ROC คือเส้นกราฟความน่าจะเป็น และ AUC แสดงถึงระดับหรือการวัดความสามารถในการแยกออกจากกัน โดยค่าดังกล่าวจะบอกได้ว่าแบบจำลองสามารถแยกแยะระหว่างได้มากน้อยเพียงใด ยิ่ง AUC สูง แบบจำลองก็ยิ่งทำนาย 0 กลุ่มเป็น 0 และกลุ่ม 1 เป็น 1 ได้ดีกว่า และยัง AUC สูง แบบจำลองก็ยิ่งแยกความแตกต่างระหว่างผู้ป่วยที่เป็นโรคและไม่มีโรคได้ดีกว่า เป็นต้น หรืออธิบายเพิ่มเติมของค่า AUC คือ เมื่อ AUC เท่ากับ 0.5 แสดงถึงแบบจำลองไม่มีความสามารถในการแยกกลุ่มได้


เส้นโค้ง ROC จะถูกพล็อตด้วย True Positive Rate (TPR) ที่แสดงดังสมการที่ 18 เทียบกับ False Positive Rate (FPR) โดยที่ TPR อยู่บนแกน y และ FPR อยู่บนแกน x โดยสมการของ FPR แสดงดังสมการที่ 19 และสำหรับรูปการพล็อตเส้นโค้ง ROC แสดงดังรูปที่ 17 ตามลำดับ

$$FPR = \frac{FP}{TN + FP} \quad (19)$$




รูปที่ 17 เส้นโค้ง AUC-ROC (Narkhede, 2018)

ยกตัวอย่างการเปรียบเทียบค่า AUC แสดงดังรูปที่ 18 (ก) – (ง) ตามลำดับ ในที่นี้กำหนดให้เส้นการกระจายสีแดงเป็นระดับบวก (ผู้ป่วยที่เป็นโรค) และเส้นโค้งการกระจายสีเขียวเป็นระดับลบ (ผู้ป่วยที่ไม่มีโรค)





(ก) เมื่อค่า AUC = 1



(ข) เมื่อค่า AUC = 0.7



(ค) เมื่อค่า  $AUC = 0.5$ (ง) เมื่อค่า  $AUC = 0$ 

รูปที่ 18 เปรียบเทียบค่า AUC และเส้นโค้ง ROC ที่แสดงผลออกมาตามค่า AUC (Narkhede, 2018)

รูปที่ 18 (ก) เป็นสถานการณ์ในอุดมคติ เมื่อเส้นโค้งสองเส้นไม่ทับซ้อนกัน หมายความว่าแบบจำลองมีความสามารถในการแยกออกจากกันในอุดมคติ คือสามารถแยกแยะความแตกต่างระหว่างกลุ่มบวกและกลุ่มลบได้อย่างสมบูรณ์แบบ

รูปที่ 18 (ข) เมื่อการแจกแจงสองครั้งทับซ้อนกันเมื่อ AUC เท่ากับ 0.7 หมายความว่ามีโอกาส 70% ที่แบบจำลองจะสามารถแยกแยะระหว่างกลุ่มบวกและกลุ่มลบ

รูปที่ 18 (ค) เป็นสถานการณ์ที่เลวร้ายที่สุดเมื่อ AUC มีค่าประมาณ 0.5 แบบจำลองจะไม่สามารถแยกแยะระหว่างกลุ่มบวกและกลุ่มลบได้

รูปที่ 18 (ง) เมื่อ AUC มีค่าประมาณ 0 แบบจำลองจะตอบสนองกลุ่มจริง ๆ หมายความว่าแบบจำลองคาดการณ์กลุ่มเชิงลบว่าเป็นกลุ่มบวก และทำนายกลุ่มเชิงบวกว่าเป็นกลุ่มเชิงลบสลับกัน (Narkhede, 2018)

#### 2.1.16 อคติสูง (Under Fitting) / ความแปรปรวนสูง (Over fitting)

ในการสร้างแบบจำลองโดยใช้การเรียนรู้ของเครื่อง มักเกิดปัญหาที่เราจะพบเห็นได้บ่อยครั้ง ประกอบด้วย

1. อันเดอร์ฟิตติ้ง (Under-fitting) หรือเรียกอีกอย่างว่า อคติสูง (High bias) คือ แบบจำลองที่เรียบง่ายหรือมีสมการที่ไม่ซับซ้อนจนเกินไป เมื่อนำไปใช้ในการทำนาย/จัดกลุ่ม จะส่งผลต่อผลลัพธ์ที่ไม่ค่อยถูกต้องและไม่ใกล้เคียงกับผลเฉลยหรือคำตอบที่แท้จริงเลย

2. โอเวอร์ฟิตติ้ง (Over-fitting) หรือเรียกอีกอย่างว่าความแปรปรวนสูง (High variance) คือ แบบจำลองที่มีโครงสร้างที่ซับซ้อนจนเกินไป ซึ่งโครงสร้างภายในปรับเข้ากับทุกข้อมูลที่ใช้ในการฝึก ส่งผลให้สามารถทำนายข้อมูล/จัดกลุ่มข้อมูลกับข้อมูลที่ใช้ในการทำการฝึกได้อย่างถูกต้องและแม่นยำ แต่เมื่อนำไปใช้งานจริงจะส่งผลต่อผลลัพธ์ที่ทำนายไม่มีทางถูกเลย/ถูกน้อยมาก

ดังนั้นสิ่งที่เราต้องการในการสร้างแบบจำลองคือความเหมาะสมดี (Good Fit) หมายถึง ขณะที่ฝึกนั้นสามารถทำนายผลลัพธ์ของชุดข้อมูลนั้นมีการผิดพลาดไปบ้าง และเมื่อนำแบบจำลองออกไปใช้งานจริงๆ ก็ยังทำนาย/จัดกลุ่ม ข้อมูลชุดนั้นๆ ได้แม่นยำได้



## 2.2 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

“Condition monitoring of induction motors: A review and an application of an ensemble of hybrid intelligent models” (Seera et al., 2014) ในงานวิจัยนี้เสนอการตรวจสอบสภาพของมอเตอร์เหนี่ยวนำ โดยใช้แบบจำลองรุ่นไฮบริดอัจฉริยะทั้งหมด (Ensemble of Hybrid Intelligent Models) ที่เป็นประโยชน์สำหรับการตรวจสอบสภาพของมอเตอร์เหนี่ยวนำ การตรวจสอบครอบคลุมสองส่วน คือ วิธีการตรวจสอบสภาพที่ใช้กันทั่วไป 9 วิธีของมอเตอร์เหนี่ยวนำและแบบจำลองการเรียนรู้อัจฉริยะสำหรับการตรวจสอบสภาพของมอเตอร์เหนี่ยวนำขึ้นอยู่กับสัญญาณอินพุตเดียวและหลายอินพุต โดยแบบจำลองอัจฉริยะในงานวิจัยประกอบด้วยโครงข่ายประสาทเทียม Fuzzy Min-Max (FMM) และ Random Forest (RF) ได้มีการพัฒนาแบบจำลองที่ประกอบด้วยกลุ่มของ Classification and Regression Trees โดยการหาคะแนนเสียงข้างมาก จากนั้น นำแบบจำลองไปใช้กับการตรวจสอบสภาพของมอเตอร์เหนี่ยวนำโดยใช้ชุดตัวอย่างข้อมูลจริง แบบจำลองที่เกิดจากการรวมกันนี้เรียกว่า FMM-RF (หรือ FMM-RFE) ผลการทดลองแสดงให้เห็นประสิทธิภาพที่ดีทั้งในสภาพแวดล้อมที่ปราศจากเสียงรบกวนและเสียงรบกวนที่สำคัญกว่านั้น การอธิบายในรูปแบบของแผนผังการตัดสินใจสามารถนำมาใช้กับแบบจำลอง FMM-RFE เพื่อปรับสภาพจะการคาดการณ์ พบว่าผลลัพธ์ที่ได้ยังยืนยันประสิทธิภาพของแบบจำลอง โดยเฉพาะอย่างยิ่งสำหรับมอเตอร์เหนี่ยวนำภายใต้สภาพแวดล้อมที่แตกต่างกัน

“Multi-classifiers Ensemble with Confidence Diversity for Fault Diagnosis in Induction Motors” (Tao et al., 2016) มอเตอร์เป็นอุปกรณ์ขับเคลื่อนที่มีความจำเป็น ดังนั้นการตรวจสอบสถานะของมอเตอร์ได้อย่างแม่นยำและวินิจฉัยความผิดปกติทันเวลาจะมีผลกระทบอย่างมากสำหรับอุตสาหกรรม งานวิจัยส่วนใหญ่แสดงการตรวจสอบข้อบกพร่องหรือความผิดปกติทั่วไปของมอเตอร์เพื่อการวินิจฉัยให้ได้ความแม่นยำที่สูงโดยใช้วิธีการเรียนรู้ของเครื่องทั่วไป จึงไม่สามารถประสบผลสำเร็จในด้านการจำแนกกลุ่มได้ดีเท่าที่ความคาดหวัง ในงานวิจัยนี้จึงเป็นการรวมกันของสามตัวแยกประเภท ประกอบด้วย ตัวแยกประเภทไร้เดียงสา (Naïve Bayes Classifier) สุ่มตัวแยกประเภทป่า (Random Forest Classifier) และตัวแยกประเภท SVM (Support Vector Machine Classifier) โดยอัลกอริทึมของตัวแยกประเภทที่รวมตัวกันนี้สามารถทำนายสถานะของมอเตอร์ได้อย่างถูกต้องและแม่นยำ

**“Cascade Neural-Network-Based Fault Classifier for Three-Phase Induction Motor”** (Ghate & Dudul, 2010) มอเตอร์เหนี่ยวนำอาจมีความผิดปกติที่แตกต่างกัน ซึ่งหากตรวจไม่พบ อาจทำให้มอเตอร์เสียหายร้ายแรงได้ จากการทบทวนงานวิจัยที่เกี่ยวข้องอย่างละเอียดถี่ถ้วนเป็นที่สังเกตว่าการตรวจจับความผิดปกติบนโครงข่ายประสาท-ฟัซซีและโครงข่ายประสาทเทียม (neuro-fuzzy and neural network (NN)) ที่ทำงานได้ดีสำหรับเครื่องจักรขนาดใหญ่ที่แพง และยังทำงานได้ดีกับเครื่องจักรที่ซับซ้อน ในงานวิจัยนี้ ผู้เขียนได้พัฒนารูปแบบการตรวจจับข้อบกพร่องบนพื้นฐานเรเดียล - มัลติเลเยอร์ - เพอร์เซปตรอน Cascadeconnection NN (Radial-Basis-Function-Multilayer-Perceptron Cascadeconnection NN ) สำหรับมอเตอร์เหนี่ยวนำสามเฟสขนาดกลางและขนาดเล็ก สำหรับชิ้นส่วนที่นำเข้ามาพิจารณาประกอบด้วยขดลวดสเตเตอร์, ความเยื้องศูนย์ของโรเตอร์, และข้อบกพร่องทั้งสองอย่างพร้อมกัน โดยพารามิเตอร์ทางสถิติอย่างง่ายของกระแสเตเตอร์ถือเป็นอินพุตในการวิเคราะห์ห้วงค์ประกอบหลัก ผลการทดลองแสดงให้เห็นถึงความสามารถของแบบจำลองในการตรวจจับความผิดปกติดังกล่าว นอกจากนี้เครือข่ายที่ได้รับการทดสอบนี้ยังมีความทนทานต่อความไม่สม่ำเสมอและเสียงรบกวนแบบเกาส์เซียน (Gaussian Noises) และยังมีความแม่นยำในการจำแนกประเภทที่ดี ซึ่งลักษณะที่น่าเสนอนี้เหมาะสำหรับการใช้งานในโลกแห่งความเป็นจริง

**“An in-depth experimental study of anomaly detection using gradient boosted machine”**(Tama & Rhee, 2019) งานวิจัยได้นำเสนอการปรับปรุงประสิทธิภาพการตรวจจับของระบบตรวจจับการบุกรุกตามความผิดปกติ (Intrusion Detection System - IDS) โดยใช้เครื่องเพิ่มการไล่ระดับสี (Gradient Boosted Machine - GBM) โดยไฮเปอร์พารามิเตอร์ของ GBM ได้มาจากการทำตารางค้นหา (Grid Search) ซึ่งประสิทธิภาพของแบบจำลอง GBM จะถูกนำมาเปรียบเทียบกับอัลกอริทึมที่มีชื่อเสียงอื่นๆ 4 อัลกอริทึม ได้แก่ ป่าไม้สุ่ม (Random Forest) โครงข่ายประสาทเทียมแบบลึก (Deep Neural Network) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) และการจำแนกประเภทและต้นไม้ตัดสินใจแบบถดถอย (Classification and Regression Tree) ในด้านของการวัดประสิทธิภาพสี่ประการ เช่น ความแม่นยำ (Accuracy) ความจำเพาะ (Specificity) ความอ่อนไหว (Sensitivity) อัตราความผิดปกติบวก (False Positive Rate) และพื้นที่ใต้เส้นโค้งลักษณะการทำงานของเครื่องรับ (Area Under Receiver Operating Characteristic Curve - AUC) จากผลการทดลองพบว่า GBM มีประสิทธิภาพเหนือกว่าในการใช้กับเทคนิคการแก้ปัญหาแบบ IDS อย่างมาก เช่น ตัวแยกประเภทคลุมเครือ (Fuzzy Classifier) ตัวแยกประเภทสองระดับ (Two-tier Classifier) GAR-ป่า (GAR-

Forest) และการแบ่งกลุ่มแบบฝังอ้างอิงต้นไม้ (Tree-based Classifier Ensemble) ผลลัพธ์ที่สูงเหล่านี้นำไปใช้กับชุดข้อมูล เช่น NSL-KDD, UNSW-NB15 และชุดข้อมูล GPRS

“การพยากรณ์ปริมาณน้ำฝนของประเทศไทยด้วยวิธีการเรียนรู้เชิงลึก” (เฟื่องลดา, 2019) วิทยานิพนธ์นี้ถูกจัดทำเพื่อใช้สำหรับนำเสนอแนวทางการทำนายปริมาณน้ำฝนในประเทศไทย โดยการใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning Model) ในการนำข้อมูลจากโทรมาตรวัดปริมาณน้ำฝนที่ได้รับการสนับสนุนจากสถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) หรือ สสน. โดยมีจุดติดตั้งทั้งหมด 469 แห่งของประเทศไทยและเก็บข้อมูลรายชั่วโมงตั้งแต่ปี ค.ศ. 2012 จนถึงปี ค.ศ. 2018 มาฝึกฝนในแบบจำลองการเรียนรู้เชิงลึก นอกเหนือจากการใช้ข้อมูลปริมาณน้ำฝนตรงบริเวณที่สนใจแล้ว งานวิจัยนี้ได้นำข้อมูลจากโทรมาตรใกล้เคียงเข้ามาช่วยพยากรณ์น้ำฝนด้วย โดยพิจารณาความสัมพันธ์เชิงพื้นที่ของแต่ละโทรมาตร แล้วนำข้อมูลเข้าสู่แบบจำลองการเรียนรู้เชิงลึก 2 แบบจำลองต่อกัน (Cascade models) ได้แก่ แบบจำลองการจำแนกข้อมูล (Classification model) ที่นำโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network - CNN) มาพิจารณาความสัมพันธ์ของคุณลักษณะเพื่อจำแนกว่าอีกหนึ่งชั่วโมงข้างหน้าฝนจะตกหรือไม่ตก และแบบจำลองการถดถอย (Regression model) เพื่อทำนายปริมาณน้ำฝน โดยแบบจำลองแรกใช้โครงข่ายประตูกลับ (Gated Recurrent Unit : GRU) สำหรับพิจารณาความสัมพันธ์ในเชิงแกนเวลาและแบบจำลองที่สองคือแบบจำลองตัวเข้ารหัสอัตโนมัติ (Autoencoder Model) ร่วมกับเพอร์เซ็ปตรอนหลายชั้น (Multi-Layer Perceptron) โดยนำแนวคิดเรื่องการลดมิติของข้อมูล (Dimensionality reduction) มาใช้ร่วมกับข้อมูลปริมาณน้ำฝนและสภาพอากาศ เพื่อเพิ่มความสามารถในการดักจับปริมาณน้ำฝนที่มีค่าสูง ทำให้แบบจำลองมีประสิทธิภาพในการทำนายดีขึ้น

1. ว่าสามารถทำนายปริมาณน้ำฝนด้วยข้อมูลหลายตัวแปรโดยใช้ข้อมูลตัวแปรสภาพอากาศและช่วงเวลาย้อนหลังผ่านแบบจำลองการเรียนรู้เชิงลึกสองแบบต่อกัน
2. แบบจำลองสามารถให้ความคลาดเคลื่อนต่ำสุดเมื่อเทียบกับการใช้เทคนิคด้านอนุกรมเวลาและแบบจำลองการเรียนรู้เชิงลึกแบบต่างๆ

“การพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงไฟฟ้ากำลังสำหรับการประเมินสมรรถนะโดยใช้แบบจำลองการเรียนรู้ของเครื่อง” (สุวพันธุ์, 2019) วิทยานิพนธ์นี้ได้ศึกษาแบบจำลองการเรียนรู้ของเครื่องที่สามารถเรียนรู้พฤติกรรมที่เกิดความร้อนภายในหม้อแปลงโดยใช้ข้อมูลในอดีตเพื่อพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดของหม้อแปลงที่จะเกิดขึ้น

ก่อนการใช้งานจริง ข้อมูลดังกล่าวสามารถนำมาหาอายุการใช้งานที่คาดว่าจะสูญเสียไปของหม้อแปลงแต่ละตัว เพื่อใช้ในการวางแผนการส่งจ่ายกำลังไฟฟ้าและการบำรุงรักษา โดยงานวิจัยได้ทำการศึกษาเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่อง 4 รูปแบบ ได้แก่ โครงข่ายประสาทเทียม (Artificial Neural Network - ANN) ต้นไม้การตัดสินใจแบบประกอบป่าไม้สุ่ม (Random Forest - RF) โครงข่ายประสาทเทียมแบบวนซ้ำ ( Recurrent Neural Network - RNN ) และต้นไม้การถดถอยที่เคลื่อนที่ลงตามความชัน (Gradient Boosting Regression Tree - GBR) จากผลการทดลองสรุปผลได้ว่า

1. แบบจำลองโครงข่ายประสาทเทียม (ANN) ให้สมรรถนะในขั้นตอนการหาค่าอายุการใช้งานที่สูญเสียและการตรวจหาความผิดปกติของอุณหภูมิน้ำมันของหม้อแปลง A ที่ดีที่สุด และมีความคลาดเคลื่อน (MSE และ MAE) ต่ำที่สุด
2. แบบจำลอง RF ให้การพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนหม้อแปลง B มีความเหมาะสมในการใช้งานร่วมกับค่า %B ในขณะที่แบบจำลอง GBR จะเหมาะสมในการคำนวณอายุการใช้งานที่สูญเสียของหม้อแปลง
3. แบบจำลอง RF ให้ความคลาดเคลื่อนสะสมในการพยากรณ์ค่าอุณหภูมิขดลวดของหม้อแปลง A มีค่าต่ำที่สุด ดังนั้นจึงนำแบบจำลอง RF ไปใช้เพื่อการพยากรณ์ค่าของหม้อแปลง A
4. แบบจำลอง GBR ให้ความคลาดเคลื่อนสะสมในการพยากรณ์ค่าอุณหภูมิขดลวดของหม้อแปลง B มีค่าต่ำที่สุด ดังนั้นจึงนำแบบจำลอง RF ไปใช้เพื่อการพยากรณ์ค่าของหม้อแปลง B

**“Bearing fault diagnosis through vibration signals utilizing J-8 Decision Tree Algorithm”** (Arunkumar & Manjunath, 2018) เป็นงานวิจัยเพื่อวินิจฉัยความเสียหายของแบริ่งจากสัญญาณความสั่นสะเทือนในมอเตอร์เหนี่ยวนำ โดยใช้ J-8 Decision Tree Algorithm เปรียบเทียบกับการใช้ Random Forest Algorithm งานวิจัยเป็นการทำนายแบบแบ่งกลุ่ม (Classification) มีการพัฒนาความแม่นยำในการแบ่งกลุ่ม 3 ขั้นตอน ประกอบด้วย FE (Feature Extraction) , FS (Feature Selection) , FC (Feature Classification) ในการประเมินผลแบบจำลอง ใช้ Confusion matrix ในการประเมินจากการศึกษาที่หลากหลายพบว่าการใช้ RFA (Random Forest Algorithm) สามารถให้ค่าความบรรลุผลที่ 94.07% เมื่อเทียบกับ Algorithm อื่น

**“Vibration based fault diagnosis of monoblock centrifugal pump using decision tree”** (Sakthivel et al., 2010) งานวิจัยเป็นการนำการเรียนรู้ของเครื่อง เข้ามาช่วยในการวิเคราะห์ความเสียหายของปั๊มหอยโข่งโมโนบล็อกโดยใช้อัลกอริทึมต้นไม้ตัดสินใจโดยใช้

มาตรฐานที่เกิดจาก C5.0 (ID3 or C4.5) ที่ประกอบด้วยกิ่งก้านและโหนดจำนวนหนึ่งและใบไม้จำนวนหนึ่ง , อัลกอริทึม J48 ถูกใช้งานอย่างแพร่หลายในต้นไม้ตัดสินใจโดยความเสียหายหรือข้อบกพร่องที่ถูกใส่เข้าไปในคุณสมบัติ ประกอบด้วย (i) ข้อบกพร่องจากตลับลูกปืน (Bearing fault),(ii) ข้อบกพร่องของซีล (Seal fault), (iii) ข้อบกพร่องของใบพัด (Impeller fault) , (iv) ข้อบกพร่องของตลับลูกปืนร่วมกับใบพัด (Bearing and impeller fault together), (v) ข้อบกพร่องของการเกิดควิเท็นส์ (Cavitation) โดยชุดของคุณสมบัติข้อบกพร่องถูกแยกและจัดประเภทโดยใช้ อัลกอริทึมแผนผังการตัดสินใจ C4.5 ผลการวิจัยพบว่าตารางความสับสน (Confuse Metrix) ได้ค่าที่ทำให้มั่นใจได้ว่าอัลกอริทึม C4.5 สามารถนำไปประยุกต์ใช้ในการวินิจฉัยความผิดพลาดของปั๊มหอยโข่งโมโนบล็อกได้ และในการทดสอบด้วยข้อมูลทดสอบพบว่าได้ค่าความถูกต้องที่ 100%

**“Estimation of Remaining Useful Life of Electric Motor using supervised deep learning methods”** (Kewalramani & Ram, 2019) การเรียนรู้เชิงลึกได้รับการพิสูจน์แล้วว่าเป็นเครื่องมือที่มีประสิทธิภาพในการวิเคราะห์เชิงคาดการณ์ เนื่องจากความสามารถในการเข้าใจรูปแบบในชุดมหัต มีการใช้เทคนิคการเรียนรู้เชิงลึกภายใต้การดูแลเพื่อทำความเข้าใจความสัมพันธ์ระหว่างอายุของมอเตอร์ไฟฟ้ากับพารามิเตอร์ของเซ็นเซอร์จากสิ่งเดียวกัน ดังนั้น การใช้วิธีการเรียนรู้เชิงลึกภายใต้การดูแลจึงมีศักยภาพในการปรับใช้แบบจำลองชีวิตที่เหลืออยู่ (Remaining Useful Life - RUL) โดยมีข้อมูลการฝึกอบรมเพียงเล็กน้อย บทความนี้มุ่งเน้นไปที่การนำวิธีการเรียนรู้เชิงลึก (Feed Forward Neural networks) มาใช้สำหรับการคาดการณ์อายุการใช้งานที่เหลืออยู่สำหรับมอเตอร์ไฟฟ้า จุดมุ่งหมายของบทความคือการปรับปรุงความถูกต้องของการประมาณค่าอายุที่เหลืออยู่ (RUL) เมื่อเปรียบเทียบกับวิธีการเรียนรู้ของเครื่องภายใต้การดูแลแบบเดิม โดยทดลองใช้กับเซ็นเซอร์ 4 ตัว ของมอเตอร์ทั้งหมด 3 ตัว จากผลการสร้างแบบจำลองพบได้ค่าค่าประเมินผลดังต่อไปนี้ รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error : RMSE) = 21.31, ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error: MSE) = 16.55, อาร์กำลังสอง (R-Square) = 0.75

**“Research Advances in Fault Diagnosis and Prognostic based on Deep Learning”** (Zhao et al., 2016) งานวิจัยให้รายละเอียดเกี่ยวกับการวินิจฉัยข้อผิดพลาดโดยใช้การเรียนรู้เชิงลึก ทำการเปรียบเทียบข้อดีและข้อเสียระหว่างอัลกอริทึมการเรียนรู้เชิงลึก ประกอบด้วย DNN, DBN, CNN) พบว่า DNN หรือ DBN เหมาะสมกว่าในการจัดการกับข้อมูลแบบมิติเดียว แต่ CNN สามารถจัดการกับข้อมูลหลายมิติได้ดีกว่า เนื่องจากการนำ เทคนิคการบิด โดยปกติแล้ว DNN หรือ DBN จะใช้เพื่อดึงคุณลักษณะส่วนกลางจากข้อมูลข้อบกพร่อง นอกจากนี้ CNN

ยังมีประสิทธิภาพที่ยอดเยี่ยมในการดึงข้อมูลคุณลักษณะในเครื่อง นอกจากนี้ อัลกอริทึม CNN ยังซับซ้อนกว่า DNN และ DBN ดังนั้นจึงต้องใช้เวลาในการฝึกแบบจำลองขั้นสุดท้ายมากขึ้น

#### “Flight Delay Prediction Using a Hybrid Deep Learning Method”

(Cheevachaipimol et al., 2021) งานวิจัยได้นำการเรียนรู้ของเครื่องและอัลกอริทึมการเรียนรู้เชิงลึก เข้ามาประยุกต์ใช้ในการวิเคราะห์ข้อมูลการจราจรทางอากาศของสนามบินหลักในสหรัฐอเมริกาที่มีพื้นที่กว้างและมีความแออัดทางอากาศสูง โดยผลการทดลองพบว่าแบบจำลองการเรียนรู้เชิงลึกแบบไฮบริด ประสบผลสำเร็จในด้านผลลัพธ์การประเมินที่เหนือกว่าในการแก้ปัญหาที่ซับซ้อน เช่น การจัดกลุ่มภาพและการตรวจจับพฤติกรรมตามข้อมูลวิดีโอภาพที่ได้มา โดยจุดที่น่าสนใจอย่างหนึ่งคือ ยังไม่มีการทดลองก่อนหน้านี้ที่ใช้แนวคิดของการเรียนรู้เชิงลึกแบบไฮบริดมาใช้กับข้อมูลการจราจรทางอากาศแต่อย่างใด โดยแบบจำลองนี้ได้รับการผสมผสานแบบจำลองโครงข่ายประสาทเทียมแบบฟีดฟอร์เวิร์ด (Feed-Forward Artificial Neural Network) จำนวนสามชั้นซ้อนกับแบบจำลองต้นไม้ไล่ระดับสีแบบเดิม (Conventional Gradient Boosted Tree model – XGBoost) โดยแบบจำลองที่เสนอนี้มีความแม่นยำเพิ่มขึ้น 22.94% เมื่อเทียบกับแบบจำลองโครงข่ายประสาทเทียมแบบธรรมดา

สำหรับการทบทวนวรรณกรรมดังที่ได้กล่าวไปข้างต้นนี้เห็นได้ชัดว่ายังไม่มีของบทความหรือวรรณกรรมที่ได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองที่สร้างจากอัลกอริทึมทั้งหมด 4 แบบประกอบด้วย โครงข่ายประสาทเทียม (Artificial Neural Network) , การเพิ่มประสิทธิภาพของอนุภาคฝูง (Particle Swarm Optimization) , ต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสี (Gradient Boosting Decision Trees) และป่าไม้สุ่ม (Random Forest) ของ ML ที่จะกล่าวถึงต่อไปในบทที่ 3 นำมาใช้กับชุดข้อมูล IM มาก่อน นอกจากนี้ ภายใต้บริบทการทำนายดัชนีสุขภาพของ IM ก็ยังไม่เคยใช้อัลกอริทึมการเพิ่มประสิทธิภาพของอนุภาคฝูงในการสร้างแบบจำลองมาก่อน ซึ่งบทความที่ใกล้เคียงที่สุดในการวิจัยนี้จัดทำโดย (Tao et al., 2016) แต่อย่างไรก็ตาม พารามิเตอร์ IM ที่ใช้ในงานวิจัยนั้นมีจำนวนน้อยกว่าที่นำเสนอในงานวิจัยนี้และใช้แบบจำลอง ML ที่ต่างออกไปในการทำนาย



### บทที่ 3

#### วิธีดำเนินงานวิจัย

##### 3.1 การออกแบบการทดลอง

ชุดข้อมูลที่ใช้ในงานวิจัยฉบับนี้รวบรวมค่าพารามิเตอร์ที่เก็บค่ามาจากเซ็นเซอร์ของมอเตอร์เหนี่ยวนำ ขนาด 475 กิโลวัตต์, 2 ขั้ว, 50 เฮิร์ต, 3 เฟส, 6.6 กิโลโวลต์, 2988 รอบต่อนาที ช่วงเวลาของข้อมูลทุกๆหนึ่งชั่วโมง ระยะเวลาตั้งแต่ ปีค.ศ.2010 ถึง ปีค.ศ.2021


สำหรับคอมพิวเตอร์ที่ใช้ในการเขียนโปรแกรมด้วยภาษาไพธอนในการสร้างแบบจำลอง มีข้อมูลประกอบด้วย Processor: Intel(R) Core (TM) i7-8650U CPU @ 1.90GHz 2.11 GHz , System type type: 64-bit operating system, x64-based processor และ ะ Edition: Windows 11 Pro

##### 3.1.1 การจัดการข้อมูลก่อนการสร้างแบบจำลอง

เป็นกระบวนการจัดการและแก้ไขข้อมูลที่เสียหาย ไม่ถูกต้อง หรือไม่เกี่ยวข้องที่เกิดจากความผิดปกติของเซ็นเซอร์หรือข้อผิดพลาดอื่นๆ ที่ส่งผลต่อค่าจริงหรือค่าที่ผิดเพี้ยนไม่เป็นความจริงหรือไม่ตรงกับค่าจริงของข้อมูล ซึ่งค่าผิดปกติเหล่านี้ไม่สามารถนำเข้ามาใช้งานได้ ขั้นตอนการจัดการข้อมูลนี้เรียกอีกอย่างว่าการล้างข้อมูล (Data Cleansing) เป็นกระบวนการตรวจสอบ การแก้ไข หรือการลบ เพื่อให้รายการข้อมูลที่ไม่ถูกต้องออกไปจากชุดข้อมูล ตารางหรือฐานข้อมูล นอกจากนั้นยังเป็นขั้นตอนสำคัญในการปรับปรุงความสม่ำเสมอ ความถูกต้องและความน่าเชื่อถือของข้อมูลก่อนสร้างแบบจำลอง เป็นต้น สำหรับงานวิจัยจะจัดการกับข้อมูลไม่ถูกต้องนี้ โดยการลบข้อมูลออก

สำหรับข้อมูลพารามิเตอร์ของมอเตอร์เหนี่ยวนำที่พิจารณา ได้แก่ การสั่นสะเทือน (หน่วยอัตราเร่งและความเร็ว ในแนวแกน, แนวนอนและแนวตั้ง) ,อุณหภูมิพื้นผิว, กระแสไฟฟ้าเข้า, กำลังไฟฟ้าเข้า และอัตราการไหลของสารในระบบ โดยอัตราการเปลี่ยนแปลงของพารามิเตอร์เหล่านี้จะส่งผลต่อการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ ที่จะเป็นข้อมูลนำเข้าสำหรับฝึกฝนแบบจำลองต่อไป

คุณลักษณะ (Attribute) หรือพารามิเตอร์ และตำแหน่งที่ติดเซ็นเซอร์ของมอเตอร์เหนี่ยวนำแสดงในรูปที่ 19



รูปที่ 19 อ่างอิงจุดวัดสำหรับเก็บค่าพารามิเตอร์ของมอเตอร์

รูปแบบข้อมูลจริงที่ได้จากเซ็นเซอร์ ดังแสดงในตารางที่ 12 โดยจำนวนพารามิเตอร์ตั้งต้นที่จะนำเข้ามาสำหรับวินิจัยในเบื้องต้นมีจำนวนทั้งหมด 17 พารามิเตอร์

ประกอบด้วย

Acc_DE_Ax	คือ อัตราเร่งของการสั่นสะเทือน ณ ตลับลูกปืนฝาน้ำมอเตอร์ในแนวแกน
Acc_DE_RH	คือ อัตราเร่งของการสั่นสะเทือน ณ ตลับลูกปืนฝาน้ำมอเตอร์ในแนวนอน
Acc_DE_RV	คือ อัตราเร่งของการสั่นสะเทือน ณ ตลับลูกปืนฝาน้ำมอเตอร์ในแนวตั้ง
Acc_NDE_Ax	คือ อัตราเร่งของการสั่นสะเทือน ณ ตลับลูกปืนฝาลังมอเตอร์ในแนวแกน
Acc_NDE_RH	คือ อัตราเร่งของการสั่นสะเทือน ณ ตลับลูกปืนฝาลังมอเตอร์ในแนวนอน
Acc_NDE_RV	คือ อัตราเร่งของการสั่นสะเทือน ณ ตลับลูกปืนฝาลังมอเตอร์ในแนวตั้ง
Temp_DE	คือ อุณหภูมิพื้นผิว ณ ตลับลูกปืนฝาน้ำ
Temp_NDE	คือ อุณหภูมิพื้นผิว ณ ตลับลูกปืนฝาลัง
Vel_DE_Ax	คือ ความเร็วของการสั่นสะเทือน ณ ตลับลูกปืนฝาน้ำมอเตอร์ในแนวแกน
Vel_DE_RH	คือ ความเร็วของการสั่นสะเทือน ณ ตลับลูกปืนฝาน้ำมอเตอร์ในแนวนอน
Vel_DE_RV	คือ ความเร็วของการสั่นสะเทือน ณ ตลับลูกปืนฝาน้ำมอเตอร์ในแนวตั้ง
Vel_NDE_Ax	คือ ความเร็วของการสั่นสะเทือน ณ ตลับลูกปืนฝาลังมอเตอร์ในแนวแกน
Vel_NDE_RH	คือ ความเร็วของการสั่นสะเทือน ณ ตลับลูกปืนฝาลังมอเตอร์ในแนวนอน
Vel_NDE_RV	คือ ความเร็วของการสั่นสะเทือน ณ ตลับลูกปืนฝาลังมอเตอร์ในแนวตั้ง
I_SYS	คือ กระแสขาเข้าระบบ
P_SYS	คือ กำลังไฟฟ้าขาเข้าระบบ
Q_SYS	คือ อัตราการไหลของสารในระบบ

ตารางที่ 12 คุณลักษณะ/พารามิเตอร์ที่นำเข้ามาสำหรับการทำนายสุขภาพของมอเตอร์เหนี่ยวนำ

Attribute Name	Parameter	Unit	Direction	Location
Acc_DE_Ax	Acceleration	m/s <sup>2</sup>	Axial	Drive end
Acc_DE_RH	Acceleration	m/s <sup>2</sup>	Horizontal	Drive end
Acc_DE_RV	Acceleration	m/s <sup>2</sup>	Vertical	Drive end
Acc_NDE_Ax	Acceleration	m/s <sup>2</sup>	Axial	Non drive end
Acc_NDE_RH	Acceleration	m/s <sup>2</sup>	Horizontal	Non drive end
Acc_NDE_RV	Acceleration	m/s <sup>2</sup>	Vertical	Non drive end
Temp_DE	Temperature	degrees Celsius	Horizontal	Drive end
Temp_NDE	Temperature	degrees Celsius	Horizontal	Non drive end
Vel_DE_Ax	Velocity	mm/s	Axial	Drive end
Vel_DE_RH	Velocity	mm/s	Horizontal	Drive end
Vel_DE_RV	Velocity	mm/s	Vertical	Drive end
Vel_NDE_Ax	Velocity	mm/s	Axial	Non drive end
Vel_NDE_RH	Velocity	mm/s	Horizontal	Non drive end
Vel_NDE_RV	Velocity	mm/s	Vertical	Non drive end
I_SYS	Current	Ampere	-	System
P_SYS	Power	kW	-	System
Q_SYS	Flow Rate	m <sup>3</sup> /h	-	System

และข้อมูลดิบในรูปแบบไฟล์ Comma-Separated Value (.csv file) จากฐานข้อมูลของระบบที่นำเข้ามาใช้สำหรับพิจารณาสร้างแบบจำลองการประเมินดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ แสดงดังรูปที่ 20




หลังจากทำการปรับตั้งให้แต่ละพารามิเตอร์อยู่ในรูปเป็นมาตรฐานค่าคะแนน  $Z$  แล้ว จากนั้นจะนำข้อมูลเหล่านี้เข้าสู่กระบวนการจัดกลุ่มในการประเมินระดับดัชนีสุขภาพต่อไป

### 3.1.2 การจัดกลุ่มข้อมูลสำหรับการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ

มาตรฐานสากลที่ใช้อ้างอิงในการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำในการศึกษานี้แสดงไว้ในตารางที่ 13 ประกอบด้วยมาตรฐานที่ใช้อ้างอิงระดับการสั่นสะเทือนและอุณหภูมิ แต่สำหรับค่ากระแสไฟฟ้า, กำลังไฟฟ้า และอัตราการไหล จะกำหนดจากข้อกำหนดการใช้งานเครื่องจักรจากฝั่งผู้ผลิต

ตารางที่ 13 มาตรฐานและข้อกำหนดที่ใช้อ้างอิงในการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำในงานวิจัย



Attribute	Standard and specification
Vibration	ISO-10816 Part 3
Temperature	ANSI/NETA MTS-2019
Current, Voltage and Flow rate	Machine specifications and manufacturing guidelines

สำหรับงานวิจัยนี้ จะทำการแบ่งระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ ออกเป็น 4 กลุ่ม ประกอบด้วย กลุ่ม 0, กลุ่ม 1, กลุ่ม 2 และกลุ่ม 3 เนื่องจากอ้างอิงจากมาตรฐาน ISO-10816 Part 3 ที่แบ่งเกณฑ์การประเมินการสั่นสะเทือนออกเป็น 4 กลุ่ม คือ A แทน เครื่องจักรที่ได้รับการติดตั้งใหม่ (Newly commissioned machinery), B แทน การไม่จำกัดการดำเนินงานของเครื่อง (Unrestricted operation), C แทน การจำกัดการดำเนินงานของเครื่อง (Restricted operation), และ D แทน เครื่องจักรเกิดความเสียหายขึ้น (Damage occurred) ดังนั้นจึงเป็นเกณฑ์ตั้งต้นที่นำมาเทียบเคียงเพื่อใช้สำหรับแบ่งกลุ่มการประเมินดัชนีสุขภาพ


สำหรับพารามิเตอร์ที่ได้กล่าวในเบื้องต้นและอ้างอิงเกณฑ์ในการประเมินระดับความรุนแรงจากมาตรฐานสากล รวมถึงข้อกำหนดการใช้งานเครื่องจักร ในด้านรายละเอียดการแบ่งกลุ่มนั้น อธิบายไว้ในตารางที่ 14

ตารางที่ 14 การแบ่งกลุ่มดัชนีสุขภาพของมอเตอร์เหนียวน้ำ

คุณลักษณะที่พิจารณา	กลุ่มดัชนีสุขภาพของมอเตอร์เหนียวน้ำ				หน่วย
	0	1	2	3	
ความเร็วของการสั่นสะเทือน	<2.3	2.3-4.5	4.5-7.1	>7.1	mm/sec rms.
อัตราเร่งของการสั่นสะเทือน	< $\bar{X}$	> ( $\bar{X}$ + 2*SD)	> ( $\bar{X}$ + 4*SD)	> ( $\bar{X}$ + 6*SD)	g's
อุณหภูมิเพิ่มขึ้นจากสภาพแวดล้อม	1-10	10-20	20-40	>40	°C
กระแสไฟฟ้า	11-26	26-37	37-43	<11, >43	Ampere
กำลังไฟฟ้า	<320	>350	>360	>403	kW
อัตราการไหลของสารในระบบ	<90	>123	>154	>187	m <sup>3</sup> /h

หมายเหตุ :  $\bar{X}$  แทน ค่ากลางของข้อมูล , Standard Deviation (SD) แทน ส่วนเบี่ยงเบนมาตรฐานของข้อมูล


สำหรับการประเมินกลุ่มดัชนีสุขภาพมอเตอร์เหนียวน้ำในเบื้องต้น จะพิจารณาจากพารามิเตอร์เข้าจำนวน 17 พารามิเตอร์ ดังแสดงในตารางที่ 12 นำค่าแต่ละตัวมาให้คะแนนการจัดกลุ่มดังตารางที่ 14 จะได้ค่ากลุ่มสถานะดัชนีสุขภาพมอเตอร์มาทั้งหมด 17 ค่า จากนั้นจะทำการเลือกค่าสถานะที่มากที่สุดของแถวนั้นๆ เป็นตัวแทนของกลุ่มดัชนีสุขภาพ ดังแสดงในรูปที่ 21




รูปที่ 21 ตัวอย่างขั้นตอนการประเมินการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ

เมื่อเสร็จสิ้นกระบวนการแบ่งกลุ่มดัชนีสุขภาพของมอเตอร์เหนี่ยวนำแล้ว พบว่า สัดส่วนข้อมูลการจัดกลุ่มประกอบด้วย กลุ่ม 0 , 1 , 2 และ 3 เท่ากับ 10.06% , 86.03% , 2.73% และ 1.18% ตามลำดับ รายละเอียดดังแสดงในรูปที่ 22

Class=1, n=4097 (86.035%)  
 Class=2, n=130 (2.730%)  
 Class=3, n=56 (1.176%)  
 Class=0, n=479 (10.059%)



าลัย



รูปที่ 22 การจัดกลุ่มดัชนีสุขภาพของมอเตอร์เหนี่ยวนำก่อนการนำเทคนิค Synthetic Minority Over-sampling Technique เข้ามาปรับใช้

เมื่อนำระดับดัชนีสุขภาพของมอเตอร์ที่ระดับ 0,1,2 และ 3 มาแบ่งละเอียดแยกออกเป็นการประเมินย่อยเข้าไปในแต่ละคุณลักษณะ จะพบว่าทุกๆคุณลักษณะมีระดับความรุนแรงที่จัดระดับออกมาในกลุ่ม 0 และ 1 แต่สำหรับความรุนแรงในกลุ่ม 2 และ 3 นั้น จะมีเฉพาะบางคุณลักษณะเท่านั้น ที่ปรากฏค่าขึ้นสูงไปแต่ละระดับที่กำหนดไว้ สำหรับระดับดัชนีสุขภาพกลุ่มที่ 3 บ่งบอกความรุนแรงของระดับสุขภาพที่สูงสุดนั้น คุณลักษณะที่เป็นตัวบ่งชี้สำคัญ 3 ลำดับแรกประกอบด้วย Acc\_DE\_Ax , I\_SYS และ Acc\_DE\_RH ตามลำดับ แสดงถึงข้อมูลการแจ้งเตือนที่มาจากทั้งค่าทางกลคือค่าการสั่นสะเทือน (ค่าของ Acc\_DE\_Ax และ Acc\_DE\_RH) และค่าทางไฟฟ้า (คือ I\_SYS) ดังสมมุติฐานที่ได้กล่าวไปเบื้องต้นในบทที่ 1

การประเมินดัชนีสุขภาพของมอเตอร์เหนี่ยวนำจากแต่ละคุณลักษณะ แสดงดังตารางที่ 15

ตารางที่ 15 การประเมินดัชนีสุขภาพของมอเตอร์เหนี่ยวนำจากแต่ละคุณลักษณะ

คุณลักษณะ/พารามิเตอร์	ระดับความรุนแรง				
	0	1	2	3	Grand Total
Acc_DE_Ax	4,599	125	17	21	4,762
Acc_DE_RH	4,651	81	20	10	4,762
Acc_DE_RV	4,612	129	21	-	4,762
Acc_NDE_Ax	4,744	18	-	-	4,762
Acc_NDE_RH	4,717	44	1	-	4,762
Acc_NDE_RV	4,730	22	8	2	4,762
Temp_DE	3,673	1,044	37	8	4,762
Temp_NDE	4,728	31	3	-	4,762
Vel_DE_Ax	4,729	33	-	-	4,762
Vel_DE_RH	4,644	118	-	-	4,762
Vel_DE_RV	4,686	76	-	-	4,762
Vel_NDE_Ax	4,712	16	34	-	4,762
Vel_NDE_RH	4,642	120	-	-	4,762
Vel_NDE_RV	4,644	36	82	-	4,762
I_SYS	4,653	78	12	19	4,762
P_SYS	4,396	339	23	4	4,762
Q_SYS	1,030	3,718	14	-	4,762
<b>กลุ่มดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ</b>	<b>479</b>	<b>4,097</b>	<b>130</b>	<b>56</b>	<b>4,762</b>





เมื่อพิจารณาการแบ่งกลุ่มดัชนีสุขภาพมอเตอร์เหนียวนำ ดังที่กล่าวไปเบื้องต้นแล้ว จะพบว่าข้อมูลเป็นไปในลักษณะไม่สมดุล (Unbalance) จึงต้องเข้าสู่กระบวนการจัดการข้อมูลที่ไม่สมดุลต่อไป

### 3.1.3 การจัดการข้อมูลที่ไม่สมดุล

สำหรับงานวิจัยนี้จะอ้างอิงเทคนิค Synthetic Minority Over-sampling TEchnique (SMOTE) เข้ามาจัดการกับข้อมูลที่ไม่สมดุล โดย SMOTE เป็นเทคนิคการสุ่มตัวอย่างเพิ่ม โดยสังเคราะห์ตัวอย่างที่เพิ่มขึ้นมาจากข้อมูลในชนกลุ่มน้อย เพื่อให้มีจำนวนใกล้เคียงหรือเท่ากับจำนวนข้อมูลที่มีอยู่ในชนกลุ่มมาก โดยอัลกอริทึมนี้จะช่วยแก้ปัญหาคิดเกินไป (overfitting) จากการสุ่มตัวอย่างที่มากเกินไป โดยเน้นที่พื้นที่ของคุณลักษณะ (feature) ที่ใกล้ที่สุด เพื่อสร้างตัวอย่างใหม่ (วิชญ์วิสิฐ เกษรสิทธิ์, 2018) เมื่อผ่าน SMOTE เทคนิคแล้ว จะได้ตัวอย่างของกลุ่ม 0 , 2 และ 3 ที่มีจำนวนเพิ่มขึ้นมาเท่ากับจำนวนข้อมูลของตัวอย่างชนกลุ่มมากคือกลุ่ม 1 แสดงดังรูปที่ 23

Class=1, n=4097 (25.000%)  
Class=2, n=4097 (25.000%)  
Class=3, n=4097 (25.000%)  
Class=0, n=4097 (25.000%)



รูปที่ 23 การจัดการกลุ่มดัชนีสุขภาพของมอเตอร์เหนียวนำหลังการนำเทคนิค Synthetic Minority Over-sampling Technique เข้ามาปรับใช้

### 3.1.4 การวัดผลการประเมิน (Evaluation Metrics)

หลังจากสร้างแบบจำลองแล้ว เพื่อวัดผลแบบประสิทธิภาพหรือสมรรถนะของแต่ละแบบจำลองในงานวิจัยนี้ใช้ค่าความถูกต้องเพียงตรง (Accuracy), ความแม่นยำ (Precision), ค่าความถูกต้อง (Recall), ค่าเฉลี่ยของความแม่นยำและค่าความถูกต้องหรือแทนด้วยคะแนน F1 (F1-score) นอกจากนั้นยังใช้ค่าพื้นที่ใต้เส้นโค้ง (Area Under the Curve - AUC) -ROC (Receiver Operating Characteristic - ROC) เข้ามาช่วยในการพิจารณาเลือกแบบจำลองที่เหมาะสมกับ

ฐานข้อมูล สำหรับสมการที่นิยามค่า Accuracy , Precision , Recall และ F1-score ได้แสดงไว้แล้ว ในสมการที่ (16) – (19) ตามลำดับ ในบทที่ 2

สำหรับเส้นโค้ง ROC นั้นแสดงถึงแบบจำลองที่สามารถแยกแยะระหว่างสองสิ่งได้ดีเพียงใด โดยแบบจำลองที่ดีนั้นสามารถแยกแยะความแตกต่างระหว่างสิ่งสองสิ่งได้อย่างแม่นยำ ในขณะที่ AUC จะแสดงถึงระดับความสามารถในการแยกแยะนี้ออกมาเป็นตัวเลข โดยเมื่อ AUC เข้าใกล้ 1 หมายถึงแบบจำลองสามารถแยกตัวออกจากกันในแต่ละกลุ่มได้ในระดับสูง ในทางตรงกันข้าม หากแบบจำลองไม่มีศักยภาพในการแยกกลุ่ม ค่า AUC ก็ยิ่งเข้าใกล้ 0 (Narkhede, 2018)

### 3.1.5 การสร้างแบบจำลองโดยใช้การเรียนรู้ของเครื่อง (Machine Learning Model)

สำหรับข้อมูลที่น่าเข้ามาเพื่อใช้ในการสร้างแบบจำลองการประเมินระดับดัชนีสุขภาพของมอเตอร์เหนี่ยวนำนั้น มีพารามิเตอร์หลากหลายที่จะส่งผลต่อสุขภาพของมอเตอร์เหนี่ยวนำ พารามิเตอร์ต่างๆเหล่านี้เป็นสิ่งสำคัญที่ต้องนำมาพิจารณา เพราะปัจจัยเหล่านี้หากไม่สำคัญโดยตรงกับแบบจำลองก็จะส่งต่อความถูกต้องแม่นยำและประสิทธิภาพของแบบจำลอง ดังนั้นในงานวิจัยจะใช้หลักการเลือกพารามิเตอร์ผ่านการวิเคราะห์ทางสถิติ ดังต่อไปนี้

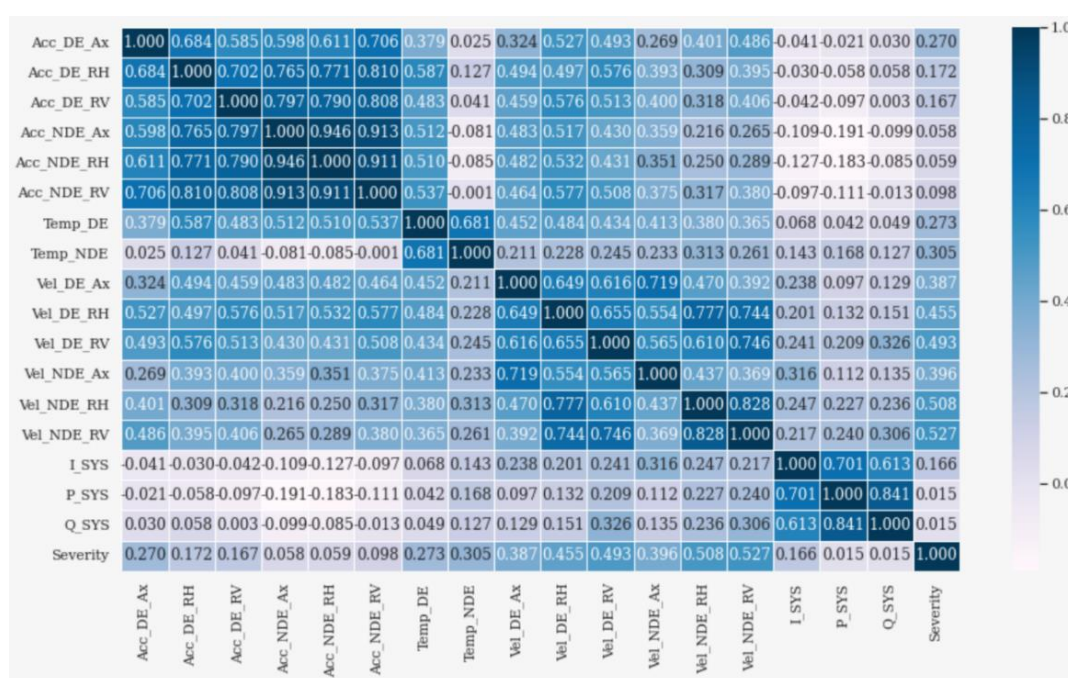
#### 3.1.5.1 การเลือกพารามิเตอร์โดยพิจารณาค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน

การเลือกพารามิเตอร์เป็นกระบวนการสำคัญที่ใช้เพื่อค้นหาเซตย่อยที่เล็กที่สุดของพารามิเตอร์ ที่จะส่งผลอย่างมากต่อดัชนีสุขภาพของมอเตอร์เหนี่ยวนำ ในงานวิจัยนี้ใช้ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson Correlation Coefficient - PCC) เป็นเทคนิคทางสถิติที่ใช้วัดความสัมพันธ์เชิงเส้นตรงหรือการเชื่อมโยงระหว่างตัวแปรตั้งแต่สองตัวขึ้นไป โดยความสัมพันธ์ดังกล่าวจะบอกให้ทราบว่า พฤติกรรมของพารามิเตอร์หนึ่งจะแปรผันตามความสัมพันธ์กับอีกพารามิเตอร์หนึ่ง ถ้าค่าของ PCC ระหว่างตัวแปรตั้งแต่สองตัวขึ้นไปมีค่ามาก ในงานวิจัยนี้จะกำหนดว่าหากค่า PCC มีค่ามากกว่า 0.95 ถือว่าความสัมพันธ์ระหว่างตัวแปร 2 ตัวนั้นมีค่าสูง จึงจะทำการเลือกเก็บแค่ตัวแปรใดตัวแปรหนึ่งไว้ (เก็บ  $x$  หนึ่งไว้) เป็นตัวแทนของกลุ่ม ที่จะส่งผลกระทบต่อตัวแปรตอบสนอง  $y$  มากที่สุด ส่วนอีกตัวแปรหนึ่ง ( $x$  อีกตัว) จะถูกตัดออก

รูปที่ 24 แสดงค่า PPC ระหว่าง 17 พารามิเตอร์ที่แตกต่างกัน ( $x$  ใดๆที่เป็นข้อมูลขาเข้า) ของชุดข้อมูลมอเตอร์เหนี่ยวนำ จะเห็นได้ชัดว่าไม่มีองค์ประกอบใดหรือพารามิเตอร์ใดในรูปที่ 24 ที่มีค่า PCC มากกว่า 0.95 ซึ่งหมายความว่าความสัมพันธ์ของพารามิเตอร์เหล่านี้ไม่สูงพอที่จะตัดพารามิเตอร์ใดออก

เมื่อผ่านกระบวนการเลือกพารามิเตอร์จากค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันจะพบว่า ยังคงเหลือพารามิเตอร์ทั้งหมด 17 พารามิเตอร์ที่จะนำไปใช้งานและเข้าสู่กระบวนการเลือกพารามิเตอร์จากเทคนิคอื่นต่อไป

หมายเหตุ : สำหรับตัวแปรตอบสนอง  $y$  ในงานวิจัยนี้คือค่าดัชนีสุขภาพของมอเตอร์เหนี่ยวนำที่แบ่งเป็น กลุ่ม 0 ถึง กลุ่ม 3 และสำหรับในรูปที่ 24 แสดงด้วยค่าระดับความรุนแรง (Severity)



รูปที่ 24 ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่าง 17 พารามิเตอร์ที่แตกต่างกัน

CHULALONGKORN UNIVERSITY

### 3.1.5.2 การเลือกพารามิเตอร์โดยพิจารณาใช้การถดถอยแบบพหุคูณ

หลังจากผ่านกระบวนการพิจารณาจากสัมประสิทธิ์สหสัมพันธ์เพียร์สันแล้ว ขั้นตอนต่อไปคือการใช้การถดถอยพหุคูณ (Multiple Regression) กับชุดข้อมูลมอเตอร์เหนี่ยวนำ เพื่อค้นหาพารามิเตอร์เหล่านี้มีนัยสำคัญหรือไม่ โดยการสร้างสมการถดถอยที่เป็นการแสดงออกถึงความสัมพันธ์ทางสถิติระหว่างหนึ่งหรือมากกว่าในพารามิเตอร์ของมอเตอร์เหนี่ยวนำทั้ง 17 พารามิเตอร์ ที่สำคัญมากพอที่จะส่งผลต่อตัวแปรตอบสนอง  $y$  และงานวิจัยนี้ใช้ซอฟต์แวร์ Minitab มาเป็นเครื่องมือในการวิเคราะห์การถดถอยแบบพหุคูณ

การวิเคราะห์ความแปรปรวน (ANOVA) ที่ได้จากขั้นตอนการพิจารณาการถดถอยพหุคูณ จากซอฟต์แวร์ Minitab แสดงไว้ในตารางที่ 16 จะสังเกตพบว่ามีค่า  $P$  ของพารามิเตอร์

ของมอเตอร์เหนี่ยวนำ ประกอบด้วย Acc\_DE\_RV, ACC\_NDE\_Ax และ Vel\_DE\_RH มีค่ามากกว่า 0.05 (ที่เป็นระดับความสำคัญ) แสดงถึงพารามิเตอร์เหล่านี้ไม่มีนัยสำคัญที่จะส่งผลกระทบต่อดัชนีสุขภาพของมอเตอร์เหนี่ยวนำหรือตัวแปรตอบสนอง  $y$  ดังนั้นพารามิเตอร์เหล่านี้จึงถูกลบออกจากชุดข้อมูล และไม่ถูกนำมาพิจารณาเป็นชุดข้อมูลในการนำไปสร้างแบบจำลอง

เมื่อผ่านขั้นตอนการพิจารณาจากการถดถอยหาค่าแล้ว จะเหลือพารามิเตอร์สุทธิที่จะนำไปใช้สำหรับสร้างแบบจำลองจำนวนทั้งสิ้น 14 พารามิเตอร์ ประกอบด้วย Acc\_DE\_Ax, Acc\_DE\_RH, Acc\_NDE\_RH, Acc\_NDE\_RV, Temp\_DE, Temp\_NDE, Vel\_DE\_Ax, Vel\_DE\_RV, Vel\_NDE\_Ax, Vel\_NDE\_RH, Vel\_NDE\_RV, I\_SYS, P\_SYS และ Q\_SYS ตามลำดับ แสดงดังตารางที่ 17 คือพารามิเตอร์สุทธิท้ายสุด ที่ใช้เป็นข้อมูลนำเข้าสำหรับการสร้างแบบจำลอง

ตารางที่ 16 การวิเคราะห์ความแปรปรวน (ANOVA)

#### Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	17	382.358	22.4916	243.14	0.000
Acc_DE_Ax	1	15.266	15.2665	165.03	0.000
Acc_DE_RH	1	1.454	1.4541	15.72	0.000
Acc_DE_RV	1	0.067	0.0674	0.73	0.393
Acc_NDE_Ax	1	0.117	0.1169	1.26	0.261
Acc_NDE_RH	1	0.486	0.4860	5.25	0.022
Acc_NDE_RV	1	6.347	6.3469	68.61	0.000
Temp_DE	1	0.475	0.4754	5.14	0.023
Temp_NDE	1	1.576	1.5762	17.04	0.000
Vel_DE_Ax	1	4.514	4.5142	48.80	0.000
Vel_DE_RH	1	0.212	0.2117	2.29	0.130
Vel_DE_RV	1	12.135	12.1348	131.18	0.000
Vel_NDE_Ax	1	3.054	3.0541	33.02	0.000
Vel_NDE_RH	1	0.455	0.4548	4.92	0.027
Vel_NDE_RV	1	10.272	10.2724	111.05	0.000
I_SYS	1	6.096	6.0959	65.90	0.000
P_SYS	1	4.441	4.4412	48.01	0.000
Q_SYS	1	6.239	6.2391	67.45	0.000
Error	4744	438.847	0.0925		


ตารางที่ 17 พารามิเตอร์สุดท้าย ที่ใช้เป็นข้อมูลนำเข้าสำหรับการสร้างแบบจำลอง

Attribute Name	Parameter	Unit	Direction	Location
Acc_DE_Ax	Acceleration	m/s <sup>2</sup>	Axial	Drive end
Acc_DE_RH	Acceleration	m/s <sup>2</sup>	Horizontal	Drive end
Acc_NDE_RH	Acceleration	m/s <sup>2</sup>	Horizontal	Non drive end
Acc_NDE_RV	Acceleration	m/s <sup>2</sup>	Vertical	Non drive end
Temp_DE	Temperature	degrees Celsius	Horizontal	Drive end
Temp_NDE	Temperature	degrees Celsius	Horizontal	Non drive end
Vel_DE_Ax	Velocity	mm/s	Axial	Drive end
Vel_DE_RV	Velocity	mm/s	Vertical	Drive end
Vel_NDE_Ax	Velocity	mm/s	Axial	Non drive end
Vel_NDE_RH	Velocity	mm/s	Horizontal	Non drive end
Vel_NDE_RV	Velocity	mm/s	Vertical	Non drive end
I_SYS	Current	Ampere	-	System
P_SYS	Power	kW	-	System
Q_SYS	Flow Rate	m <sup>3</sup> /h	-	System

### 3.2 ขั้นตอนการดำเนินการทดลอง

ขั้นตอนการดำเนินการทดลองของงานวิจัยการสร้างแบบจำลองสำหรับพยากรณ์ดัชนีสุขภาพของมอเตอร์เหนี่ยวนำนั้นจะใช้อัลกอริทึมทั้งหมด 4 แบบ ประกอบด้วย โครงข่ายประสาทเทียม (Artificial Neural Network), การเพิ่มประสิทธิภาพของอนุภาคฝูง (Particle Swarm Optimization), ต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสี (Gradient Boosting Decision Trees) และป่าไม้สุ่ม (Random Forest) นำมาสร้างแบบจำลองจากนั้นจะทดสอบประสิทธิภาพของแต่ละ

แบบจำลองและเปรียบเทียบผล โดยขั้นตอนกระบวนการทำงานหรือการสร้างแบบจำลองในการพยากรณ์นั้น แสดงดังแผนภาพในรูปที่ 25



รูปที่ 25 ขั้นตอนการดำเนินการสร้างแบบจำลอง

### 3.3 การสร้างแบบจำลองโดยใช้โครงข่ายประสาทเทียม (Artificial Neural Network - ANN)

การสร้างแบบจำลองโดยใช้โครงข่ายประสาทเทียมในงานวิจัยฉบับนี้ ใช้การค้นหาไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุด (Hyper-Parameter Optimization) ด้วยออปทูนนา (Optuna) โดยไฮเปอร์พารามิเตอร์ที่นำมาใช้พิจารณา ประกอบด้วย ขนาดชั้นซ่อน (Hidden layer size), การเปิดใช้งาน (activation), ตัวแก้ (solver), อัตราการเรียนรู้ (Learning rate) และจำนวนการทำซ้ำสูงสุด

(Maximun number of iterations) นอกเหนือจากไฮเปอร์พารามิเตอร์ที่ได้กล่าวมาข้างต้นนี้ ทางผู้จัดทำจะตั้งค่าให้เป็นค่าเริ่มต้น (default) ที่กำหนดมาโดยอัลกอริทึมอื่นๆ

ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับจูนในแบบจำลอง ANN รวมถึงพิสัยที่ใช้พิจารณาสำหรับงานวิจัยฉบับนี้ แสดงดังตารางที่ 18 และท้ายที่สุดเมื่อผ่านกระบวนการออกแบบแล้ว จะได้ค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมสำหรับแบบจำลองโครงข่ายประสาทเทียมกับชุดของข้อมูลดังแสดงในตารางที่ 19 ประกอบด้วย ขนาดชั้นซ่อนที่มีค่า (64,4), การเปิดใช้งานเป็นแบบ relu , ตัวแก้ชนิด sgd, อัตราการเรียนรู้ เท่ากับ 0.35 และจำนวนการทำซ้ำสูงสุดเท่ากับ 150


ในการเลือกไฮเปอร์พารามิเตอร์ที่นำมาปรับจูนเพื่อให้เหมาะสมกับแบบจำลองแล้ว จะมีหลักการที่ใช้พิจารณาถึงความสำคัญของไฮเปอร์พารามิเตอร์แต่ละตัวที่มีต่อแบบจำลอง ANN ที่สร้างขึ้น โดยกระบวนการออกแบบนี้ ยังบ่งบอกถึงความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับจูนด้วยเช่นกัน ดังรูปที่ 26 เป็นกราฟแสดงความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาปรับจูนเพื่อให้เหมาะสมกับแบบจำลอง ANN จากรูปจะพบว่าอัตราการเรียนรู้ (Learning rate) หรือหลักพารามิเตอร์ชื่อ learning\_rate\_int เป็นไฮเปอร์พารามิเตอร์ที่สำคัญที่สุดสำหรับแบบจำลองกับชุดข้อมูลมอเตอร์เหนี่ยวนำนี้

ตารางที่ 18 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับจูนในแบบจำลอง ANN รวมถึงพิสัยที่ใช้พิจารณา

Parameter	Parameter keys	Range
Hidden layer size	hidden_layer_sizes	[16,4], [32,4], [64,4], [128,4], [256,4]
Activation function for hidden layer	activation	['logistic', 'tanh', 'relu']
The solver for weigh optimisation	solver	['lbfgs', 'sgd']
Learning rate	learning_rate_int	[0.01,1.00, step=0.05]
Maximun number of iterations	max_iter	[50,500, step=50]

ตารางที่ 19 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง ANN ในงานวิจัย

Parameter keys	Range
hidden_layer_sizes	(64,4)
activation	'relu'
solver	'sgd'
learning_rate_init	0.35
max_iter	150



รูปที่ 26 ความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาปรับจนเพื่อให้เหมาะสมกับแบบจำลอง ANN

### 3.4 การสร้างแบบจำลองโดยใช้การเพิ่มประสิทธิภาพของอนุภาคฝูง (Particle Swarm Optimization - PSO)

การสร้างแบบจำลองโดยใช้การเพิ่มประสิทธิภาพของอนุภาคฝูงในงานวิจัยฉบับนี้ อ้างอิงการกำหนดขอบเขตของพื้นที่ค้นหาไฮเปอร์พารามิเตอร์บางส่วนจากงานวิจัย (Ratnaweera et al., 2004) และ (Rauf et al., 2018) ประกอบด้วย ขนาดชั้นซ่อน (Hidden layer size), ค่าสัมประสิทธิ์การเร่งความเร็ว (Acceleration coefficients) และน้ำหนักเฉื่อย (Inertial weight) ดังแสดงในตารางที่ 20

โดยไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดสำหรับแบบจำลองการเพิ่มประสิทธิภาพของอนุภาคฝูงหรือแทนด้วย PSO นี้แสดงในตารางที่ 21 นอกจากนั้นแล้วในตารางยังประกอบไปด้วยค่าไฮเปอร์พารามิเตอร์อื่นๆที่ใช้สำหรับการสร้างแบบจำลอง ดังต่อไปนี้



- เลเยอร์ขาเข้า (Input Layer) ที่ภายในกำหนดค่าขาเข้า (input values) เป็น (14, ) และขาออก (output values) ของชั้นนี้เท่ากับ (14, )
- จำนวนชั้นซ่อน (Hidden Layer) ที่ภายในกำหนดค่าขาเข้า (input values) เป็น (14, ) , ขาออก (output values) ของชั้นนี้เท่ากับ 32 และภายในชั้นเองกำหนดฟังก์ชันการเปิดใช้งาน (Activation function) เป็นรูปแบบ relu
- เลเยอร์ขาออก (Output Layer) ที่ภายในกำหนดค่าขาเข้า (input values) เป็น (14, ) , ขาออก (output values) ของชั้นนี้เท่ากับ 32 และภายในชั้นเองกำหนดฟังก์ชันการเปิดใช้งาน (Activation function) เป็นรูปแบบ softmax
- ค่าสัมประสิทธิ์การเร่งความเร็ว (Acceleration coefficients) ประกอบด้วย c1 และ c2 เท่ากับ 0.5 และ 0.5 ตามลำดับ
- น้ำหนักเฉื่อย (Inertial weight) เท่ากับ 0.4
- จำนวนอนุภาค (Number of particles) เท่ากับ 500
- จำนวนการทำซ้ำ (Number of iterations) เท่ากับ 400

ตารางที่ 20 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับจูนในแบบจำลอง PSO รวมถึงพิสัยที่ใช้พิจารณา

Parameter	Parameter keys	Range
Hidden layer size	n_hidden	[16, 32, 64, 128]
Acceleration coefficients	c1	[0.5, 1.49, 2.5]
	c2	[0.5, 1.49, 2.5]
Inertial weight	w	[0.4, 0.9]

ตารางที่ 21 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง PSO ในงานวิจัย

Parameter	Parameter keys	Range
Input Layer	input values	(14, )
	output values	(14, )
Hidden Layer	input values	(14, )
	output values	32
	Activation function	relu
Output Layer	Input values	(14, )
	Output values	32
	Activation function	softmax
Acceleration coefficients	c1	0.5
	c2	0.5
Inertial weight	w	0.4
Number of particles	Num of particles	500
Number of iterations	iter	400

### 3.5 การสร้างแบบจำลองโดยใช้ต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสี (Gradient Boosting Decision Trees - GBT)

การสร้างแบบจำลองโดยใช้ต้นไม้การตัดสินใจส่งเสริมการไล่ระดับสีหรือแทนด้วย GBT ใช้กรอบแนวคิดอุปนุณาในการค้นหาไฮเปอร์พารามิเตอร์ที่เหมาะสม เช่นเดียวกับกับแบบจำลองโครงข่ายประสาทเทียม โดยพื้นที่ค้นหาของไฮเปอร์พารามิเตอร์ที่จะทดลองนำมาปรับใช้ แสดงในตารางที่ 22 ประกอบด้วย

- อัตราการเรียนรู้ลดการมีส่วนร่วมของต้นไม้แต่ละต้น แทนด้วย learning\_rate
- จำนวนขั้นตอนการส่งเสริมที่จะดำเนินการ แทนด้วย n\_estimators
- เศษส่วนของขนาดกลุ่มตัวอย่างจะถูกนำมาใช้เพื่อให้พอดีกับผู้เรียนพื้นฐานแต่ละราย หรือแทนด้วย subsample
- ตัวอย่างขั้นต่ำเพื่อแยกโหนดภายใน แทนด้วย min\_samples\_split
- ขนาดตัวอย่างขั้นต่ำเพื่อแยกโหนดภายใน แทนด้วย min\_sample\_leaf
- และ ความลึกสูงสุดของตัวประมาณการถดถอย แทนด้วย max\_depth

เมื่อผ่านกระบวนการอุปนุณาแล้ว จะได้ไฮเปอร์พารามิเตอร์สุดท้ายที่นำมาใช้สำหรับสร้างแบบจำลอง PSO และความสำคัญของไฮเปอร์พารามิเตอร์แต่ละตัวสำหรับแบบจำลอง แสดงในตาราง


ที่ 23 และรูปที่ 27 ตามลำดับ ประกอบด้วย learning\_rate, n\_estimators, subsample, min\_samples\_split, min\_sample\_leaf และ max\_depth มีค่าเท่ากับ 1.69, 350, 0.7, 5, 5 และ 5 ตามลำดับ โดย learning\_rate ยังคงเป็นไฮเปอร์พารามิเตอร์ที่สำคัญลำดับแรกของแบบจำลอง เช่นเดียวกันกับการหาความสำคัญของไฮเปอร์พารามิเตอร์ของแบบจำลอง ANN

ตารางที่ 22 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับจูนในแบบจำลอง GBT รวมถึงพิสัยที่ใช้พิจารณา

Parameter	Parameter keys	Range
The rate of learning reduces the contribution of each tree.	learning_rate	[0.01,1.00, step=0.01]
The number of boosting stages to be performed	n_estimators	[0, 500, step=1]
The sample size fraction will be used to fit the individual base learners.	subsample	[0.1,1.0, step=0.1]
The minimum sample size is required to split an internal node.	min_samples_split	[2,5]
The minimum sample size is required to split an internal node.	min_sample_leaf	[1,5]
Individual regression estimators' maximum depth.	max_depth	[2,5]

ตารางที่ 23 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง GBT ในงานวิจัย

Parameter keys	Range
learning_rate	1.69
n_estimators	350
subsample	0.7
min_samples_split	5
min_sample_leaf	5
max_depth	5



รูปที่ 27 ความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาปรับจนเพื่อให้เหมาะสมกับแบบจำลอง GBT

### 3.6 การสร้างแบบจำลองโดยใช้ป่าไม้สุ่ม (Random Forest - RF)

การสร้างแบบจำลองโดยใช้ป่าไม้สุ่ม (Random Forest) หรือแทนด้วยแบบจำลอง RF นี้ใช้กรอบแนวคิดของออฟทუნ่า เข้ามาประยุกต์ใช้อีกครั้งหนึ่งเช่นเดียวกับแบบจำลอง ANN และแบบจำลอง GBT ที่เคยนำเสนอไปแล้วก่อนหน้านี้ สำหรับแบบจำลอง RF ใช้พื้นที่การค้นหาของไฮเปอร์พารามิเตอร์โดยนำค่าบางส่วนมาจากการอ้างอิงจาก (Koehrsen, 2018) ดังตารางที่ 24 แสดงพื้นที่การค้นหาของไฮเปอร์พารามิเตอร์ ประกอบด้วย

- จำนวนต้นไม้ในป่า แทนด้วย n\_estimators
- จำนวนคุณสมบัติสูงสุดที่พิจารณาสำหรับการแยกโหนด แทนด้วย max\_features
- จำนวนระดับสูงสุดในแต่ละแผนภูมิการตัดสินใจ แทนด้วย max\_depth
- จำนวนข้อมูลขั้นต่ำที่ได้รับอนุญาตก่อนที่โหนดจะถูกแยก แทนด้วย min\_samples\_split
- จำนวนจุดข้อมูลขั้นต่ำที่อนุญาตในโหนดใบ min\_samples\_leaf
- วิธีการสุ่มตัวอย่างจุดข้อมูล (มีหรือไม่มีการเปลี่ยน) แทนด้วย bootstrap

สำหรับค่าสุดท้ายของไฮเปอร์พารามิเตอร์ที่ใช้สำหรับแบบจำลองป่าไม้สุ่ม แสดงไว้ในตารางที่ 25 และความสำคัญของไฮเปอร์พารามิเตอร์แสดงในรูปที่ 28 ตามลำดับ ซึ่งแบบจำลองที่ได้จะประกอบไปด้วย n\_estimators, max\_features, max\_depth, min\_samples\_split, min\_samples\_leaf และ bootstrap มีค่าเท่ากับ 160, auto, 100, 5, 4 และ True ตามลำดับ


นอกจากนั้นแล้ว `n_estimators` ยังเป็นไฮเปอร์พารามิเตอร์ที่มีความสำคัญมากที่สุดในการปรับที่จะส่งผลต่อแบบจำลอง

ตารางที่ 24 ไฮเปอร์พารามิเตอร์ที่นำมาใช้ปรับจูนในแบบจำลอง GBT รวมถึงพิสัยที่ใช้พิจารณา

Parameter	Parameter keys	Range
Number of trees in the forest	<code>n_estimators</code>	[200, 2000, step=10]
Max number of features considered for splitting a node	<code>max_features</code>	["auto","sqrt"]
Max number of levels in each decision tree	<code>max_depth</code>	[10, 110, step=10]
min number of data points placed in a node before the node is split	<code>min_samples_split</code>	[2,5]
min number of data points allowed in a leaf node	<code>min_samples_leaf</code>	[1,4]
method for sampling data points (with or without replacement)	<code>bootstrap</code>	["True","False"]

ตารางที่ 25 ไฮเปอร์พารามิเตอร์ท้ายสุดที่นำมาปรับใช้ในการสร้างแบบจำลอง RF ในงานวิจัย

Parameter keys	Range
<code>n_estimators</code>	160
<code>max_features</code>	auto
<code>max_depth</code>	100
<code>min_samples_split</code>	5
<code>min_sample_leaf</code>	4
<code>bootstrap</code>	True



รูปที่ 28 ความสำคัญของไฮเปอร์พารามิเตอร์ที่นำมาปรับจูนเพื่อให้เหมาะสมกับแบบจำลอง RF



## บทที่ 4

### ผลการทดลองและการวิเคราะห์ผล

หลังจากทำการสร้างแบบจำลองพยากรณ์ดัชนีสุขภาพของมอเตอร์เหนียวนำโดยการประยุกต์ใช้การเรียนรู้ของเครื่องและการปรับไฮเปอร์พารามิเตอร์ให้เหมาะสมในแต่ละแบบจำลองแล้ว ส่วนนี้จะแสดงการประเมินประสิทธิภาพสัมพัทธ์ของแบบจำลองต่างๆ ที่ประยุกต์ใช้กับชุดข้อมูลมอเตอร์เหนียวที่ทำงานภายใต้สภาวะโหลดที่กำหนดของอุตสาหกรรมปิโตรเคมีการศึกษาอัตราส่วนระหว่างชุดข้อมูลการฝึกและชุดข้อมูลทดสอบคือ 70:30 โดยพารามิเตอร์ที่นำเข้ามาใช้ในการทดลองทั้งหมดถูกกำหนดให้เหมาะสม เพื่อให้แน่ใจว่าพารามิเตอร์ทั้งหมดได้รับการดำเนินการอย่างมีประสิทธิภาพสูงสุดและส่งผลต่อประสิทธิภาพการสร้างแบบจำลอง

การจำแนกดัชนีความสมบูรณ์ของมอเตอร์เหนียวถูกแบ่งออกเป็น 4 กลุ่ม และเมตริกที่นำมาใช้ในการประเมิน ประกอบด้วย ค่าความถูกต้องแม่นยำ (Accuracy) , รายงานการจัดหมวดหมู่ (Classification Report) ที่แสดง ความแม่นยำ (Precision) ค่าการเรียกคืน (Recall) และ คะแนน F1 นอกจากนั้นแล้วยังพิจารณาถึงเมตริกซ์ความสับสน รวมถึงเส้นโค้ง AUC-ROC ของแต่ละแบบจำลอง ดังต่อไปนี้

#### 4.1 การวิเคราะห์ประสิทธิภาพแบบจำลองจากรายงานการจัดหมวดหมู่ (Classification Report)

ดังที่ได้กล่าวไว้ก่อนหน้านี้ ที่วัตถุประสงค์ของการศึกษาคือการใช้การเรียนรู้ของเครื่องเข้ามาประยุกต์ใช้กับชุดข้อมูลมอเตอร์เหนียว นำเพื่อจัดหมวดหมู่สถานะของมอเตอร์ออกเป็นระดับดัชนีสุขภาพต่างๆ ตั้งแต่กลุ่ม 0 (การติดตั้งเครื่องใหม่) ไปจนถึงกลุ่ม 3 (จำเป็นต้องหยุดระบบและดำเนินการแก้ไขทันที) นอกนั้นแล้ว กลุ่ม 2 และ กลุ่ม 3 ยังถือเป็นกลุ่มสุขภาพมอเตอร์ที่ต้องได้รับความสนใจเป็นพิเศษ เนื่องจากหากการประเมินผลดัชนีสุขภาพมีระดับอยู่ในกลุ่มดังกล่าวนี้แล้ว นั้นหมายความว่าสถานะของมอเตอร์เหนียวจะเกี่ยวข้องโดยตรงกับระดับความรุนแรงที่ก่อให้เกิดความล้มเหลวหรือพังเสียหาย ด้วยเหตุนี้แล้วในการพิจารณาเลือกแบบจำลองจากการวัดค่าความแม่นยำ การเรียกคืน และคะแนน F1 จากการทำนายค่าถูกต้องที่กลุ่มกลุ่ม 2 และ กลุ่ม 3 จึงเป็นสิ่งสำคัญที่จะนำมาพิจารณาด้วยเช่นกัน โดยค่าความแม่นยำ การเรียกคืน และคะแนน F1 ต้องมีค่าใกล้เคียงกับ 1 มากที่สุด สื่อความถึงว่าผลลัพธ์ที่พยากรณ์ออกมาอยู่ในกลุ่มใดแล้ว ค่าจริงที่เป็นอยู่จะต้องเป็นค่าที่อยู่ในกลุ่มนั้นๆ ด้วยเช่นกัน

ตารางที่ 26 - ตารางที่ 29 แสดงรายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง ANN, PSO, GBT และ RF ตามลำดับ โดยค่าที่แสดงนี้ เป็นค่าที่ได้จากชุดทดสอบที่เป็น 30 ส่วนที่เหลือจากข้อมูลทั้งหมด

ตารางที่ 26 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง ANN

	<b>precision</b>	<b>recall</b>	<b>F1-score</b>	<b>support</b>
Class 0	0.43	1.00	0.60	1195
Class 1	0.00	0.00	0.00	1253
Class 2	1.00	0.73	0.84	1241
Class 3	1.00	1.00	1.00	1228
accuracy			0.68	4917
Macro avg	0.61	0.68	0.61	4917
Weighted avg	0.61	0.68	0.61	4917



ตารางที่ 27 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง PSO

	<b>precision</b>	<b>recall</b>	<b>F1-score</b>	<b>support</b>
Class 0	0.94	1.00	0.97	1195
Class 1	1.00	0.94	0.97	1253
Class 2	0.98	0.98	0.98	1241
Class 3	0.98	0.98	0.98	1228
accuracy			0.97	4917
Macro avg	0.98	0.97	0.97	4917
Weighted avg	0.98	0.97	0.97	4917



ตารางที่ 28 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง GBT

	precision	recall	F1-score	support
Class 0	1.00	1.00	1.00	1195
Class 1	0.99	1.00	0.99	1253
Class 2	0.82	0.94	0.88	1241
Class 3	0.94	0.79	0.86	1228
accuracy			0.93	4917
Macro avg	0.94	0.93	0.93	4917
Weighted avg	0.94	0.93	0.93	4917

ตารางที่ 29 รายงานการจำแนกประเภท (Classification Report) ของแบบจำลอง RF

	precision	recall	F1-score	support
Class 0	0.99	1.00	1.00	1195
Class 1	1.00	0.99	0.99	1253
Class 2	0.95	0.92	0.94	1241
Class 3	0.92	0.95	0.94	1228
accuracy			0.96	4917
Macro avg	0.97	0.96	0.96	4917
Weighted avg	0.96	0.96	0.96	4917

เมื่อพิจารณาในแง่ของความสามารถในการพยากรณ์สุขภาพของมอเตอร์เหนียวนำ ดังรายงานการจัดหมวดหมู่แล้วจะพบว่าแบบจำลอง PSO เป็นแบบจำลองที่มีประสิทธิภาพในการพยากรณ์มากที่สุด เนื่องจากการกระจายตัวการวัดคะแนนของความแม่นยำ การเรียกคืน และคะแนน F1 ตั้งแต่กลุ่ม 0 ถึงกลุ่ม 3 มีค่าที่สูงและใกล้เคียงกับ 1 ในบรรดาการแยกกลุ่มทั้ง 4 กลุ่ม นอกจากนั้นแล้วแม้ว่าประสิทธิภาพของแบบจำลอง RF จะดูดีด้อยกว่าแบบจำลอง PSO เพียงเล็กน้อย แต่โดยภาพรวมแล้วยังถือว่าดีกว่าแบบจำลอง GBT และแบบจำลอง ANN มาก

สำหรับคะแนน F1 เป็นการหาค่าเฉลี่ยฮาร์โมนิกระหว่างความแม่นยำ (Precision) และการเรียกคืน (Recall) นั้นหมายความว่าความแม่นยำและการเรียกคืนต้องมีค่าสูง จึงจะส่งผลต่อคะแนน F1 ที่สูงตามไปด้วย ด้วยเหตุนี้แล้วคะแนน F1 จึงมีความสำคัญและถูกนำมาใช้ในการประเมินประสิทธิภาพโดยรวมของแบบจำลองการเรียนรู้ของเครื่อง จากตารางที่ 24 - ตารางที่ 27 จะพบว่า

ความแม่นยำเฉลี่ยถ่วงน้ำหนัก (Macro average) ของแบบจำลอง PSO ในแง่ของคะแนน F1 นั้นมีค่าสูงสุดที่ 0.97 รองลงมาคือแบบจำลอง RF, GBT และ ANN มีค่า 0.96, 0.93 และ 0.61 ตามลำดับ จากผลการทดลองดังกล่าวแสดงถึงประสิทธิภาพของแบบจำลอง PSO ที่นอกเหนือจากความสามารถที่ยอดเยี่ยมในการจำแนกข้อมูลออกเป็นหมวดหมู่ต่างๆแล้ว ยังมีความแม่นยำมากกว่าแบบจำลองรุ่นอื่นๆ ที่นำมาเปรียบเทียบกัน

#### 4.2 การวิเคราะห์ประสิทธิภาพแบบจำลองจากค่าความแม่นยำ (Accuracy)

หนึ่งในการวัดประสิทธิภาพแบบจำลองที่นำมาใช้พิจารณาคือเปอร์เซ็นต์ความถูกต้องหรือความแม่นยำ (% Accuracy) ในการทำนายผลของแบบจำลอง ซึ่งแสดงถึงความถูกต้องของการทำนายได้ตรงกับความเป็นจริง โดยจะพิจารณาจากการทำนายความถูกต้องรวมของทุกๆกลุ่ม สำหรับการทดลองพบว่าแบบจำลองที่มีเปอร์เซ็นต์ความถูกต้องมากที่สุดคือแบบจำลอง PSO ที่ 97.46% รองลงมาคือ FR , GBT และ ANN ด้วยค่า 96.46%, 93.21% และ 67.75% ตามลำดับ ค่าเปอร์เซ็นต์ความถูกต้องของแต่ละแบบจำลอง แสดงดังตารางที่ 30

ตารางที่ 30 เปรียบเทียบค่าเปอร์เซ็นต์ความถูกต้องของแต่ละแบบจำลอง

แบบจำลอง	% Accuracy
PSO	97.46 %
RF	96.46 %
GBT	93.21 %
ANN	67.75 %


#### 4.3 การวิเคราะห์ประสิทธิภาพแบบจำลองด้วยเมทริกซ์ความสับสน (Confusion Matrix) และเส้นโค้ง AUC-ROC

อีกสองตัวชี้วัดที่สามารถประยุกต์เข้ามาใช้ในการวัดความสามารถของการจำแนกกลุ่มข้อมูลคือเมทริกซ์ความสับสน (Confusion Matrix) และเส้นโค้ง AUC-ROC หากแบบจำลองมีประสิทธิภาพในการจัดหมวดหมู่ข้อมูลให้อยู่ในกลุ่มที่ถูกต้องแล้ว เมทริกซ์ความสับสนจะแสดงออกมาในรูปแบบฟังก์ชันแผนที่ความร้อน (heatmap function) โดยข้อมูลองค์ประกอบในแนวทแยง (จาก


ซ้ายบนลงไปขวาล่าง) ของเมทริกซ์ควรมีค่ามากที่สุดหรือความเข้มของแถบสีต้องมีมากที่สุดในบรรดาข้อมูลที่อยู่ในแถวหรือคอลัมน์เดียวกัน แสดงถึงสิ่งที่คาดการณ์ไว้ตรงกับผลลัพธ์จริงของสถานการณ์

นอกจากนั้นแล้วสำหรับการพิจารณาคะแนน AUC ที่ได้จากเส้นโค้ง ROC เป็นวิธีที่ใช้ในการสรุปประสิทธิภาพออกมาในรูปแบบตัวเลข โดย AUC ควรมีค่ามากกว่า 0.5 ซึ่งแสดงถึงประสิทธิภาพในการแยกแยะของสิ่งหนึ่งออกจากสิ่งใด ในที่นี้เปรียบกับเป็นการแยกประเภทแต่ละกลุ่มออกจากกันได้อย่างชัดเจน

รูปที่ 29 - รูปที่ 32 แสดงเมทริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง ANN, PSO, GBT และ RF ตามลำดับ จะพบว่าสำหรับแบบจำลอง PSO นั้นยังคงมีประสิทธิภาพที่เหนือกว่าแบบจำลองจากการเรียนรู้ของเครื่องอื่นๆ ในการแก้ปัญหาการแยกกลุ่มข้อมูล เนื่องจากเมทริกซ์ความสับสนมีการเน้น (Highlight) หรือความเข้มของสีน้ำเงินเข้ม (ค่าสูง) ในแนวทแยงจากบนซ้ายไปล่างขวาทั้งหมด และ ค่า AUC ของการแยกแยะแต่ละกลุ่มยังมีค่าที่มากกว่า 0.5 ส่วนอันดับสองที่ดีที่สุดรองลงมาคือ RF ตามด้วย GBT และ ANN ตามลำดับ ในบรรดาแบบจำลองทั้ง 4 นี้ จะพบว่าแบบจำลอง ANN ยังมีประสิทธิภาพที่น้อยที่สุดในการแยกแยะกลุ่ม 1 ที่ถูกต้อง ที่จะแสดงดังเมทริกซ์ความสับสนของแบบจำลอง ANN




(ก) เมทริกซ์ความสับสน




(ข) เส้นโค้ง AUC-ROC

รูปที่ 29 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง ANN




(ก) เมตริกซ์ความสับสน




(ข) เส้นโค้ง AUC-ROC

รูปที่ 30 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง PSO




(ก) เมตริกซ์ความสับสน




(ข) เส้นโค้ง AUC-ROC

รูปที่ 31 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง GBT



(ก) เมตริกซ์ความสับสน



(ข) เส้นโค้ง AUC-ROC

รูปที่ 32 เมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC ของแบบจำลอง RF

## บทที่ 5

### สรุปและอภิปรายผลการทดลอง

การศึกษานี้เป็นการรวมวิทยาศาสตร์ข้อมูลและเทคนิคการเรียนรู้ของเครื่อง (Data Science and Machine Learning) เข้าด้วยกันเพื่อใช้ในการทำนายระดับดัชนีสุขภาพ (กลุ่ม 0 – กลุ่ม 3) ของมอเตอร์เหนียวนา เพื่อช่วยเจ้าหน้าที่บำรุงรักษา (Maintenance Officers) ของบริษัทกรณีศึกษา สำหรับใช้ในการระบุความจำเป็นในการดำเนินการบำรุงรักษาที่เหมาะสมในประเภทการบำรุงรักษาแบบตามเวลาจริงหรือเรียลไทม์ (Real-time) โดยเครื่องมือที่นำมาใช้ในการเก็บรวบรวมข้อมูลหัตนี้คือเซ็นเซอร์อัจฉริยะ (Smart sensor) ที่ถูกติดตั้งไว้บริเวณตำแหน่งของมอเตอร์เหนียวนาและในระบบเพื่อใช้ในการเก็บค่าพารามิเตอร์ต่างๆ โดยในปัจจุบันที่มีข้อมูลจำนวนมากดังกล่าวนี้นี้ ทำให้เจ้าหน้าที่บำรุงรักษามีแนวโน้มที่จะตัดสินใจผิดพลาดในเรื่องของการประเมินระดับสุขภาพและบางครั้งในการตัดสินใจเกี่ยวกับการซ่อมบำรุงที่ไม่ทันท่วงที ในกระบวนการฝึกอบรมและพยากรณ์ระดับดัชนีสุขภาพของมอเตอร์เหนียวนาเพื่อระบุและแก้ไขปัญหาการชำรุดเสียหายที่ผิดพลาดหรือไม่เกี่ยวข้องนั้นโดยส่วนใหญ่แล้วเกิดจากข้อผิดพลาดหรือการทำงานที่ผิดปกติของเซ็นเซอร์ ดังนั้นข้อมูลต่างๆเหล่านี้จำเป็นต้องผ่านกระบวนการทำความสะอาดและจัดรูปแบบให้เหมาะสม นอกจากนี้คุณลักษณะหรือพารามิเตอร์ของมอเตอร์เหนียวนาที่จะนำเข้ามาใช้ในการสร้างแบบจำลอง จะต้องได้รับการตรวจสอบความเป็นอิสระออกจากกันของแต่ละพารามิเตอร์ เพื่อพิจารณาว่าพารามิเตอร์เหล่านี้สามารถรวมหรือลดขนาดลงได้หรือไม่ หรือผ่านกระบวนการดูความมีนัยสำคัญของพารามิเตอร์ที่ส่งผลกระทบต่ตัวแปรตอบสนองที่แทนด้วยดัชนีสุขภาพของมอเตอร์เหนียวนา เพื่อประสิทธิภาพสูงสุดของแบบจำลอง

สำหรับการทดลองจะเป็นการใช้แบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์และแก้ไขปัญหาการแบ่งกลุ่ม โดยแบ่งออกเป็น 4 กลุ่ม โดยแบบจำลองการเรียนรู้ของเครื่องนี้จะประกอบไปด้วย แบบจำลองการคำนวณ (Computational Models) จำนวนสองแบบ (คือ ANN และ PSO) และแบบจำลองรุ่นทั้งมวล (Ensemble Models) จำนวนสองแบบ (คือ GBT และ RF) โดยที่การวัดประสิทธิภาพที่ใช้ในการเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องรุ่นต่างๆ ประกอบด้วย เปอร์เซ็นต์ค่าความถูกต้องแม่นยำ (% Accuracy), ค่าความแม่นยำ (Precision), การเรียกคืน (Recall), คะแนน F1, เมทริกซ์ความสับสน (Confusion Matrix) และ เส้นโค้ง AUC-ROC ซึ่งในบทนี้จะเป็นการกล่าวถึงสรุปผล อภิปรายผล ข้อจำกัดและข้อเสนอแนะของการทดลอง

### 5.1 สรุปผลที่ได้จากการทดลอง

จากผลการทดลองพบว่าแบบจำลอง PSO มีประสิทธิภาพที่ดีกว่าแบบจำลองจากการเรียนรู้ของเครื่องอีก 3 แบบจำลองที่เหลือ (ประกอบด้วย ANN, GBT และ RF) ในแง่ของความสามารถในการแยกแยะสถานะหรือดัชนีสุขภาพของมอเตอร์ไฟฟ้าเหนี่ยวนำ เมื่อนำมาทดลองใช้ชุดข้อมูลจากมอเตอร์ไฟฟ้าเหนี่ยวนำในอุตสาหกรรมกรณีศึกษา โดยไฮเปอร์พารามิเตอร์ที่นำเข้ามาปรับแต่งให้เหมาะสมภายในแบบจำลองประกอบด้วย เลเยอร์ขาเข้า (input layer) จำนวน 14 ชั้นที่เท่ากับจำนวนพารามิเตอร์ขาเข้าของระบบ, จำนวนชั้นซ่อน (hidden layer) จำนวน 32 ชั้น และภายในชั้นเองมีการใช้ relu เป็นฟังก์ชันกระตุ้น (activation function) , จำนวนเลเยอร์ขาออก (output layer) เท่ากับ 4 และฟังก์ชันกระตุ้นภายในใช้ชนิด softmax นอกจากนั้นค่า c1 และ c2 ที่เหมาะสมที่สุดสำหรับแบบจำลองมีค่าเท่ากับ 0.5 สำหรับค่า w , จำนวนอนุภาคและจำนวนการทำซ้ำ ถูกตั้งค่าไว้ที่ 0.4, 500 และ 400 ตามลำดับ เมื่อปรับค่าไฮเปอร์พารามิเตอร์ดังที่ได้กล่าวไปแล้วส่งผลให้แบบจำลองสามารถบรรลุประสิทธิภาพที่เปอร์เซ็นต์ความแม่นยำ 97.46 % รองลงมาคือแบบจำลอง RF, GBT และ ANN ที่มีค่าเปอร์เซ็นต์ความแม่นยำเท่ากับ 96.46 % , 93.21 % และ 67.75 % ตามลำดับ

สำหรับประสิทธิภาพในแง่ของรายงานการจัดหมวดหมู่ (Classification Report) ที่จะอธิบายในด้านค่าความแม่นยำ (Precision), การเรียกคือ (Recall) และคะแนน F1 พบว่าสำหรับแบบจำลอง PSO แล้ว ยังให้ประสิทธิภาพที่ดีที่สุดในการแยกแยะปัญหาการจัดหมวดหมู่เมื่อเปรียบเทียบกับแบบจำลองอื่นๆเช่นกัน โดยสรุปภาพรวมค่าเฉลี่ยถ่วงน้ำหนัก (Macro average) คะแนน F1 ของแบบจำลอง PSO นั้นมีค่าสูงสุดที่ 0.97 รองลงมาคือแบบจำลอง RF, GBT และ ANN มีค่า 0.96, 0.93 และ 0.61 ตามลำดับ

นอกจากนั้นเมื่อพิจารณาในส่วนเมตริกซ์ความสับสนและเส้นโค้ง AUC-ROC นั้นค่า AUC ของการแยกแยะแต่ละกลุ่มของแบบจำลอง PSO ยังมีค่าที่มากกว่า 0.5 ส่วนอันดับสองที่ดีที่สุดรองลงมาคือ RF ตามด้วย GBT และ ANN ตามลำดับ

เมื่อผ่านกระบวนการสร้างแบบจำลองและเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลองแล้ว จะเข้าสู่กระบวนการนำแบบจำลองที่ได้นี้ไปประยุกต์ใช้เพื่อพยากรณ์ระดับดัชนีสุขภาพของมอเตอร์ไฟฟ้าเหนี่ยวนำในอุตสาหกรรมปิโตรเคมีกรณีศึกษาในลักษณะเรียลไทม์มากขึ้น เพราะในความเป็นจริงแล้ว ค่าที่ได้จากสมาร์ทเซ็นเซอร์นี้จะมาในรูปแบบเรียลไทม์ที่สามารถนำแบบจำลองที่สร้าง มาใช้พยากรณ์ผลและรู้ผลลัพธ์ได้ในทันที ผลการศึกษานี้จึงเป็นประโยชน์อย่างยิ่งต่อการปฏิบัติงานของเจ้าหน้าที่ซ่อมบำรุง เนื่องสามารถทำนายสถานะดัชนีสุขภาพแบบเรียลไทม์ โดยเฉพาะเมื่อดัชนีสุขภาพตกอยู่ในกลุ่ม 2 (ระดับความรุนแรงที่มีความเสี่ยงปานกลาง) และกลุ่ม 3 (ระดับความ



รุนแรงที่มีความเสี่ยงสูง) ทำให้สามารถดำเนินการได้ทันที ทำการบำรุงรักษาแก้ไขหรือฉุกเฉินได้ตรงเวลา นอกจากนี้ ข้อมูลนี้มีประโยชน์มากสำหรับใช้เพื่อการปรึกษากับผู้เชี่ยวชาญสำหรับแนวทางและวิธีการแก้ปัญหาการซ่อมบำรุงที่เป็นไปได้ การจัดการกับกำหนดการของแผนการบำรุงรักษา การวางแผนการจัดซื้ออะไหล่ ฯลฯ เพื่อป้องกันการหยุดระบบของเครื่องจักรภายในอุตสาหกรรมโดยไม่ได้วางแผนไว้ เนื่องจากประสบความสำเร็จในการนำไปใช้งาน บริษัทมีแผนที่จะขยายแนวคิดนี้ไปยังอุปกรณ์ที่สำคัญอื่น ๆ เช่นเครื่องจักรที่หมุนได้ในอนาคตต่อไป

## 5.2 อภิปรายผลการทดลอง

1. สำหรับประสิทธิภาพของแบบจำลองเมื่อเปรียบเทียบกับเมตริกซ์การเมินที่หลากหลาย ประกอบด้วย ค่าความแม่นยำถูกต้อง (Accuracy), ค่าความแม่นยำ (Precision) ค่าเรียกคืน(Recall) คะแนน F1, เมตริกซ์ความสับสน (Confusion Matrix) และเส้นโค้ง AUC-ROC จะพบว่าระหว่างแบบจำลอง PSO และ RF มีค่าประสิทธิภาพที่ใกล้เคียงกันมากถึงแม้ว่าแบบจำลอง RF จะมีค่าประสิทธิภาพที่ดีกว่าเพียงเล็กน้อย แต่เมื่อเปรียบเทียบในแง่ของเวลาที่ใช้ในการประมวลผลในการสร้างแบบจำลองจะพบว่า แบบจำลอง RF สามารถบรรลุเวลาในการสร้างแบบจำลองที่รวดเร็วกว่าแบบจำลอง PSO ดังนั้นสำหรับในอนาคต หากมีจำนวนข้อมูลเข้าระบบมากขึ้น สามารถนำเข้าข้อมูลเหล่านี้เพื่อใช้ในการฝึกฝนข้อมูลใหม่อีกครั้งนั้น (Refitting model) จะพบว่าแบบจำลอง RF จะเป็นอีกหนึ่งทางเลือกที่จะนำมาพิจารณาด้วยเช่นกัน

2. ในการทดลองนี้เนื่องจากข้อมูลเข้ามามีในระบบเป็นข้อมูลที่ไม่สมดุล กล่าวคือกลุ่มข้อมูลเดิมที่ได้แบ่งกลุ่มของดัชนีสุขภาพของมอเตอร์ไฟฟ้าเหนี่ยวนำเป็นข้อมูลที่ไม่สมดุล ดังนั้นการใช้เทคนิค SMOTE ที่จะช่วยจัดการปัญหาความไม่สมดุลของข้อมูล อาจส่งผลต่อผลลัพธ์ของประสิทธิภาพที่ได้ของแต่ละแบบจำลอง

## 5.3 ข้อจำกัดและข้อเสนอแนะของการทดลอง


1. เนื่องจากขีดจำกัดความสามารถคอมพิวเตอร์ที่ใช้ในการทดลอง ส่งผลให้การกำหนดพื้นที่การค้นหาของไฮเปอร์พารามิเตอร์ (Hyperparameter search space) อาจมีไม่เพียงพอ ส่งผลต่อค่าที่เหมาะสมที่สุดของไฮเปอร์พารามิเตอร์ที่นำมาใช้ในการสร้างแบบจำลอง ดังนั้นหากมีการทดลองโดยขยายขอบเขตพื้นที่การค้นหาของไฮเปอร์พารามิเตอร์เพิ่มเติม อาจเป็นไปได้ว่าจะส่งผลต่อประสิทธิภาพของแต่ละแบบจำลองที่ดีขึ้นได้

2. สำหรับแบบจำลอง ANN ที่ประสิทธิภาพยังไม่แม่นยำเท่าที่ควร หากสามารถปรับไฮเปอร์พารามิเตอร์หรือเลือกใช้พารามิเตอร์ตัวอื่นๆของอัลกอริทึมมาปรับปรุงให้ละเอียดขึ้น อาจส่งผลต่อประสิทธิภาพของแบบจำลองที่แม่นยำในการพยากรณ์ผล

3. ข้อมูลที่นำเข้ามาใช้ในการสร้างแบบจำลองค่อนข้างมีจำกัด เพื่อเพิ่มประสิทธิภาพขีดความสามารถของแบบจำลอง จำเป็นต้องมีพารามิเตอร์ที่นำเข้ามาให้หลากหลายมากยิ่งขึ้น เช่น เพิ่มเซ็นเซอร์ตรวจวัดค่ากระแสหรือแรงดันไฟฟ้าของแต่ละเฟส, ค่าคลื่นเสียงความถี่สูง หรืออื่นๆ ที่จะส่งผลต่อการกำหนดแผนในการเพิ่มการติดตั้งสมาร์ตเซ็นเซอร์ในอนาคตต่อไป

#### 5.4 ข้อเสนอแนะ

1. ควรเพิ่มจำนวนข้อมูลที่ใช้สำหรับสร้างแบบจำลองสำหรับการจัดกลุ่มในกลุ่ม 2 หรือ 3 ที่มากกว่านี้เพื่อกำจัดปัญหาการไม่สมดุลของข้อมูล



## บรรณานุกรม

1. ANSI/NETA MTS-2019 Standard for Maintenance Testing Specifications for Electrical Power Equipment and Systems (2019).
2. Arunkumar, K., & Manjunath, T. (2018). Bearing fault diagnosis through vibration signals utilizing J-48 Decision Tree Algorithm. 2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT),
3. Certify Level 1 Infrared Thermographer Book. (2020). SYSTRONICS CO.,LTD.
4. Cheevachaipimol, W., Teinwan, B., & Chutima, P. (2021). Flight Delay Prediction Using a Hybrid Deep Learning Method. Engineering Journal, 25(8), 99-112.
5. Clark, T. (2017). Search Algorithm Series: PSO.
6. Ghate, V. N., & Dudul, S. V. (2010). Cascade neural-network-based fault classifier for three-phase induction motor. IEEE Transactions on Industrial Electronics, 58(5), 1555-1563.
7. ISO 10816-3:2009 Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts (2009).
8. ISO 14224:2016 Petroleum, petrochemical and natural gas industries — Collection and exchange of reliability and maintenance data for equipment. (2016).
9. Kewalramani, R., & Ram, A. (2019). Estimation of Remaining Useful Life of Electric Motor using supervised deep learning methods. 2019 IEEE Transportation Electrification Conference (ITEC-India),
10. Koehrsen, W. (2018). Hyperparameter Tuning the Random Forest in Python. จาก <https://towardsdatascience.com/>
11. Lu, G. (2021). Tuning Hyperparameters with Optuna.
12. Narkhede, S. (2018). Understanding auc-roc curve. Towards Data Science, 26(1), 220-227.
13. Ratnaweera, A., Halgamuge, S. K., & Watson, H. C. (2004). Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients.

- IEEE Transactions on evolutionary computation, 8(3), 240-255.
14. Rauf, H. T., Bangyal, W. H., Ahmad, J., & Bangyal, S. A. (2018). Training of artificial neural network using pso with novel initialization technique. 2018 international conference on innovation and intelligence for informatics, computing, and technologies (3ICT),
  15. Sakthivel, N., Sugumaran, V., & Babudevasenapati, S. (2010). Vibration based fault diagnosis of monoblock centrifugal pump using decision tree. Expert Systems with Applications, 37(6), 4040-4049.
  16. Sanyal, S. (2021). An Introduction to Particle Swarm Optimization (PSO) Algorithm.
  17. Seera, M., Lim, C. P., Nahavandi, S., & Loo, C. K. (2014). Condition monitoring of induction motors: A review and an application of an ensemble of hybrid intelligent models. Expert Systems with Applications, 41(10), 4891-4903.
  18. Tama, B. A., & Rhee, K.-H. (2019). An in-depth experimental study of anomaly detection using gradient boosted machine. Neural Computing and Applications, 31(4), 955-965.
  19. Tao, H., Mo, L., Shen, F., Du, Z., & Yan, R. (2016). Multi-classifiers ensemble with confidence diversity for fault diagnosis in induction motors. 2016 10th International Conference on Sensing Technology (ICST),
  20. Zhao, G., Zhang, G., Ge, Q., & Liu, X. (2016). Research advances in fault diagnosis and prognostic based on deep learning. 2016 Prognostics and system health management conference (PHM-Chengdu),
  21. กอบเกียรติ สรรอุบล. (2020). เรียนรู้ Data Science และ AI : Machine Learning ด้วย Python. สำนักพิมพ์ มีเดีย เนทเวิร์ค.
  22. ไกรศักดิ์ เกษร. (2021). วิทยาศาสตร์ข้อมูล. In วิทยาศาสตร์ข้อมูล(Data Science). ภาควิชาวิทยาการคอมพิวเตอร์และเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร.
  23. นวภัทรา หนูนาคน , และทวีพล ชื้อสัตย์. (2012). การวัดและเครื่องมือวัด การประยุกต์ใช้ในอุตสาหกรรมอาหาร (Measurement and Instrumentation). สำนักพิมพ์ ค ณ ะวิศวกรรมศาสตร์ สจล.
  24. นันทชัย กานตานันทะ. (2021). เอกสารประกอบการสอน วิชา RES PROB IE I (Machine Learning). In. Department of Industrial Engineering, Faculty of Engineering,

Chulalongkorn University,

25. นายช่างมาแชร์. (2020). (Maintenance KPI's) – ดัชนีชี้วัดคุณภาพ ในงานซ่อม และการบำรุงรักษา. จาก [www.naichangmashare.com](http://www.naichangmashare.com)
26. ประดิษฐ์ หมูเมืองสอง , และสุชญาณ หรรษสุข. (2013). การวิเคราะห์การสันสเทือน. สำนักพิมพ์ ซีเอ็ดยูเคชั่น จำกัด.
27. ปริญญา สงวนสัตย์. (2019). Artificial Intelligence with Machine Learning, AI สร้างได้ด้วยแมชชีนเลิร์นนิง. สำนักพิมพ์ Infopress.
28. พาราติน จันทเขตต์. (2017). การตรวจวิเคราะห์น้ำมันหล่อลื่น ยืดอายุการใช้งานเครื่องจักร ลดค่าใช้จ่ายซ่อมบำรุง. จาก <https://www.mmthailand.com>
29. เฟื่องลดา มะโนกิจ. (2019). การพยากรณ์ปริมาณน้ำฝนของประเทศไทยด้วยวิธีการเรียนรู้เชิงลึก [วิทยานิพนธ์ปริญญามหาบัณฑิต จุฬาลงกรณ์มหาวิทยาลัย].
30. ยุทธพงศ์ ทัพผดุง. (2019). ผลกระทบที่มีผลต่อมอเตอร์เมื่อแรงดันไฟฟ้าและความถี่เกิดการเปลี่ยนแปลง. จาก <https://www.pea.co.th/>.
31. วิชญ์พงศ์ ตรุณธรรม. (2018). เจาะลึก Random Forest — Part 2 of “รู้จัก Decision Tree, Random Forest, และ XGBoost”.
32. วิชญ์วิสิฐ เกษรสิทธิ์ , วิชิต หล่อจิระชุมท์กุล , และจิราวัลย์ จิตรถเวช. (2018). การแก้ปัญหาข้อมูลไม่สมดุลของข้อมูลสำหรับการจำแนกผู้ป่วยโรคเบาหวาน. KKU Research Journal (Graduate Study), 18 No.3.
33. วิทยา พรพัชรพงศ์. (2008). โครงข่ายประสาทเทียม (Artificial Neural Networks - ANN).
34. วิชาน มีนาภินันท์. (2018). Machine Learning คืออะไร. จาก <https://medium.com/>
35. สุวพันธุ์ อริเดช. (2019). การพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงไฟฟ้ากำลังสำหรับการประเมินสมรรถนะโดยใช้แบบจำลองการเรียนรู้ของเครื่อง [วิทยานิพนธ์ปริญญามหาบัณฑิต จุฬาลงกรณ์มหาวิทยาลัย].
36. อกนิษฐ์ ทองจิตร , พูลพงศ์ สุขสว่าง , และจตุภัทร เมฆพ่ายพ. (2018). การพัฒนาวิธีจำแนกประเภทข้อมูลโดยใช้โครงข่ายประสาทเทียมแบบปรับเหมาะผสมผสานการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค สำหรับการจำแนกประเภทกลุ่มเสี่ยงในการเป็นโรคเบาหวาน Vol. 17 No. 2 (2562): วารสารวิทยาการวิจัยและวิทยาการปัญญา.



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ประวัติผู้เขียน

ชื่อ-สกุล	วริศรา ขระเชื่อน
วัน เดือน ปี เกิด	17 กันยายน 2536
สถานที่เกิด	จังหวัดน่าน
วุฒิการศึกษา	วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมไฟฟ้า มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา
ที่อยู่ปัจจุบัน	292/94 ม.8 ต.บ่อวิน อ.ศรีราชา จ.ชลบุรี 20230

