

2021

การตรวจจัยความแปลกใหม่เพื่อการบำรุงรักษาเชิงคาดการณ์ของคอมเพรสเซอร์ แบบลูกสูบด้วยตัวเข้ารหัสอัตโนมัติประเภทหน่วยความจำระยะสั้นแบบยาว

สุนิธิ อิศวเลิศพลากร
คณะวิศวกรรมศาสตร์

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



Part of the [Applied Mechanics Commons](#), and the [Engineering Mechanics Commons](#)

Recommended Citation

อิศวเลิศพลากร, สุนิธิ, "การตรวจจัยความแปลกใหม่เพื่อการบำรุงรักษาเชิงคาดการณ์ของคอมเพรสเซอร์แบบลูกสูบด้วยตัวเข้ารหัสอัตโนมัติประเภทหน่วยความจำระยะสั้นแบบยาว" (2021). *Chulalongkorn University Theses and Dissertations (Chula ETD)*. 5349.

<https://digital.car.chula.ac.th/chulaetd/5349>

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.

การตรวจจับความแปลกใหม่เพื่อการบำรุงรักษาเชิงคาดการณ์ของคอมเพรสเซอร์แบบลูกสูบด้วยตัว
เข้ารหัสอัตโนมัติประเภทหน่วยความจำระยะสั้นแบบยาว



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิศวกรรมระบบกายภาพที่เชื่อมประสานด้วยเครือข่ายไซเบอร์ ภาควิชาวิศวกรรมเครื่องกล
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2564
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Novelty Detection for Predictive Maintenance of a Reciprocating Compressor using
Long short-term memory Autoencoder



Mr. Sunithi Asavalertpalakorn

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Cyber-Physical System

Department of Mechanical Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2021

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์

การตรวจจับความแปลกใหม่เพื่อการบำรุงรักษาเชิง
คาดการณ์ของคอมเพรสเซอร์แบบลูกสูบด้วยตัวเข้ารหัส
อัตโนมัติประเภทหน่วยความจำระยะสั้นแบบยาว

โดย

นายสุนิธิ อัสวเลิศพลากร

สาขาวิชา

ระบบกายภาพที่เชื่อมประสานด้วยเครือข่ายไซเบอร์

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

ศาสตราจารย์ ดร.ไพโรจน์ สิงห์นาคกิจ

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.รัชทิน จันทร์เจริญ)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ศาสตราจารย์ ดร.ไพโรจน์ สิงห์นาคกิจ)

..... กรรมการ
(รองศาสตราจารย์ ดร.กฤษฎา พนมแข็ง)

..... กรรมการ
(อาจารย์ ดร.รีนา แซ่)

..... กรรมการภายนอกมหาวิทยาลัย
(ผู้ช่วยศาสตราจารย์ ดร.พิเชษฐ์ พินิจ)

สุนิธิ อัครเลิศพลากร : การตรวจจับความแปลกใหม่เพื่อการบำรุงรักษาเชิงคาดการณ์
ของคอมเพรสเซอร์แบบลูกสูบด้วยตัวเข้ารหัสอัตโนมัติประเภทหน่วยความจำระยะสั้น
แบบยาว. (Novelty Detection for Predictive Maintenance of a Reciprocating
Compressor using Long short-term memory Autoencoder) อ.ที่ปรึกษาหลัก :
ศ. ดร.ไพโรจน์ สิงห์นาคกิจ

ความท้าทายหลักในการบำรุงรักษาเชิงคาดการณ์คือปัญหาการขาดแคลนข้อมูลความ
ผิดปกติของเครื่องจักรสำหรับใช้ในการฝึกสอนแบบจำลอง และความซับซ้อนของระบบโรงงานซึ่งมี
สภาพการทำงานของเครื่องจักรที่ไม่แน่นอน ทำให้เกณฑ์ตรวจจับความผิดปกติที่ถูกกำหนดไว้
ล่วงหน้าอาจเปลี่ยนแปลงได้ การตรวจจับความแปลกใหม่ (novelty detection) แก้ปัญหา
ดังกล่าวโดยการตรวจจับความผิดปกติผ่านการเรียนรู้เฉพาะข้อมูลปกติเท่านั้น วิทยานิพนธ์นี้ใช้
วิธีการตรวจจับความแปลกใหม่เพื่อตรวจจับสัญญาณเริ่มต้นของความเสียหายในคอมเพรสเซอร์
แบบลูกสูบโดยใช้ตัวเข้ารหัสอัตโนมัติประเภทหน่วยความจำระยะสั้นแบบยาว ตัวเข้ารหัสอัตโนมัติ
ประเภทหน่วยความจำระยะสั้นแบบยาวเป็นขั้นตอนวิธีการเรียนรู้เชิงลึกที่รวมตัวเข้ารหัสอัตโนมัติ
และเครือข่ายหน่วยความจำระยะสั้นแบบยาวเข้าด้วยกัน เพื่อสร้างข้อมูลปกติขึ้นมาใหม่เพื่อเรียนรู้
ความสัมพันธ์ของข้อมูลที่ไม่เป็นเชิงเส้นและความสัมพันธ์เชิงเวลา คุณลักษณะทางกายภาพเพิ่มเติม
ของเครื่องจักรถูกคำนวณจากสมการอุณหพลศาสตร์เพื่อช่วยในการระบุความสัมพันธ์ระหว่างตัว
แปรแต่ละตัว ชั้นดรอปเอาต์ (dropout layer) ถูกใช้เพื่อสร้างแบบจำลองร่วมตัดสินใจของ
โครงข่ายประสาทเทียม แบบจำลองนี้ได้รับการฝึกสอนด้วยข้อมูลเซ็นเซอร์อนุกรมเวลาแบบหลาย
ตัวแปรที่ถูกรวบรวมมาจากช่วงเวลาเครื่องจักรทำงานเป็นปกติโดยบริษัท ระยะเวลาวิศวกรรมและ
ซ่อมบำรุง จำกัด แผนงานวิจัยได้รับการทดสอบกับรูปแบบความเสียหายที่ถูกจำลองขึ้นของ
คอมเพรสเซอร์ ผลการวิจัยชี้ให้เห็นว่าตัวเข้ารหัสอัตโนมัติประเภทหน่วยความจำระยะสั้นแบบยาว
สามารถแยกความแตกต่างระหว่างรูปแบบความปกติและรูปแบบความเสียหายของคอมเพรสเซอร์
ได้อย่างมีประสิทธิภาพด้วยความเที่ยงตรงสูงสุด 90% และความถูกต้อง 100% สุดท้ายจึงสร้าง
สัญญาณเตือนเพื่อจำแนกความเสียหายที่ตรวจจับได้ออกเป็น 3 ระดับตามความรุนแรง

สาขาวิชา ระบบกายภาพที่เชื่อมประสาน ลายมือชื่อนิสิต
ด้วยเครือข่ายไซเบอร์

ปีการศึกษา 2564 ลายมือชื่อ อ.ที่ปรึกษาหลัก

6370417021 : MAJOR CYBER-PHYSICAL SYSTEM

KEYWORD: Artificial Intelligence

Sunithi Asavalertpalakorn : Novelty Detection for Predictive Maintenance of a Reciprocating Compressor using Long short-term memory Autoencoder. Advisor: Prof. PAIROD SINGHATANADGID, Ph.D.

The major challenge in predictive maintenance is an insufficiency of failure data used to train the model and the high complexity of industrial plants, where operational conditions change over time. Novelty detection offers a solution to this problem by detecting anomalies through learning only the normal data. This study implemented a novelty detection to detect early signs of failure in a reciprocating compressor using long short-term memory (LSTM) autoencoder. LSTM autoencoder is a deep learning algorithm combining an autoencoder and LSTM network to reconstruct the normal data to learn nonlinear relationships and temporal nature. Additional features were derived from thermodynamic equations to further identify the relationships between variables. The dropout layer was implemented to create an ensemble model of a neural network. The model was trained on multivariate time-series sensors data collected from a real-world normal operation of the compressor provided by Rayong Engineering and Plant Services Co., Ltd. The proposed methods were tested against various simulated fault patterns of the compressor. The results suggested that the LSTM autoencoder can effectively differentiate between normal and fault patterns of the compressor with up to 90% accuracy and 100% recall. Finally, alarm levels were generated to classify the detected faults into 3 categories based on their severity.

Field of Study: Cyber-Physical System

Student's Signature

Academic Year: 2021

Advisor's Signature

กิตติกรรมประกาศ

ขอกราบขอบพระคุณศาสตราจารย์ ดร.ไพโรจน์ สิงห์นัตกิจ อาจารย์ที่ปรึกษาที่มีความเมตตา
กรุณาให้คำแนะนำทั้งในด้านวิชาการและการใช้ชีวิตจนทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดี

ขอกราบขอบพระคุณพี่ทัตพล อาจสำอางค์และบริษัท ระยองวิศวกรรมและซ่อมบำรุง จำกัด
ในธุรกิจเคมีคอลส์ เอสซีจี ที่ให้คำปรึกษาและให้ความอนุเคราะห์ข้อมูลเซ็นเซอร์ที่ถูกรวบรวมมาจาก
เครื่องคอมพิวเตอร์แบบลูกสูบ ซึ่งถูกใช้ในการทำวิทยานิพนธ์ฉบับนี้

ขอกราบขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ ที่ได้ให้ความอนุเคราะห์เป็นกรรมการ
สอบและให้คำแนะนำสำหรับการปรับปรุงวิทยานิพนธ์

ขอกราบขอบพระคุณคณาจารย์และเจ้าหน้าที่ทุกท่านในภาควิชาวิศวกรรมเครื่องกล คณะ
วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ที่ให้คำแนะนำและความรู้แก่ข้าพเจ้า

สุนิธิ อัสวเลิศพลากร



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญภาพประกอบ.....	ณ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ของวิทยานิพนธ์	4
1.3 ขอบเขตของวิทยานิพนธ์	5
1.4 ขั้นตอนการดำเนินงานโดยสรุป	6
บทที่ 2 ปรีทัศน์วรรณกรรม	8
บทที่ 3 ทฤษฎีพื้นฐาน	13
3.1 คอมเพรสเซอร์แบบลูกสูบ (Reciprocating Compressor).....	13
3.2 การบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance: PdM).....	19
3.3 LSTM Autoencoder	20
3.4 การเก็บข้อมูล และการเตรียมข้อมูล.....	27
3.5 การประเมินงานวิจัย	29
3.6 การสร้างระดับสัญญาณเตือน (Alarm levels)	34
บทที่ 4 การสอบทวนแนวคิด LSTM Autoencoder.....	36
บทที่ 5 ผลลัพธ์และการอภิปรายผล	43

5.1. การเตรียมข้อมูลและการจำลองความผิดปกติ.....	43
5.2. ค่าไฮเปอร์พารามิเตอร์ที่ใช้สร้างแบบจำลอง LSTM Autoencoder	43
5.3. รูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาเข้าเกิดรอยร้าว (C1S)	47
5.4. รูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว (C1D)	49
5.5. รูปแบบความเสียหายกระบอกสูบที่ stage 2 ด้านขาเข้าเกิดรอยร้าว (C2S)	51
5.6. รูปแบบความเสียหายกระบอกสูบที่ stage 2 ด้านขาออกเกิดรอยร้าว (C2D)	54
5.7. รูปแบบความเสียหายตัวแลกเปลี่ยนความร้อนระหว่าง stage มีปัญหา (ICI).....	56
5.8. ผลการวิเคราะห์ข้อมูล	58
5.9. สัญญาณแจ้งเตือนความเสียหาย.....	59
บทที่ 6 สรุปผลการวิจัย.....	61
บรรณานุกรม.....	63
ประวัติผู้เขียน.....	69

สารบัญตาราง

	หน้า
ตารางที่ 1 รูปแบบความเสียหายของเครื่องจักรที่ใช้ในวิทยานิพนธ์	17
ตารางที่ 2 เงื่อนไขการสร้างระดับสัญญาณเตือน	35
ตารางที่ 3 Confusion Matrix จากผลการศึกษาเบื้องต้น	40
ตารางที่ 4 เปรียบเทียบ Accuracy ของ LSTM Autoencoder กับงานวิจัยของ Kamat [50]	41
ตารางที่ 5 สรุปผลลัพธ์จากการตรวจจับความแปลกใหม่	59
ตารางที่ 6 สัญญาณแจ้งเตือนความเสียหาย	60



สารบัญภาพประกอบ

	หน้า
รูปที่ 1 แผนภาพแสดงขั้นตอนการดำเนินงาน	7
รูปที่ 2 คอมเพรสเซอร์แบบลูกสูบชนิดวางแนวตั้งประเภทมีสอง stage [25].....	14
รูปที่ 3 แผนภาพการทำงานของคอมเพรสเซอร์ที่ใช้ในวิทยานิพนธ์.....	15
รูปที่ 4 โครงสร้างของ Autoencoder.....	21
รูปที่ 5 โครงสร้างของ LSTM.....	25
รูปที่ 6 โครงสร้างอย่างละเอียดของ LSTM Autoencoder.....	25
รูปที่ 7 ลักษณะของข้อมูลรับเข้าและข้อมูลส่งออกสำหรับแบบจำลอง LSTM Autoencoder [33]	26
รูปที่ 8 สัดส่วนการแบ่งข้อมูล Train, Test และ Validate	30
รูปที่ 9 การจำลองความผิดปกติให้กับข้อมูล.....	32
รูปที่ 10 Confusion Matrix.....	33
รูปที่ 11 โครงสร้างของแท่นทดสอบตลับลูกปืนเม็ดกลม.....	36
รูปที่ 12 แบบจำลอง LSTM Autoencoder ที่ใช้กับข้อมูลจากตลับลูกปืน.....	37
รูปที่ 13 ผลลัพธ์จากการศึกษาเบื้องต้น.....	38
รูปที่ 14 ชุดข้อมูลทดสอบของรูปแบบความเสียหาย Inner race 0.007”	39
รูปที่ 15 Loss (MSE) ของรูปแบบความเสียหาย Inner race 0.007”	39
รูปที่ 16 ผลลัพธ์ของรูปแบบความเสียหาย Inner race 0.007”	39
รูปที่ 17 ผลลัพธ์จากงานวิจัยของ Kamat และคณะ [50]	41
รูปที่ 18 กราฟสหสัมพันธ์ของตัวแปรทั้งหมด	44
รูปที่ 19 แบบจำลอง LSTM Autoencoder ที่ใช้กับคอมเพรสเซอร์ลูกสูบ.....	45
รูปที่ 20 กราฟแสดงค่า loss (mse) ในแต่ละ epoch.....	46
รูปที่ 21 กราฟการกระจายตัวของค่า loss (mse).....	46

รูปที่ 22 ผลลัพธ์ของรูปแบบความเสียหาย C1S.....	47
รูปที่ 23 Confusion Matrix ของรูปแบบความเสียหาย C1S.....	48
รูปที่ 24 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C1S.....	48
รูปที่ 25 เปรียบเทียบ label ของรูปแบบ C1S.....	49
รูปที่ 26 ผลลัพธ์ของรูปแบบความเสียหาย C1D	50
รูปที่ 27 Confusion Matrix ของรูปแบบความเสียหาย C1D	50
รูปที่ 28 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C1D	51
รูปที่ 29 เปรียบเทียบ label ของรูปแบบ C1D	51
รูปที่ 30 ผลลัพธ์ของรูปแบบความเสียหาย C2S.....	52
รูปที่ 31 Confusion Matrix ของรูปแบบความเสียหาย C2S.....	52
รูปที่ 32 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C2S.....	53
รูปที่ 33 เปรียบเทียบ label ของรูปแบบ C2S.....	53
รูปที่ 34 ผลลัพธ์ของรูปแบบความเสียหาย C2D	54
รูปที่ 35 Confusion Matrix ของรูปแบบความเสียหาย C2D	55
รูปที่ 36 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C2D	55
รูปที่ 37 เปรียบเทียบ label ของรูปแบบ C2D	56
รูปที่ 38 ผลลัพธ์ของรูปแบบความเสียหาย IC	56
รูปที่ 39 Confusion Matrix ของรูปแบบความเสียหาย ICI	57
รูปที่ 40 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ ICI	57
รูปที่ 41 เปรียบเทียบ label ของรูปแบบ ICI	58

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

อุตสาหกรรม 4.0 (Industry 4.0) หรือการปฏิวัติอุตสาหกรรมครั้งที่ 4 คือแนวคิดที่มุ่งพัฒนาระบบอัตโนมัติโดยการนำเทคโนโลยีสารสนเทศและการสื่อสาร (Information and Communication Technology: ICT) มาประยุกต์รวมเข้ากับเทคโนโลยีของอุตสาหกรรมการผลิต [1] แนวคิดดังกล่าวประกอบด้วยเทคโนโลยีหลักคือระบบไซเบอร์กายภาพ (Cyber-Physical systems: CPS), ระบบอินเทอร์เน็ตของสรรพสิ่ง (Internet of Things: IoT), ระบบอินเทอร์เน็ตของการบริการ (Internet of Services: IoS) และโรงงานอัจฉริยะ (Smart Factory) [2] โรงงานอัจฉริยะประยุกต์ใช้ปัญญาประดิษฐ์ (Artificial Intelligence: A.I.) ร่วมกับระบบอินเทอร์เน็ตของสรรพสิ่งสำหรับภาคอุตสาหกรรม (Industrial Internet of Things: IIoT) เข้ามาช่วยบริหารจัดการทรัพยากรภายในโรงงานเพื่อการทำงานที่มีประสิทธิภาพมากขึ้น นอกจากนี้โรงงานสามารถใช้ข้อมูลที่เก็บรวบรวมจากเซ็นเซอร์ของเครื่องจักรมาคาดการณ์ความผิดปกติเพื่อวางแผนซ่อมบำรุงรักษาเครื่องจักรก่อนที่จะเกิดความเสียหายขึ้นจริงเพื่อเพิ่มความปลอดภัย, เพิ่มระยะเวลาใช้งานของเครื่องจักร และเพื่อลดค่าใช้จ่ายในการซ่อมบำรุงลง กระบวนการนี้เรียกว่าการบำรุงรักษาเชิงคาดการณ์ หรือการบำรุงรักษาเชิงพยากรณ์ (Predictive Maintenance: PdM) [3]

สามารถแบ่งวิธีการในการบำรุงรักษาเชิงคาดการณ์ในเครื่องจักรออกเป็น 3 วิธีคือ [4]

1. การใช้แบบจำลองถดถอย (regression model) ในการคาดการณ์ค่าระยะเวลาใช้งานคงเหลือของเครื่องจักรก่อนที่จะชำรุด (Remaining Useful Life: RUL) โดยการวิเคราะห์จากการเสื่อมถอย (degradation) ที่พบในข้อมูลการทำงานของเครื่องจักร
2. การพยากรณ์ความชำรุดที่จะเกิดขึ้นภายในช่วงระยะเวลาที่กำหนดด้วยแบบจำลองการจัดหมวดหมู่ (classification model) เช่นคาดการณ์ว่ามีโอกาสที่เครื่องจักรจะเสียหายภายใน 1 เดือนข้างหน้าหรือไม่
3. การตรวจจับพฤติกรรมที่ผิดปกติของเครื่องจักร (anomalous behavior detection) ในกรณีที่ไม่มีข้อมูลรูปแบบความชำรุดของเครื่องจักรเพียงพอจะสามารถใช้เทคนิคการตรวจจับความผิดปกติ (anomaly detection) ในการตรวจจับความเสียหายของเครื่องจักร (fault detection) ตั้งแต่ช่วงเริ่มต้นของความผิดปกติ หากตรวจพบก็จะสามารถคาดการณ์ได้ว่าเครื่องจักรอาจจะชำรุดในอนาคตอันใกล้ [5]

อย่างไรก็ตามสองวิธีแรกจำเป็นต้องมีข้อมูลในอดีตขณะที่เครื่องจักรเกิดการชำรุดจริงซึ่งเป็นเรื่องยากในความเป็นจริง เนื่องจากส่วนใหญ่แล้วโรงงานจะซ่อมแซมเครื่องจักรก่อนที่จะเกิดการชำรุดจริงเสมอเพื่อหลีกเลี่ยงความเสียหายรุนแรงที่อาจเกิดขึ้น ดังนั้นวิทยานิพนธ์นี้จะเลือกใช้วิธีการที่ 3

ดังนั้นจึงสรุปได้ว่าเป้าหมายหลักของการบำรุงรักษาเชิงคาดการณ์ก็คือการตรวจจับความเสียหาย (fault) และรูปแบบของความเสียหาย (fault pattern) ที่เกิดขึ้นในเครื่องจักรด้วยวิธีการตรวจจับความผิดปกติซึ่งเป็นวิธีการแยกแยะตัวแปรหรือกลุ่มของจุดข้อมูลที่มีรูปแบบหรือพฤติกรรมแตกต่างออกไปจากรูปแบบของข้อมูลอื่นในชุดข้อมูลเดียวกัน [6] โดยทั่วไปจะเก็บข้อมูลจากเซ็นเซอร์ของเครื่องจักรแล้วนำมาวิเคราะห์ด้วยวิธีการทางสถิติแบบดั้งเดิม, การเรียนรู้ของเครื่อง (Machine Learning) หรือการเรียนรู้เชิงลึก (Deep Learning)

ความท้าทายที่เกิดขึ้นเมื่อตรวจจับความผิดปกติด้วยวิธีการทางสถิติแบบดั้งเดิมคือ [7]

1. ลักษณะของข้อมูลที่เป็นปกติและผิดปกติ (anomaly) อาจไม่แน่นอนและสามารถเปลี่ยนแปลงได้ ทำให้เกณฑ์ที่ใช้แบ่งความผิดปกติ (threshold) อาจเปลี่ยนตามไปด้วย
2. ข้อมูลทางสถิติอาจมีข้อมูลรบกวน (noise) ผสมอยู่ ทำให้แบบจำลองอาจเข้าใจผิดว่าเป็นความผิดปกติที่ต้องการตรวจจับ
3. รูปแบบของความผิดปกติอาจขึ้นอยู่กับความแปรผันตามฤดูกาลของข้อมูล (seasonality) ทำให้ไม่สามารถตรวจจับรูปแบบความผิดปกติจากข้อมูลหลายตัวแปร (multivariate data) ที่มีความสัมพันธ์ซับซ้อนได้

นอกจากนี้หากนำวิธีการตรวจจับความผิดปกติมาประยุกต์ใช้กับข้อมูลเซ็นเซอร์ที่เก็บมาจากหลายตัวแปรจะพบความท้าทายเพิ่มเติมดังนี้ [8]

1. ถ้าผู้ใช้งานแบบจำลองไม่เข้าใจความรู้เฉพาะทางที่เพียงพอต่อการแยกแยะความผิดปกติที่เกิดขึ้น จะทำให้ไม่สามารถตรวจจับความผิดปกติได้อย่างมีประสิทธิภาพ
2. ตามปกติแล้ววิศวกรผู้ควบคุมระบบจะเป็นผู้ตรวจจับและวินิจฉัยความผิดปกติที่เกิดขึ้นเนื่องจากมีความรู้เฉพาะทางในสายงานนี้ อย่างไรก็ตามถ้าเป็นข้อมูลอนุกรมเวลาแบบหลายตัวแปร (multivariate time-series data) จะกลายเป็นเรื่องที่ยากลำบากและเสี่ยงต่อความผิดพลาดจากมนุษย์มากขึ้น
3. ในการตรวจจับความผิดปกติด้วยการเรียนรู้แบบมีผู้สอน (supervised learning) จำเป็นต้องมีการกำหนดป้ายกำกับ (label) ของข้อมูลที่เพียงพอ และต้องมีการกระจายตัวของประเภท

ของข้อมูลที่สมดุลกัน (balance class distribution) ซึ่งในการทำงานจริงเราอาจมีข้อมูลที่ไม่สมดุลอย่างรุนแรง (extremely imbalance data) เช่นมีเพียงข้อมูลในขณะเครื่องจักรทำงานเป็นปกติเท่านั้น

เพื่อแก้ปัญหาการขาดแคลนข้อมูลความผิดปกติของเครื่องจักรสำหรับใช้ในการฝึกสอนแบบจำลอง เราสามารถใช้ประโยชน์จากข้อมูลของเครื่องจักรขณะที่ทำงานตามปกติที่มีอยู่เป็นจำนวนมากได้ โดยการเปลี่ยนมาใช้วิธีการตรวจจับความแปลกใหม่ (Novelty Detection) ซึ่งเป็นการตรวจจับข้อมูลที่มีรูปแบบหรือพฤติกรรมที่แตกต่างหรือเบี่ยงเบนออกไปจากรูปแบบที่แบบจำลองเคยเรียนรู้มาก่อน โดยการสอนให้แบบจำลองเรียนรู้จากชุดข้อมูลฝึกสอนที่ประกอบด้วยข้อมูลที่เครื่องจักรทำงานเป็นปกติเพียงอย่างเดียว โดยปราศจากค่าที่ผิดปกติเจือปน หลังจากนั้นจะทดสอบด้วยข้อมูลทดสอบ (test data) ที่มีทั้งข้อมูลปกติและข้อมูลที่ผิดปกติผสมอยู่ ถ้าแบบจำลองพบว่าชุดข้อมูลใหม่มีลักษณะที่แตกต่างจากข้อมูลปกติที่เรียนรู้มาจะพยากรณ์ว่าชุดข้อมูลใหม่นั้นเป็นความแปลกใหม่ (novelty) [9] ความแตกต่างระหว่างการตรวจจับความแปลกใหม่และการตรวจจับความผิดปกติ (anomaly detection) คือชุดข้อมูลที่ใช้ในการสอนแบบจำลอง หากข้อมูลชุดนั้นมีเพียงข้อมูลที่เป็นปกติสิ่งที่แบบจำลองตรวจจับได้จะถูกเรียกว่าความแปลกใหม่ แต่ถ้าข้อมูลชุดนั้นมีข้อมูลที่เป็นปกติและผิดปกติผสมกันอยู่ สิ่งที่เราตรวจจับได้จะถูกเรียกว่าความผิดปกติ

ตัวเข้ารหัสอัตโนมัติ หรือ Autoencoder คือโครงข่ายประสาทเทียม (Neural Network: NN) ประเภทหนึ่งที่สามารถเรียนรู้ได้จากข้อมูลฝึกสอนที่ไม่ได้กำหนดป้ายกำกับของข้อมูลไว้ เช่นเดียวกับการเรียนรู้แบบไม่มีผู้สอน [10] ซึ่งจะถูกใช้เพื่อเรียนรู้ที่จะสร้างข้อมูลฝึกสอนขึ้นมาใหม่ (reconstruct) ให้ใกล้เคียงกับของเดิม โดยการบีบอัดข้อมูล (encode) ลงเพื่อให้เหลือแต่ใจความสำคัญของข้อมูล (code) ก่อนที่จะสืมสร้างข้อมูลขึ้นมาใหม่ (decode) ให้คล้ายเดิม ด้วยการใช้แบบจำลองนี้ร่วมกับวิธีการตรวจจับความแปลกใหม่ แบบจำลองจะเรียนรู้ที่จะสร้างเฉพาะข้อมูลปกติที่ได้รับการสอนขึ้นมาใหม่ หากเราใส่ข้อมูลที่ผิดปกติลงในข้อมูลทดสอบแบบจำลองจะล้มเหลวในการสร้างข้อมูลผิดปกติขึ้นเนื่องจากไม่เคยเรียนรู้ที่จะสร้างข้อมูลดังกล่าวขึ้นมาใหม่

โครงข่ายหน่วยความจำระยะสั้นแบบยาว หรือ Long Short-Term Memory Network (LSTM) [11] คือโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) ประเภทหนึ่งที่ถูกออกแบบมาสำหรับเรียนรู้ข้อมูลที่มีลำดับยาวๆ รวมถึงสามารถจดจำข้อมูลลำดับก่อนหน้าเพื่อนำมาใช้ในการพยากรณ์ข้อมูลที่มีลำดับยาวได้ เมื่อใส่ชั้น (layer) ของ LSTM เข้ามาใน

autoencoder เพื่อช่วยในการรับข้อมูลที่เป็นลำดับอนุกรมเวลา (time-series sequential data) ขั้นตอนวิธีใหม่นี้จะถูกเรียกว่า LSTM Autoencoder

คอมเพรสเซอร์แบบลูกสูบ (Reciprocating Compressor) ที่ทำงานอย่างต่อเนื่องเป็นระยะเวลานานอาจส่งผลให้เครื่องจักรหยุดทำงานเนื่องจากต้องทำงานในสภาพแวดล้อมที่มีแรงดันและอุณหภูมิสูง ในบางครั้งคอมเพรสเซอร์ชนิดนี้ยังถูกใช้ในการบีบอัดก๊าซที่สามารถติดไฟหรือระเบิดได้ เช่น ไฮโดรเจน, เอทิลีน (ethylene) หรือ ก๊าซธรรมชาติ [12] หากเครื่องจักรเกิดความเสียหายเช่น กระบอกลูกสูบหรือวาล์วรั่วไหล เมื่อก๊าซอันตรายดังกล่าวรั่วไหลอาจก่อให้เกิดอุบัติเหตุร้ายแรง, ความสูญเสียทางเศรษฐกิจ และเกิดอันตรายต่อพนักงานได้ [13] นอกจากนี้ในกรณีที่ไม่มีเครื่องจักรสำรอง การหยุดทำงานของเครื่องจักรเพียงเครื่องเดียวอาจทำให้กระบวนการผลิตทั้งหมดในโรงงานหยุดชะงักลงอย่างกะทันหัน ซึ่งส่งผลให้สูญเสียกำลังการผลิตอย่างหลีกเลี่ยงไม่ได้

ดังนั้นงานวิจัยนี้จึงนำขั้นตอนวิธีการเรียนรู้เชิงลึกที่ประกอบขึ้นจาก Autoencoder และ LSTM มาใช้ในการตรวจจับความแปลกใหม่ในเครื่องคอมเพรสเซอร์แบบลูกสูบ ซึ่งสามารถนำมาใช้เรียนรู้ข้อมูลอนุกรมเวลาที่เป็นลำดับและสามารถแก้ปัญหาหลักในอุตสาหกรรมคือ ข้อมูลความชำรุดของเครื่องจักรไม่เพียงพอสำหรับการเรียนรู้แบบมีผู้สอน, กฎเกณฑ์ที่ใช้กำหนดความผิดปกติ (rule-based threshold) ไม่เหมาะสมกับรูปแบบความผิดปกติที่ซับซ้อน และการขาดความรู้เฉพาะทางในการแยกแยะระหว่างรูปแบบความปกติและรูปแบบความเสียหายของเครื่องจักร ทั้งนี้ความแปลกใหม่ที่ถูกระบุได้ อาจเป็นความเสียหายที่เกิดขึ้นในเครื่องจักรจริงๆ หรืออาจเป็นรูปแบบความปกติใหม่ที่ไม่เคยพบมาก่อน (new normal) ซึ่งสามารถนำข้อมูลปกติใหม่นี้ไปเพิ่มในข้อมูลฝึกสอนเพื่อให้แบบจำลองเรียนรู้ได้ดียิ่งขึ้น วิธีการที่นำเสนอสามารถใช้เป็นขั้นตอนเบื้องต้นในการบำรุงรักษาเชิงคาดการณ์ในเครื่องจักร เพื่อเพิ่มประสิทธิภาพการทำงานและความปลอดภัยในโรงงาน

1.2 วัตถุประสงค์ของวิทยานิพนธ์

1. เพื่อตรวจจับสัญญาณความเสียหายเริ่มต้นในเครื่องคอมเพรสเซอร์แบบลูกสูบด้วยวิธีการตรวจจับความแปลกใหม่โดยใช้แบบจำลอง LSTM Autoencoder

2. ประเมินประสิทธิภาพของแบบจำลองด้วยชุดข้อมูลทดลองที่จำลองขึ้นจากรูปแบบความผิดปกติที่เกิดขึ้นเมื่อคอมเพรสเซอร์เกิดการรั่วไหลของกระบอกสูบในด้านที่ใช้ดูดและในด้านที่อัดอากาศ และตัวแลกเปลี่ยนความร้อนระหว่าง stage ขำรด
3. สร้างสัญญาณเตือนเพื่อจำแนกความเสียหายที่ตรวจจับได้ออกเป็น 3 ประเภท


1.3 ขอบเขตของวิทยานิพนธ์

1. ใช้ข้อมูลจากเครื่องคอมเพรสเซอร์แบบลูกสูบประเภท Multistage Vertical Reciprocating Compressor รหัสรุ่น J4D300-2M ผลิตโดย JSW LTD. ที่มีกำลังไฟฟ้าสูงสุด 1,250.00 KW, มีความดันขาเข้าและขาออกสูงสุด 0.5-0.8/22 kg/cm²G และมีอัตราการไหลของก๊าซอยู่ที่ 5,300 m³/hr.
2. รวบรวมข้อมูลของเครื่องจักรในขณะที่ทำงานเป็นปกติในช่วงวันที่ 22 พฤศจิกายน 2019 เวลา 16.40 น. จนถึงวันที่ 31 กรกฎาคม 2021 เวลา 06.00 น. โดยจะเก็บข้อมูลจากเซ็นเซอร์ทุก 5 นาที ได้รับตัวแปรทั้งหมด 16 ตัว คือ กระแสไฟฟ้าในมอเตอร์ของคอมเพรสเซอร์, ตำแหน่งของ solenoid valve plate, อัตราการไหลของก๊าซ, ความดันขาเข้าที่ stage 1, อุณหภูมิขาเข้าที่ stage 1, ความดันขาออกที่ stage 1, อุณหภูมิขาออกที่ stage 1, ความดันขาเข้าที่ stage 2, อุณหภูมิขาเข้าที่ stage 2, ความดันขาออกที่ stage 2, อุณหภูมิขาออกที่ stage 2, ผลต่างของความดันที่ stage 2, ปริมาณของ Ethylene ที่ถูกส่งมาจากต้นทาง, ปริมาณของ Propylene ที่ถูกส่งมาจากต้นทาง, อัตราส่วนของความดันที่ stage 1, อัตราส่วนของความดันที่ stage 2, ผลต่างอุณหภูมิของตัวแลกเปลี่ยนความร้อนระหว่าง stage
3. ประเมินวิธีการที่นำเสนอด้วยรูปแบบความเสียหายของเครื่องจักร 5 รูปแบบคือ กระบอกลูกสูบ 1 รั่วที่ด้านดูด, กระบอกลูกสูบ 1 รั่วที่ด้านอัดอากาศ, กระบอกลูกสูบ 2 รั่วที่ด้านดูด, กระบอกลูกสูบ 2 รั่วที่ด้านอัดอากาศ, ตัวแลกเปลี่ยนความร้อนระหว่าง stage มีปัญหา
4. ความแปลกใหม่ที่ถูกรวบรวมด้วยวิธีการตรวจจับความแปลกใหม่มีโอกาสเป็นได้ทั้งความเสียหายจริง และรูปแบบความปกติที่ไม่เคยพบมาก่อนในชุดข้อมูลทดสอบ
5. ไม่มีข้อมูลช่วงที่เครื่องจักรทำงานผิดปกติจริงๆ เนื่องจากโรงงานที่เก็บข้อมูลเพื่อทำวิจัยจะบำรุงรักษาเครื่องจักรชนิดนี้ก่อนเกิดการชำรุดจริงเสมอ

1.4 ขั้นตอนการดำเนินงานโดยสรุป

ขั้นตอนการดำเนินงานแบ่งออกเป็น 11 ขั้นตอน แผนภาพขั้นตอนการดำเนินงานแสดงในรูปที่ 1

1. รวบรวมข้อมูลจากเซ็นเซอร์ของคอมเพรสเซอร์แบบลูกสูบ สร้างตัวแปรทั้งหมด 16 ตัว
2. นำข้อมูลที่ได้มาเตรียมข้อมูลโดยการทำความสะอาดข้อมูลและแปลงข้อมูล เพื่อให้มีรูปแบบที่เหมาะสมต่อการนำไปใช้
3. เพิ่มตัวแปรทางกายภาพเพิ่มเติมจากสมการอุณหพลศาสตร์ (Thermodynamic) ได้แก่ อุณหภูมิขาออกของคอมเพรสเซอร์ และอัตรากำลังบีบอัดในคอมเพรสเซอร์
4. แบ่งข้อมูลออกเป็นชุดข้อมูลฝึกสอน 64%, ชุดข้อมูลตรวจสอบ 16% และชุดข้อมูลทดสอบ 20%
5. จำลองรูปแบบความเสียหายของเครื่องจักรลงในชุดข้อมูลทดสอบตามรูปแบบความเสียหายของเครื่องจักรที่กำหนดไว้ทั้ง 5 รูปแบบ แล้วกำหนดป้ายกำกับลงในชุดข้อมูลทดสอบ
6. สอนแบบจำลอง LSTM Autoencoder ด้วยชุดข้อมูลฝึกสอน
7. ประเมินประสิทธิภาพด้วยชุดข้อมูลตรวจสอบ ผลลัพธ์ที่ได้จะเป็นค่าความผิดพลาดจากการสร้างใหม่
8. ปรับปรุงค่าไฮเปอร์พารามิเตอร์ของแบบจำลองเพื่อให้ได้ประสิทธิภาพที่ดีที่สุด
9. กำหนดเกณฑ์ที่ใช้ตรวจจับความแปลกใหม่จากค่าความผิดพลาดจากการสร้างใหม่ของข้อมูลปกติ
10. พยากรณ์ความเสียหายในชุดข้อมูลทดสอบ หากข้อมูลจุดใดมีค่าความผิดพลาดจากการสร้างใหม่สูงกว่าเกณฑ์ที่กำหนด ข้อมูลจุดนั้นจะถือว่าเป็นความแปลกใหม่ โดยประเมินผลลัพธ์ของแบบจำลองด้วยค่า Precision, Recall, Accuracy, F1 Score
11. สร้างระดับสัญญาณเตือน 3 ระดับตามประเภทของความเสียหายที่แบบจำลอง LSTM Autoencoder ตรวจจับได้



รูปที่ 1 แผนภาพแสดงขั้นตอนการดำเนินงาน

บทที่ 2

ปริทัศน์วรรณกรรม

วิทยานิพนธ์นี้ทำขึ้นเพื่อตรวจจับความแปลกใหม่ในเครื่องคอมพิวเตอร์แบบลูกสูบด้วย LSTM Autoencoder ดังนั้นเนื้อหาในบทนี้จึงรวบรวมผลงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์โดยประกอบไปด้วยงานวิจัยที่เกี่ยวข้องกับการตรวจจับความแปลกใหม่ งานวิจัยที่เกี่ยวข้องกับการตรวจจับความผิดปกติในเครื่องจักรสำหรับการบำรุงรักษาเชิงคาดการณ์ งานวิจัยที่เกี่ยวข้องกับ LSTM Autoencoder และสุดท้ายคืองานวิจัยที่เกี่ยวข้องกับคอมพิวเตอร์แบบลูกสูบ

การตรวจจับความแปลกใหม่คือการจำแนกข้อมูลที่มีความแตกต่างจากข้อมูลที่อยู่ในข้อมูลฝึกสอน (trained data) ในบางครั้งวิธีการนี้อาจเรียกว่าการจำแนกแบบประเภทเดียว (one-class classification) ซึ่งแบบจำลองจะถูกสร้างขึ้นจากการเรียนรู้ข้อมูลที่เป็นปกติเท่านั้น ในปี 2014 Pimentel และคณะ [9] ทบทวนวรรณกรรมที่เกี่ยวข้องกับการตรวจจับความแปลกใหม่ สามารถแบ่งออกได้เป็น 5 หมวดหมู่คือ 1. การตรวจจับด้วยความน่าจะเป็น แบ่งเป็นวิธีการที่ใช้พารามетริกและวิธีการที่ไม่ใช้พารามетริก 2. การตรวจจับด้วยระยะทาง 3. การตรวจจับด้วยการสร้างใหม่ 4. การตรวจจับด้วยโดเมน 5. การตรวจจับด้วยทฤษฎีข้อมูล วิทยานิพนธ์ฉบับนี้ใช้ LSTM Autoencoder จึงเป็นหมวดหมู่ที่ 3 คือการตรวจจับด้วยการสร้างใหม่โดยใช้วิธีการที่เกี่ยวข้องกับโครงข่ายประสาทเทียม

ในปี 2018 Amruthnath และคณะ [14] ศึกษาวิจัยเกี่ยวกับการนำขั้นตอนวิธีการเรียนรู้ของเครื่องแบบไม่มีผู้สอนมาใช้ตรวจจับความเสียหายเริ่มต้นในการบำรุงรักษาเชิงคาดการณ์ ผู้วิจัยใช้ข้อมูลการสั่นสะเทือนจากพัดลมดูดอากาศแล้วเปรียบเทียบความเที่ยงตรงของขั้นตอนวิธีการเรียนรู้ของเครื่องแบบไม่มีผู้สอน เช่น PCA, T^2 statistic, GMM, การจัดกลุ่มตามลำดับชั้น (Hierarchical clustering), K-Means, Fuzzy C-Means clustering ผลลัพธ์แสดงว่า T^2 statistic มีประสิทธิภาพดีและสามารถใช้ได้ในกรณีที่ขาดความรู้ในการจำแนกความเสียหาย ในขณะที่การจัดกลุ่มข้อมูล (clustering) จะเหมาะสมเมื่อความเสียหายที่ต้องการตรวจจับมีหลายระดับ

ในปี 2019 Park และคณะ [15] ตรวจจับและวินิจฉัยความเสียหายในเครื่องจักร โดยการใช้ Autoencoder มาเรียนรู้ข้อมูลขณะที่เครื่องจักรทำงานเป็นปกติ แล้วนำมาตรวจจับความผิดปกติในข้อมูลอนุกรมเวลาหลายตัวแปร ก่อนที่ความผิดปกติที่ถูกตรวจจับได้จะถูกส่งไปจำแนกประเภทของความผิดปกติด้วย LSTM โดยที่แบบจำลองทั้งสองจะถูกฝึกสอนแยกกัน ค่า MSE ของความผิดพลาด

จากการสร้างใหม่ถูกใช้เป็นเกณฑ์ในการตรวจจับความผิดปกติ การวินิจฉัยความผิดปกติด้วย LSTM แบ่งออกเป็นสองส่วนคือการสกัดคุณลักษณะ และการจำแนก นอกจากนี้ชั้นดรอปเอาต์ (dropout layer) ถูกใส่เข้ามาระหว่างชั้นของ LSTM เพื่อลด overfitting สุดท้ายจะคาดการณ์ประเภทของความผิดปกติโดยใช้ฟังก์ชัน softmax และ weighted cross entropy loss function เมื่อนำวิธีการดังกล่าวไปประยุกต์ใช้กับการจำลองด้วย Tennessee Eastman Process (TEP) [16] พบว่าวิธีการนี้สามารถแยกแยะประเภทของความเสียหายได้ดี และมีความเที่ยงตรงสูงกว่าการแยกแยะด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการอย่างลึก (Deep Convolution Neural Network: DCNN) อยู่ 16.9%

Li และคณะ [17] นำเสนอวิธีการใหม่ในการตรวจจับความผิดปกติด้วยการเรียนรู้แบบไม่มีผู้สอนโดยการรวม stacked autoencoder เข้ากับ LSTM เพื่อใช้กับข้อมูลที่ไม่ทราบป้ายกำกับ วิธีการดังกล่าวถูกประยุกต์ใช้กับ Bently Nevada Rotor Kit RK3 ซึ่งจำลองสภาวะการทำงานของเครื่องจักรแบบหมุน และสังเคราะห์ความผิดปกติด้วยการเพิ่มน้ำหนักเพื่อให้น้ำหนักถ่วงเกิดความไม่สมดุล วิธีการ Wavelet Packet Decomposition (WPD) ถูกใช้ในการเลือกคุณลักษณะของข้อมูลในโดเมนเวลาและโดเมนความถี่ ค่าเฉลี่ยความผิดพลาดกำลังสองของการคาดการณ์ที่มีค่าเยอะที่สุดถูกใช้เป็นเกณฑ์ในการตรวจจับความผิดปกติ สุดท้ายเมื่อประเมินด้วย five-fold cross validation พบว่าแบบจำลองสามารถตรวจจับความผิดปกติได้ด้วย ความเที่ยงตรง 99% ผลลัพธ์ดังกล่าวพิสูจน์ว่า SAE-LSTM มีประสิทธิภาพที่จะใช้ในสภาวะที่ต้องเรียนรู้ด้วยการเรียนรู้แบบไม่มีผู้สอน

ต่อมา Hsieh และคณะ [8] ใช้ LSTM ที่ผสมกับ Autoencoder มาตรวจจับความผิดปกติจากข้อมูลเซ็นเซอร์ออนไลน์ซึ่งเป็นข้อมูลอนุกรมเวลาแบบหลายตัวแปรโดยใช้การเรียนรู้แบบไม่มีผู้สอน ก่อนที่จะสร้างสัญญาณแจ้งเตือนแบบเรียลไทม์ เป็นครั้งแรกที่นำวิธีการดังกล่าวมาประยุกต์ใช้กับเซ็นเซอร์ของจริงจากโรงงาน

ในปี 2020 Kamat [7] สำรวจวิธีการตรวจจับความผิดปกติสำหรับการบำรุงรักษาเชิงคาดการณ์ในยุคอุตสาหกรรม 4.0 พบว่าวิธีการทางสถิติล้มเหลวในการทำความเข้าใจการรวมกันของแต่ละตัวแปรที่ก่อให้เกิดความผิดปกติในเครื่องจักรดังเหตุผลที่กล่าวไว้ในบทที่ 1 มาและความสำคัญ ผู้วิจัยนำเสนอโครงร่างการตรวจจับความผิดปกติด้วยการเรียนรู้เชิงลึกซึ่งเกิดจากการรวม LSTM และ Autoencoder เข้าไว้ด้วยกันเพื่อแก้ปัญหาดังกล่าว การตรวจจับความผิดปกติด้วยวิธีนี้สามารถใช้คาดการณ์ความเสียหายก่อนที่จะเกิดเครื่องจักรจะชำรุดจริงเพื่อวางแผนการบำรุงรักษาเชิงคาดการณ์ต่อไป

ต่อมา Ahmad และคณะ [18] ใช้ LSTM Autoencoder ในการสกัดคุณลักษณะจากสัญญาณความสั่นสะเทือนของเครื่องจักรแบบหมุนที่ทำงานเป็นปกติเพื่อตรวจจับความผิดปกติในเครื่องจักร ข้อมูลที่ใช้ศึกษาถูกแบ่งออกเป็นสองชุดเพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง คือชุดที่ถูกสกัดคุณลักษณะด้วย LSTM Autoencoder โดยอัตโนมัติ และชุดที่ผู้วิจัยสกัดด้วยตนเองโดยใช้ป่าโคตเดี่ยว (Isolation Forest) ผลลัพธ์ของงานวิจัยแสดงว่าวิธีที่ใช้ LSTM Autoencoder มีค่า F1 score สูงที่สุด

ในปี 2021 Bampoula และคณะ [19] นำเสนอ LSTM Autoencoder เข้ามาช่วยในการเปลี่ยนจากการบำรุงรักษาเชิงป้องกันมาเป็นการบำรุงรักษาเชิงคาดการณ์ เพื่อคำนวณค่าระยะเวลาใช้งานคงเหลือของเครื่องจักรก่อนที่จะชำรุด วิธีการใหม่ที่ผู้วิจัยนำเสนอคือการนำโครงข่ายประสาทเทียมแต่ละโครงข่ายมาเรียนรู้แต่ละป้ายกำกับแยกกันไป เพื่อนำไปสู่ผลลัพธ์ที่ดีขึ้นในแต่ละกรณี ข้อมูลจากเซ็นเซอร์ในเครื่องบดแบบลูกกลิ้งถูกแบ่งออกเป็น 3 ส่วนตามป้ายกำกับคือสถานะสภาพของเครื่องจักรที่มีระดับต่ำ, กลาง และสูง จากนั้นประเมินประสิทธิภาพการจำแนกป้ายกำกับของแบบจำลองด้วย accuracy, recall, precision, specificity และ F1 score ค่าระยะเวลาใช้งานคงเหลือของเครื่องจักรก่อนที่จะชำรุดจะถูกคำนวณรวมกับการตรวจสอบสถานะของเครื่องจักรในโรงงานจริงพบว่าเมื่ออัตราความเที่ยงตรงระหว่างกรณีที่สถานะสภาพของเครื่องจักรมีระดับต่ำ และกรณีที่เครื่องจักรเกิดการชำรุดจริงมีมากกว่า 10% ค่าระยะเวลาใช้งานคงเหลือของเครื่องจักรก่อนที่จะชำรุดจะเท่ากับ 3 วัน จากนั้นในทุกๆ 10% ที่เพิ่มขึ้น ค่าระยะเวลาใช้งานคงเหลือของเครื่องจักรก่อนที่จะชำรุดจะเพิ่มขึ้น 2 วัน สุดท้ายจึงเปรียบเทียบตารางการบำรุงรักษาเครื่องจักรที่เกิดขึ้นจริงกับการบำรุงรักษาที่ถูกคาดการณ์โดยแบบจำลองพบว่าแบบจำลองสามารถคาดการณ์การชำรุดของเครื่องจักรล่วงหน้า 1 วันก่อนชำรุดจริง และสามารถเพิ่มวันทำงานได้ 96 วันต่อปี และลดการซ่อมบำรุงที่ไม่จำเป็นลงได้ 22.2% ข้อจำกัดของงานวิจัยนี้คือการนำโครงข่ายประสาทเทียมหลายโครงข่ายมาเรียนรู้คำอธิบายแยกกันเพื่อคำนวณค่าระยะเวลาใช้งานคงเหลือของเครื่องจักรก่อนที่จะชำรุดเป็นเรื่องยากในข้อมูลที่มีความซับซ้อนสูงทำให้แบบจำลองอาจจำแนกผิดพลาด รวมถึงเป็นเรื่องยากในการรวบรวมข้อมูลขณะที่เครื่องจักรชำรุดในความเป็นจริง

ต่อมา Mallak และคณะ [20] ตรวจจับความเสียหายของเซ็นเซอร์และชิ้นส่วนในเครื่องจักรไฮดรอลิกโดยใช้ LSTM Autoencoder ในการเรียนรู้จากข้อมูลเครื่องจักรในขณะที่มีสภาพดีเพื่อสร้างข้อมูลดังกล่าวขึ้นมาใหม่ หากข้อมูลใหม่ที่ได้รับมามีพฤติกรรมที่เบี่ยงเบนไปจนเกินเกณฑ์ที่กำหนดจะถือว่าเป็นความเสียหาย การทดลองจะถูกออกแบบเป็นสองการทดลองที่แยกเป็นอิสระออก

จากกันเพื่อใช้ตรวจจับความเสียหายจากเซ็นเซอร์และความเสียหายจากชิ้นส่วนของเครื่องจักร มาตรวัดที่ใช้ในการเปรียบเทียบความเบี่ยงเบนระหว่างข้อมูลจริงกับข้อมูลที่ถูกรังใหม่คือ Pearson's Autocorrelation สุดท้ายจึงวินิจฉัยความเสียหายจากข้อมูลความเสียหายที่ถูกตรวจจับได้ด้วยการจำแนกด้วยวิธีการเรียนรู้ด้วยเครื่องหรือการเรียนรู้เชิงลึกได้แก่ LR, LDA, KNN, CART, NB, SVM, RF, CNN และ LSTM สรุปว่าในการทดลองแรกวิธีที่มีความเที่ยงตรงสูงที่สุดคือการใช้ CART หรือ LSTM ร่วมกับการสกัดคุณลักษณะจากโดเมนเวลา ในการทดลองที่สองพบว่า Random Forest (RF) ร่วมกับการทำ feature importance (FI) ได้ความเที่ยงตรงสูงที่สุด

งานวิจัยที่เกี่ยวข้องกับการวินิจฉัยความเสียหายในเครื่องคอมเพรสเซอร์แบบลูกสูบด้วยการเรียนรู้ของเครื่องถูกทบทวนโดย Lv [21] วิธีที่ได้รับการยอมรับโดยทั่วไปคือ Artificial Neural Network (ANN), Support Vector Machine (SVM), Bayesian Network และการเรียนรู้เชิงลึกวิธีที่นิยมมากที่สุดคือ ANN และ SVM การวินิจฉัยความผิดปกติอาจขึ้นอยู่กับ 1. ตัวแปร เช่น ความดัน อุณหภูมิ และอัตราการไหล แบ่งเป็น 1.1. แผนภาพความดันและปริมาตร (p-V diagram) จากความดันของกระบอกลูกสูบ 1.2. ความดันในปริมาตรอื่นที่ไม่ใช่จากกระบอกลูกสูบ 2. สัญญาณความสั่นสะเทือน 3. การปล่อยเสียง (Acoustic Emission) 4. สัญญาณจากหลายแหล่งกำเนิด การวินิจฉัยความผิดปกติจากสัญญาณความสั่นสะเทือนและการปล่อยเสียงจำเป็นต้องผ่านการเตรียมข้อมูลที่ซับซ้อนเพื่อให้ได้องค์ประกอบของสัญญาณดิบที่เหมาะสมต่อการนำไปใช้

ในปี 2021 Charoenchitt และคณะ [22] นำเสนอวิธีการใหม่ในการตรวจจับความผิดปกติเริ่มต้นของเครื่องคอมเพรสเซอร์แบบลูกสูบด้วย Autoencoder โดยการรวมสมการอุณหภูมิขาออกของคอมเพรสเซอร์จากสมการอุณหพลศาสตร์เข้ากับข้อมูลที่ได้จากเซ็นเซอร์ของเครื่องจักร เพื่อช่วยให้แบบจำลองสามารถเข้าใจความสัมพันธ์ระหว่างอุณหภูมิ, ความดัน และน้ำหนักโมเลกุลของก๊าซ ข้อมูลถูกเก็บรวบรวมมาจากเซ็นเซอร์ 79 ตัว สามารถแบ่งข้อมูลออกเป็น 4 ประเภท คือช่วงที่เครื่องจักรทำงานเป็นปกติ, สองเดือนก่อนชำรุด, หนึ่งเดือนก่อนชำรุด และ 15 วันก่อนชำรุด ผู้วิจัยสอนแบบจำลอง Autoencoder ด้วยข้อมูลในขณะที่เครื่องจักรทำงานเป็นปกติ ข้อมูลดังกล่าวถูกสร้างเป็นสองชุด คือชุดที่เก็บข้อมูลจากเซ็นเซอร์ 79 ตัว และชุดที่มีการเพิ่มคุณลักษณะของข้อมูล 12 ตัว เมื่อนำแบบจำลองไปพยากรณ์ข้อมูลช่วงที่เครื่องจักรใกล้ชำรุดพบว่าค่าความผิดพลาดจากการสร้างใหม่เพิ่มมากขึ้นเมื่อเครื่องจักรใกล้ชำรุด และแบบจำลองที่เรียนรู้จากการเพิ่มคุณลักษณะของข้อมูลได้ค่าความผิดพลาดที่น้อยกว่า ดังนั้นจึงสรุปได้ว่าการเพิ่มคุณลักษณะของข้อมูลช่วยให้

Autoencoder เรียนรู้ข้อมูลปกติได้ดีขึ้นทำให้แยกแยะข้อมูลของเครื่องคอมพิวเตอร์แบบลูกสูบระหว่างช่วงที่เป็นปกติและชำรุดได้อย่างเที่ยงตรงมากขึ้น

สุดท้าย Bueno และคณะ [23] เปรียบเทียบวิธีการการเรียนรู้ด้วยเครื่องและการเรียนรู้เชิงลึกสำหรับนำมาใช้ในการตรวจจับความแปลกใหม่จากสัญญาณความถี่ ข้อจำกัดของการบำรุงรักษาเชิงคาดการณ์คือข้อมูลฝึกสอนที่ถูกใช้สร้างแบบจำลองในครั้งแรกสุดอาจไม่มีข้อมูลของเครื่องจักรครบทุกสถานภาพการทำงาน นอกจากนี้การตรวจสอบสถานะของเครื่องจักรแบบออนไลน์อาจพบข้อมูลของเครื่องจักรที่มีสถานภาพการทำงานรวมถึงสภาพแวดล้อมการทำงานที่เปลี่ยนแปลงไป หากสถานภาพการทำงานเปลี่ยนแปลงไปจากที่แบบจำลองเคยเรียนรู้ อาจทำให้ประสิทธิภาพของการคาดการณ์ลดลง ปัญหาดังกล่าวคือการเคลื่อนของแนวคิด (Concept Drift) หากตรวจพบการเคลื่อนของแนวคิดจะต้องนำข้อมูลที่ได้รับมาใหม่ไปเพิ่มในข้อมูลฝึกสอนเพื่อปรับปรุงแบบจำลอง การตรวจจับการเคลื่อนของแนวคิดสามารถกระทำได้ด้วยวิธีการตรวจจับความแปลกใหม่ ผลลัพธ์จากการเปรียบเทียบพบว่าแบบจำลองการเรียนรู้เชิงลึก (LSTM Autoencoder และ CNN) มีประสิทธิภาพสูงกว่าแบบจำลองจากวิธีทั่วไป (การจัดกลุ่ม, LOF, PCA, SVM, IF) แต่ใช้เวลาในการเรียนรู้นานกว่าวิธีการที่ใช้ Autoencoder มีความคงทนต่อสัญญาณรบกวนดีกว่าวิธีอื่น ดังนั้นแบบจำลองการเรียนรู้เชิงลึกจึงเหมาะสมที่จะใช้กับการตรวจจับความแปลกใหม่

จากการศึกษางานวิจัยข้างต้นจะเห็นว่าการตรวจจับความผิดปกติด้วย LSTM Autoencoder มีประสิทธิภาพสูงและเหมาะสมที่จะใช้กับข้อมูลอนุกรมเวลา วิทยานิพนธ์นี้จึงใช้ LSTM Autoencoder เพื่อตรวจจับความแปลกใหม่ในเครื่องคอมพิวเตอร์แบบลูกสูบโดยการตรวจจับด้วยการสร้างใหม่ แผนการดำเนินงานโดยรวมจะใกล้เคียงกับงานวิจัยของ Mallak และคณะ [20] นอกจากนี้ยังเพิ่มขั้นตอนเอาต์เฟรมระหว่างชั้นของแบบจำลองเพื่อลด overfitting และใช้ค่า MSE ของความผิดพลาดจากการสร้างใหม่เป็นเกณฑ์ในการตรวจจับความผิดปกติเช่นเดียวกับงานวิจัยของ Park [15] และเพื่อช่วยให้แบบจำลองสามารถเข้าใจความสัมพันธ์ระหว่างตัวแปรได้ดียิ่งขึ้น จึงรวมสมการอนุกรมมิวออกของคอมพิวเตอร์จากสมการอนุกรมพลศาสตร์เข้ากับข้อมูลที่ได้จากเซ็นเซอร์ของเครื่องจักรเช่นเดียวกับงานวิจัยของ Charoenchitt และคณะ [22]

บทที่ 3

ทฤษฎีพื้นฐาน

เนื้อหาในบทนี้อธิบายเกี่ยวกับทฤษฎีและแนวคิดที่เกี่ยวข้องกับวิทยานิพนธ์ได้แก่ เครื่องคอมเพรสเซอร์แบบลูกสูบ, การบำรุงรักษาเชิงคาดการณ์, LSTM Autoencoder, การเก็บข้อมูล และการเตรียมข้อมูล, การประเมินงานวิจัย, การสร้างระดับสัญญาณเตือน

3.1 คอมเพรสเซอร์แบบลูกสูบ (Reciprocating Compressor)

ในอุตสาหกรรมน้ำมันและก๊าซ คอมเพรสเซอร์หรือเครื่องอัดอากาศจะถูกนำมาใช้ในการบีบอัดปริมาตรของของไหลที่บีบอัดได้ (compressible fluid) เช่น ก๊าซหรือไอน้ำเพื่อเพิ่มความดัน ซึ่งการที่เราเพิ่มความดันของก๊าซจะทำให้เราสามารถส่งก๊าซในท่อส่งได้ปริมาณที่มากขึ้น, ลดการสูญเสียของก๊าซในขณะที่ขนส่งเนื่องจากแรงเสียดทาน และทำให้สามารถส่งก๊าซได้ระยะทางไกลขึ้นโดยไม่จำเป็นต้องติดตั้งปั๊มเพิ่มแรงดัน (booster pump)

คอมเพรสเซอร์จะแบ่งออกเป็น 2 ชนิดตามรูปแบบในการอัดอากาศดังนี้

1. คอมเพรสเซอร์ประเภทไดนามิก (Dynamic Compressor) จะอัดอากาศโดยใช้การเหวี่ยงจากใบพัดเพื่อเพิ่มความเร่งของอากาศ ทำให้เกิดการสร้างพลังงานจลน์ซึ่งจะเปลี่ยนเป็นความดันในที่สุด แบ่งออกเป็น คอมเพรสเซอร์แบบแรงเหวี่ยงหนีศูนย์กลาง (Centrifugal) และคอมเพรสเซอร์แบบเพลลา (Axial)
2. คอมเพรสเซอร์ประเภทปริมาตรแทนที่เชิงบวก (Positive Displacement Compressor) จะเก็บอากาศไว้ในห้องอัดอากาศ (compression chamber) จากนั้นจะบีบอัดจากภายนอกเพื่อลดปริมาตรและเพิ่มความดันของอากาศ แบ่งออกเป็นคอมเพรสเซอร์แบบโรตารี (Rotary) และคอมเพรสเซอร์แบบลูกสูบ (Reciprocating)

3.1.1 หลักการทำงานของคอมเพรสเซอร์แบบลูกสูบ

เป็นคอมเพรสเซอร์ประเภทปริมาตรแทนที่เชิงบวก ซึ่งใช้ลูกสูบที่ขับเคลื่อนเป็นเส้นตรงด้วยเพลลาข้อเหวี่ยง (crank shaft) ในการดัก, บีบอัด และดันก๊าซเข้าไปในกระบอกสูบทำให้สารมีปริมาตรน้อยลงเพื่อเพิ่มความดันของก๊าซ [24] คอมเพรสเซอร์ชนิดนี้ทำงานโดยอาศัยมอเตอร์ไฟฟ้าในการ


ขยับลูกสูบ เนื่องจากมีชิ้นส่วนที่เคลื่อนไหวได้จึงควรเติมสารหล่อลื่นเป็นครั้งคราวไม่เช่นนั้นประสิทธิภาพของเครื่องจักรอาจลดลงได้ แบ่งออกเป็น 2 ประเภท คือ

1. Single stage design ก๊าซจะถูกดูดเข้าไปในกระบอกสูบแล้วบีบอัดในครั้งเดียว จากนั้นก๊าซที่ถูกบีบอัดแล้วจะถูกส่งไปเก็บที่แท็งก์เก็บอากาศ
2. Two stage design จะเพิ่มลูกสูบมาอีกหนึ่งกระบอก เพื่อเพิ่มความสามารถในการบีบอัดและเพิ่มความดันให้มากขึ้น

ประกอบด้วยชิ้นส่วนดังนี้

- Piston ลูกสูบ
- Suction ตัวดูด
- Cylinder กระบอกสูบ
- Cylinder heads หัวกระบอกสูบ
- Discharge valves วาล์วระบาย


เครื่องจักรที่ใช้เก็บข้อมูลในวิทยานิพนธ์คือคอมเพรสเซอร์แบบลูกสูบชนิดวางแนวตั้งประเภทมีหลาย stage (Multistage Vertical Reciprocating Compressor ซึ่งเป็นประเภท two stage design ดังแสดงในรูปที่ 2



รูปที่ 2 คอมเพรสเซอร์แบบลูกสูบชนิดวางแนวตั้งประเภทมีสอง stage [25]

3.1.2 คำอธิบายของเซ็นเซอร์แต่ละตัว

เครื่องคอมเพรสเซอร์ที่ใช้ในวิทยานิพนธ์นี้ถูกใช้เพื่อหมุนเวียนก๊าซในเครื่องทำปฏิกิริยา (reactor) มีกระบวนการทำงานดังรูปที่ 3 เมื่อตัวเลขคือตัวแปรที่ถูกเก็บข้อมูลมาจากเซ็นเซอร์



รูปที่ 3 แผนภาพการทำงานของคอมเพรสเซอร์ที่ใช้ในวิทยานิพนธ์

- ในขณะที่ใส่ก๊าซเข้าไปในคอมเพรสเซอร์จะวัดค่าของอัตราการไหลของก๊าซ จากนั้นจะวัดอุณหภูมิและความดันขาเข้าที่ stage 1 ก่อนที่จะส่งต่อไปยัง Knockout Drum เพื่อแยกน้ำและของเหลวออกจากก๊าซ
- หลังจากนั้นก๊าซจะถูกส่งไปยัง stage 1 ของคอมเพรสเซอร์ เพื่อบีบอัดก๊าซ จากนั้นจึงวัดอุณหภูมิและความดันขาออกที่ stage 1 แล้วส่งต่อไปยัง Heat Exchanger เพื่อ cooldown ระบบไม่ให้อุณหภูมิสูงจนเกินไป
- วัดอุณหภูมิขาเข้าที่ stage 2 แล้วส่งไปที่ Knockout Drum อีกครั้ง จากนั้นส่งกลับไปที่ stage 2 ของคอมเพรสเซอร์เพื่อบีบอัดก๊าซอีกครั้ง ก่อนที่จะลำเลียงก๊าซไปขั้นตอนถัดไป
- วัดอุณหภูมิขาออกที่ stage 2 แล้วส่งไปที่ Knockout Drum อีก 2 ครั้ง จากนั้นวัดความดันขาออกที่ stage 2
- ส่งก๊าซที่บีบอัดแล้วไปที่เครื่องทำปฏิกิริยา

คำอธิบายของแต่ละตัวแปรที่ถูกเก็บข้อมูลมาจากเซ็นเซอร์ :

1. กระแสไฟฟ้าในมอเตอร์ของคอมเพรสเซอร์ มีหน่วยเป็น แอมแปร์
2. ตำแหน่งของวาล์ว solenoid มีหน่วยเป็น %

3. อัตราการไหลของก๊าซ มีหน่วยเป็น m^3/hr
4. ความดันขาเข้าที่ stage 1 มีหน่วยเป็น $\text{kg}/\text{cm}^2\text{G}$
5. อุณหภูมิขาเข้าที่ stage 1 มีหน่วยเป็น องศาเซลเซียส
6. ความดันขาออกที่ stage 1 ซึ่งจะเท่ากับความดันขาเข้าที่ stage 2 มีหน่วยเป็น $\text{kg}/\text{cm}^2\text{G}$
7. อุณหภูมิขาออกที่ stage 1 มีหน่วยเป็น องศาเซลเซียส
8. อุณหภูมิขาเข้าที่ stage 2 มีหน่วยเป็น องศาเซลเซียส
9. อุณหภูมิขาออกที่ stage 2 มีหน่วยเป็น องศาเซลเซียส
10. ความดันขาออกที่ stage 2 มีหน่วยเป็น $\text{kg}/\text{cm}^2\text{G}$
11. ผลต่างของความดันที่ stage 2 คำนวณจาก ความดันขาออกที่ stage 1 - ความดันขาออกที่ stage 2
12. ปริมาณของ Ethylene ที่ถูกส่งมาจากต้นทาง มีหน่วยเป็น %
13. ปริมาณของ Propylene ที่ถูกส่งมาจากต้นทาง มีหน่วยเป็น %
14. อัตราส่วนของความดันที่ stage 1 มีหน่วยเป็น %
15. อัตราส่วนของความดันที่ stage 2 มีหน่วยเป็น %
16. ผลต่างอุณหภูมิของตัวแลกเปลี่ยนความร้อนระหว่าง stage (Interstage cooler delta temperature: ICDT) มีหน่วยเป็น องศาเซลเซียส

3.1.3 รูปแบบความเสียหายของเครื่องจักร (Fault pattern)

รูปแบบความเสียหายที่ใช้ในวิทยานิพนธ์ฉบับนี้ได้แก่

- กระบอกสูบที่ stage 1 ด้านขาเข้าเกิดรอยร้าว (C1S)
- กระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว (C1D)
- กระบอกสูบที่ stage 2 ด้านขาเข้าเกิดรอยร้าว (C2S)

3.1.4 ตัวแปรทางกายภาพเพิ่มเติมจากสมการอุณหพลศาสตร์

ตัวแปรใหม่จะถูกเพิ่มเข้ามาในชุดข้อมูลที่ใช้สอนแบบจำลองโดยนำมาจากสมการอุณหพลศาสตร์ของคอมเพรสเซอร์แบบลูกสูบ ซึ่งคำนวณได้จากตัวแปรของแต่ละเซ็นเซอร์ ณ ช่วงเวลานั้นของเครื่องจักร เพื่อช่วยให้แบบจำลองสามารถทำความเข้าใจกับความสัมพันธ์ระหว่างตัวแปรได้ดียิ่งขึ้น และเพื่อเพิ่มความเที่ยงตรงในการคาดการณ์ของแบบจำลอง ตัวแปรเพิ่มมาจาก 2 สมการ ดังนี้

1. อุณหภูมิขาออกของคอมเพรสเซอร์ (Compressor Discharge Temperature: T_d)

[26] แสดงในสมการ

$$T_d = T_s \left(\frac{P_d}{P_s} \right)^{\frac{k-1}{k}} \quad (1)$$

เมื่อกำหนดให้ :

T_s คืออุณหภูมิขาเข้าของเครื่องจักร จากตัวแปรอุณหภูมิขาเข้าที่ stage 1 และอุณหภูมิขาเข้าที่ stage 2

P_d คือความดันขาออกของเครื่องจักร จากตัวแปรความดันขาออกที่ stage 1 และความดันขาออกที่ stage 2

P_s คือความดันขาเข้าของเครื่องจักร จากตัวแปรความดันขาเข้าที่ stage 1 และความดันขาเข้าที่ stage 2

k คือค่าอัตราส่วนความร้อนจำเพาะ (Specific heat ratio) ของ propene (propylene) = 1.15 [27]

2. อัตราการบีบอัด (Compression Ratio: P_r หรือ R) คืออัตราส่วนระหว่างความดันขาเข้าต่อความดันขาออกของคอมเพรสเซอร์ แสดงในสมการ

$$P_r = \frac{\text{Compressor discharge pressure}}{\text{Compressor suction pressure}} = \frac{P_{\text{discharge}}}{P_{\text{suction}}} \quad (2)$$

เมื่อกำหนดให้ :

$P_{\text{discharge}}$ คือความดันขาออกของเครื่องจักร จากตัวแปรความดันขาออกที่ stage 1 และความดันขาออกที่ stage 2

P_{suction} คือความดันขาเข้าของเครื่องจักร จากตัวแปรความดันขาเข้าที่ stage 1 และความดันขาเข้าที่ stage 2

3.2 การบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance: PdM)

การบำรุงรักษาเครื่องจักร สามารถแบ่งได้เป็น 3 ประเภทหลัก คือ [28]

1. การบำรุงรักษาเชิงแก้ไข (Run-to-Failure Maintenance: RM) คือการซ่อมแซมเครื่องจักรหลังจากที่เครื่องจักรชำรุดไปแล้ว เป็นวิธีการที่ง่ายที่สุดแต่จะใช้เวลาและค่าซ่อมบำรุงมากจึงทำให้วิธีนี้ไม่มีประสิทธิภาพ ดังนั้นวิธีการนี้จึงมักใช้กับเครื่องจักรที่สามารถปล่อยให้ชำรุดได้โดยไม่เกิดผลกระทบหรือมีผลกระทบน้อยกับการทำงาน สิ่งแวดล้อม หรือความปลอดภัย
2. การบำรุงรักษาเชิงป้องกัน (Preventive Maintenance: PM) คือการซ่อมแซมเครื่องจักรตามกำหนดการที่กำหนดไว้ล่วงหน้า เพื่อป้องกันการชำรุดของเครื่องจักร เช่น การกำหนดว่า จะต้องซ่อมแซมเครื่องจักรทุก 6 เดือน หรือการเปลี่ยนอุปกรณ์เมื่อทำงานครบทุก 1000 วงรอบ อย่างไรก็ตามบ่อยครั้งที่การซ่อมแซมเครื่องจักรด้วยวิธีนี้จะเกิดขึ้นโดยไม่จำเป็นเนื่องจากถึงจะครบกำหนดซ่อมแซมแต่เครื่องจักรยังมีสภาพที่ดีอยู่ หรือเครื่องจักรอาจจะใกล้ชำรุดแล้วแม้ว่าจะยังไม่ถึงกำหนดการซ่อมแซม
3. การบำรุงรักษาเชิงคาดการณ์หรือเชิงพยากรณ์ (Predictive Maintenance: PdM) คือการใช้วิธีการทางวิทยาศาสตร์ข้อมูล (data science) ร่วมกับการวิเคราะห์ข้อมูลในการตรวจจับความผิดปกติที่เกิดขึ้นในเครื่องจักรเพื่อวางแผนซ่อมแซมก่อนที่เครื่องจักรหรืออุปกรณ์จะชำรุดจริง วิธีการนี้เป็นการบำรุงรักษาเครื่องจักรรวมกับการใช้แบบจำลองการเรียนรู้ของเครื่องหรือการเรียนรู้เชิงลึกที่มีความซับซ้อน โดยจะใช้ข้อมูลการทำงานในอดีตของเครื่องจักรมาใช้ในการวิเคราะห์ความสัมพันธ์ระหว่างแต่ละเซ็นเซอร์แบบพลวัต (dynamic) ซึ่งจะทำให้สามารถตรวจจับพฤติกรรมของความผิดปกติในเครื่องจักรที่มีความซับซ้อนมากยิ่งขึ้น เพื่อสร้างแบบจำลองที่จะคาดการณ์ว่าเครื่องจักรจะชำรุดเมื่อใด วิธีนี้เป็นวิธีบำรุงรักษาเครื่องจักรที่มีประสิทธิภาพมากที่สุดในแง่ของการบริหารเวลาและทรัพยากร ซึ่งสามารถลดค่าใช้จ่ายในการบำรุงรักษาเครื่องจักร ลดระยะเวลาในการซ่อมแซมเครื่องจักร ลดระยะเวลาที่ต้องหยุดการผลิตในโรงงานเพื่อซ่อมบำรุง และเพิ่มอายุการใช้งานของเครื่องจักร


3.3 LSTM Autoencoder

แบบจำลองที่ใช้ในวิทยานิพนธ์นี้คือ LSTM Autoencoder ซึ่งเป็นการใส่ชั้นของ LSTM เข้าไปในแบบจำลอง Autoencoder เนื้อหาในบทนี้จะอธิบายเนื้อหาแยกตามส่วนประกอบของแบบจำลองคือ Autoencoder และ LSTM ก่อนที่จะนำมารวมกันเป็น LSTM Autoencoder

3.3.1 ตัวเข้ารหัสอัตโนมัติ (Autoencoder)

Autoencoder คือโครงข่ายประสาทเทียมประเภทหนึ่งที่จะสร้างข้อมูลรับเข้าที่ได้รับขึ้นมาใหม่ (reconstruct) เพื่อสร้างเป็นข้อมูลส่งออกที่มีคุณสมบัติใกล้เคียงกับข้อมูลรับเข้าเดิมมากที่สุด โดยการลดมิติ (dimension reduction) [29] ข้อมูลรับเข้าลงเหลือแค่ code เพื่อเรียนรู้เฉพาะส่วนที่สำคัญที่สุดซึ่งเป็นตัวแทน (representation) ของข้อมูลทั้งหมด ก่อนที่จะสร้างข้อมูลฝึกสอนขึ้นมาใหม่จาก code [30] ตัวอย่างของการใช้งาน Autoencoder คือใช้ในคอมพิวเตอร์วิทัศน์ (computer vision) การรู้จำคำพูด (speech recognition) และการประมวลผลภาษาธรรมชาติ (natural language processing) [31] [32] โครงสร้างของ Autoencoder อย่างง่ายแสดงในรูปที่ 4 มีคุณสมบัติดังนี้ [33]

- Autoencoder จะมีประสิทธิภาพในสร้างใหม่ดีก็ต่อเมื่อได้รับการสอนจากข้อมูลประเภทเดียวกันเท่านั้น เช่น ถ้าสอนแบบจำลองด้วยข้อมูลฝึกสอนที่เป็นรูปภาพ แบบจำลองจะมีประสิทธิภาพต่ำเมื่อต้องนำข้อมูลทดสอบที่เป็นรูปหน้าคนมาสร้างใหม่
- ผลลัพธ์ที่ได้จากแบบจำลองจะเกิดความสูญเสียของข้อมูล (lossy data) กล่าวคือข้อมูลส่งออกที่ถูกสร้างขึ้นมาใหม่จะมีคุณภาพของข้อมูลที่ลดลงเมื่อเทียบกับข้อมูลดั้งเดิมที่ได้รับเข้ามา
- แบบจำลองชนิดนี้เป็นการเรียนรู้ด้วยตนเอง (self-supervised learning) เพราะสามารถเรียนรู้ได้จากข้อมูลฝึกสอนที่ไม่ได้กำหนดป้ายกำกับเช่นเดียวกับการเรียนรู้แบบไม่มีผู้สอน (unsupervised learning) แต่แบบจำลองจะสกัดเอาป้ายกำกับหรือตัวแทนความสัมพันธ์ของข้อมูลออกมาด้วยตนเองโดยอัตโนมัติ (pseudo-labeling) เพื่อใช้ในการเรียนรู้โครงสร้างของข้อมูลด้วยตนเอง การเรียนรู้ประเภทนี้เหมือนการเรียนรู้แบบมีผู้สอน (supervised learning) ตรงที่ต้องการหาความสัมพันธ์ระหว่างข้อมูลรับเข้า และข้อมูลส่งออกเหมือนกัน แต่จะไม่ได้ใช้แค่ป้ายกำกับในการจำแนกเพียงอย่างเดียว เพราะแบบจำลองจะวิเคราะห์ข้อมูลฝึกสอนเพื่อสกัดเอาความสัมพันธ์ของข้อมูล, ข้อมูลย่อยที่เอาไว้อธิบายข้อมูลหลัก (Metadata) หรือความรู้เชิงลึกในสาขานั้นด้วยตนเอง [34]



รูปที่ 4 โครงสร้างของ Autoencoder

Autoencoder ประกอบด้วย 3 ส่วนหลัก คือ Encoder (ϕ), Code และ Decoder (ψ) มีความสัมพันธ์ดังสมการ

$$\phi = X \rightarrow H \quad (3)$$

และ
$$\psi = H \rightarrow X \quad (4)$$

และ
$$\phi, \psi = \arg_{\phi, \psi} \min \|X - (\psi \cdot \phi)X\|^2 \quad (5)$$

เพื่อให้ง่ายต่อการทำความเข้าใจสมการจะอธิบายกรณีของ autoencoder อย่างง่ายที่มีชั้นซ่อนตัว (hidden layer) เพียงชั้นเดียว ในกรณีนี้ Encoder จะรับข้อมูลรับเข้า X แล้วบีบอัดเป็น Code H ที่กึ่งกลางของแบบจำลอง จากนั้น Decoder จะเปลี่ยน H กลับเป็นข้อมูลส่งออกที่หน้าตาเหมือนข้อมูลรับเข้า X ที่ได้รับ

1. การเข้ารหัส (Encoder: ϕ)

คือขั้นตอนที่ autoencoder จะลดมิติของข้อมูลเพื่อบีบอัดข้อมูลรับเข้าที่ได้รับมาให้มีขนาดเล็กลง เพื่อสร้าง code ขึ้นมาผ่านโครงข่ายประสาทเทียมโดยใช้ activation function ที่ไม่เป็นเชิงเส้น code จะถูกสร้างด้วยสมการ

$$h = \sigma(Wx + b) \quad (6)$$

h คือ Code

σ คือ activation function

W คือ weight matrix

x คือ Input vector

b คือ bias vector

ค่า W และ b จะถูกแบบจำลองปรับแก้ค่าไปเรื่อยๆ โดยใช้วิธีการคำนวณความผิดพลาดย้อนหลังของแบบจำลอง (backpropagation)

เนื่องจาก activation functions ที่ใช้ในแต่ละ neuron ของ autoencoder จะเป็นแบบไม่เป็นเชิงเส้น เช่น Sigmoid, ReLU ดังนั้น autoencoder จึงสามารถนำมาใช้เป็นขั้นตอนวิธีลดมิติข้อมูลแบบไม่เป็นเชิงเส้น (non-linear dimension reduction algorithm) ได้

2. ตัวแปรแฝง (Code หรือ Latent variables)

code คือส่วนที่เป็นชั้นซ่อนตัวตรงกลางของโครงข่าย มีลักษณะเป็นคอขวด (bottleneck) เป็นข้อมูลที่ถูกบีบอัดมาจากชั้น encoder จึงเป็นชั้นที่มีมิติของข้อมูลเล็กที่สุดในแบบจำลอง ข้อมูลในชั้นนี้คือข้อมูลที่เป็นตัวแทนของข้อมูลทั้งหมดในข้อมูลรับเข้า จึงสรุปได้ว่าเป็นข้อมูลที่ถูกสกัดมาเฉพาะส่วนที่มีความสำคัญมากที่สุด ยิ่ง code มีขนาดเล็กเท่าไรก็ยิ่งลดโอกาสที่จะเกิด overfitting ได้มากขึ้นเท่านั้น (overfitting คือการที่แบบจำลองสามารถเรียนรู้จากข้อมูลฝึกสอนได้เป็นอย่างดี แต่ไม่สามารถนำไปวิเคราะห์ข้อมูลที่ไม่เคยเห็นมาก่อนได้)

3. การถอดรหัส (Decoder: ψ)

คือขั้นตอนที่แบบจำลองจะสร้างข้อมูลรับเข้าขึ้นมาใหม่เพื่อเป็นข้อมูลส่งออกโดยใช้ข้อมูลจากใน code หลังจากทีลดมิติข้อมูลรับเข้าจนเหลือเพียงแค่ code ได้แล้ว สามารถสรุปได้ว่าชั้น encoder คือการบีบอัดข้อมูล (compressor) และชั้น decoder คือการคลายการบีบอัดข้อมูล (decompressor) ข้อมูลส่งออกจะถูกสร้างด้วยสมการ

$$x' = \sigma'(W'h + b') \quad (7)$$

x' คือ Output vector

σ' คือ activation function

W' คือ weight matrix

h คือ code

b' คือ bias vector

ค่า W และ b จะถูกแบบจำลองปรับแก้ค่าไปเรื่อยๆ โดยใช้วิธีการคำนวณความผิดพลาดย้อนหลังของแบบจำลอง

เพื่อให้ข้อมูลส่งออกที่ถูกสร้างจากแบบจำลองมีรายละเอียดใกล้เคียงกับข้อมูลรับเข้ามากที่สุด แบบจำลองจะถูกสอนให้ลดค่าความผิดพลาดจากการสร้างใหม่ (Reconstruction Error หรือ Loss) ซึ่งเป็นความแตกต่างระหว่างข้อมูลรับเข้ากับข้อมูลส่งออกให้เหลือน้อยที่สุด ด้วยสมการ

$$L(x, x') = \|x - x'\|^2 = \|x - \sigma'(W'(\sigma(Wx + b)) + b')\|^2 \quad (8)$$

x' คือ Output vector จากชั้น decoder

x คือ ค่าเฉลี่ยของข้อมูลรับเข้า

Autoencoder สามารถใช้ในการตรวจจับความแปลกใหม่โดยการสอนแบบจำลองให้เรียนรู้จากข้อมูลที่เป็นปกติ ซึ่งเมื่อแบบจำลองต้องการที่จะสร้างข้อมูลปกติดังกล่าวขึ้นมาใหม่จะได้ค่าความผิดพลาดจากการสร้างใหม่ที่ต่ำ จากนั้นทดสอบแบบจำลองด้วยข้อมูลที่มีความผิดปกติป้อนอยู่ เมื่อแบบจำลองพบกับข้อมูลที่มีรูปแบบแตกต่างออกไปจากที่เคยเรียนรู้มาแบบจำลองจะไร้ประสิทธิภาพในการสร้างข้อมูลนั้นขึ้นมาใหม่เนื่องจาก code ที่ถูกสร้างจากข้อมูลปกติเอามาใช้สร้างข้อมูลผิดปกติไม่ได้ ทำให้ค่าความผิดพลาดจากการสร้างใหม่มีค่าสูง

เพื่อแยกแยะข้อมูลที่เป็นปกติและไม่เป็นปกติออกจากกัน เราจะกำหนดเกณฑ์การตรวจจับความผิดปกติขึ้นมาจากค่าความผิดพลาดจากการสร้างใหม่โดยใช้ฟังก์ชันค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error Loss: Loss MSE หรือ L2 Norm Loss) ซึ่งจะอ่อนไหวต่อค่าที่มีความผิดปกติสูง เนื่องจากนำค่าความผิดพลาดมายกกำลังสองด้วยสมการ

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (9)$$


หลังจากที่สอนแบบจำลองด้วยข้อมูลที่เป็นปกติเราจะกำหนดเกณฑ์โดยการพล็อตกราฟการกระจายตัวของค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยความผิดพลาดกำลังสองที่มีค่ามาก

ที่สุดที่แบบจำลองคาดการณ์ได้จากข้อมูลฝึกสอน ถ้าหากข้อมูลใหม่มีค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยความผิดพลาดกำลังสองสูงกว่าเกณฑ์ที่กำหนดจะหมายความว่าข้อมูลนั้นมีความแตกต่างจากข้อมูลปกติทุกตัวที่แบบจำลองเคยเรียนรู้มา ซึ่งสรุปได้ว่าเป็นความแปลกใหม่

3.3.2 โครงข่ายหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM)

ตามปกติแล้วโครงข่ายประสาทเทียมจะรับข้อมูลรับเข้าแต่ละตัวเป็นอิสระออกจากกัน (independent) โดยไม่ขึ้นกับลำดับของข้อมูล ถึงจะสลับลำดับของข้อมูลรับเข้าอย่างไรข้อมูลส่งออกที่ได้ก็จะออกมาเหมือนเดิมเสมอ ด้วยเหตุนี้โครงข่ายประสาทเทียมจะมีปัญหาเมื่อต้องนำมาวิเคราะห์ข้อมูลที่เป็นลำดับ เช่น ข้อมูลอนุกรมเวลา, การประมวลผลภาษาธรรมชาติ เพื่อแก้ปัญหาดังกล่าวโครงข่ายประสาทเทียมแบบวนซ้ำจึงถูกสร้างขึ้นเพื่อให้แบบจำลองสามารถนำข้อมูลก่อนหน้าที่เกิดขึ้นในอดีตมาใช้ในการทำนายข้อมูลในอนาคตได้ โดยการทำงานแบบวนซ้ำ (loop) เพื่อส่งต่อข้อมูลส่งออกจากสถานะ (state) ก่อนหน้าไปยังสถานะถัดไปแล้วนำไปรวมกับข้อมูลรับเข้าของสถานะถัดไป อย่างไรก็ตามในขณะฝึกสอนแบบจำลอง gradient จะมีขนาดเล็กลงเรื่อยๆจนเท่ากับ 0 ทำให้ค่า weight ไม่ได้รับการปรับปรุง ส่งผลให้ไม่สามารถฝึกสอนแบบจำลองต่อได้ ปัญหาดังกล่าวชื่อ Vanishing Gradient [35]


LSTM คือขั้นตอนวิธีที่ถูกพัฒนาต่อมาจากโครงข่ายประสาทเทียมแบบวนซ้ำเพื่อแก้ปัญหา vanishing gradient [36] ความแตกต่างระหว่าง LSTM กับโครงข่ายประสาทเทียมแบบวนซ้ำ คือใน memory cell ของ LSTM จะประกอบด้วยโครงสร้างพิเศษที่เรียกว่า gate ซึ่งมีหน้าที่ควบคุมการไหลของข้อมูลที่จะเข้ามาในแต่ละ node ไม่ให้เกินกว่าที่หน่วยความทรงจำจะรองรับได้โดยการเพิ่มหรือลบข้อมูลออกจาก cell state ด้วยเหตุนี้ LSTM จึงช่วยให้แบบจำลองสามารถจดจำลำดับของข้อมูลที่มีความยาวมากขึ้นได้ [37] LSTM เหมาะสมกับข้อมูลที่เป็นลำดับ เช่น ข้อความ เสียง และ วิดีโอ [38] โครงสร้างของ LSTM แสดงในรูปที่ 5



รูปที่ 5 โครงสร้างของ LSTM

3.3.3 ตัวเข้ารหัสอัตโนมัติประเภทหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory Autoencoder)


โครงสร้างของ LSTM Autoencoder สามารถสรุปได้ว่าเป็นแบบจำลอง autoencoder ที่ใส่ชั้นของ LSTM เข้าไปในชั้น encoder และ decoder เพื่อช่วยในการเก็บข้อมูลที่เป็นลำดับ โดย LSTM ในชั้น encoder จะวนซ้ำเพื่อเก็บข้อมูลรับเข้าที่ละชุดจนกว่าจะครบ จากนั้นจึงบีบอัดให้กลายเป็น code ในชั้นซ่อนตัว สุดท้าย LSTM ในชั้น decoder ก็วนซ้ำเพื่อคืนค่าข้อมูลส่งออกออกจาก code ที่ละชุดจนกว่าจะครบ รูปภาพแสดงโครงสร้างอย่างละเอียดของ LSTM Autoencoder แสดงในรูปที่ 6



รูปที่ 6 โครงสร้างอย่างละเอียดของ LSTM Autoencoder

ลักษณะของข้อมูลรับเข้าและข้อมูลส่งออกสำหรับแบบจำลอง LSTM Autoencoder จะเป็นเวกเตอร์ 3 มิติ ซึ่งแสดงในรูปที่ 7 ประกอบด้วย

1. Batch size คือจำนวนตัวอย่างของข้อมูลที่เราจะใส่เข้าไปในแบบจำลองใน 1 ครั้ง เช่นถ้ามีข้อมูล 1000 จุด แล้วกำหนด batch size = 100 และกำหนด epoch (จำนวนรอบของการฝึกสอน) = 20 แบบจำลองจะต้องทำงานทั้งหมด $1000/100=10$ ครั้งต่อหนึ่งรอบ แล้วทำงานรวมทั้งหมด 20 รอบ
2. จำนวนของคุณลักษณะ (Features) สำหรับงานวิจัยนี้คือจำนวนของเซ็นเซอร์ที่เลือกใช้ร่วมกับตัวแปรจากสมการอุณหพลศาสตร์
3. Time steps คือจุดของข้อมูลในอดีตที่แบบจำลองต้องเรียนรู้เพื่อคาดการณ์ผลลัพธ์ เช่นถ้า timesteps = 10 แบบจำลองจะใช้ข้อมูลในอดีต 10 จุดที่แล้วร่วมกับจุดข้อมูลในปัจจุบันเพื่อคาดการณ์ผลลัพธ์



รูปที่ 7 ลักษณะของข้อมูลรับเข้าและข้อมูลส่งออกสำหรับแบบจำลอง LSTM Autoencoder [33]

สำหรับวิทยานิพนธ์นี้ในการประมวล (compile) แบบจำลองจะกำหนดให้ :

- Activation function ที่เลือกใช้ในชั้น LSTM ใน encoder และ decoder คือ ReLU
- Optimizer (ใช้เพื่อ update ค่า weight ในชั้นซ่อนตัวเพื่อลดค่าความผิดพลาดจากการสร้างใหม่) ที่เลือกใช้คือ ADAM ซึ่งเหมาะสำหรับการทำ stochastic gradient descent ในแบบจำลองการเรียนรู้เชิงลึก [39]
- ฟังก์ชันค่าความผิดพลาดจากการสร้างใหม่ (Loss function) ที่เลือกใช้คือฟังก์ชันค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยความผิดพลาดกำลังสอง

ในการปรับปรุ้ค่าไฮเปอร์พารามิเตอร์ของแบบจำลอง (Hyperparameter Tuning) จะเริ่มปรับพารามิเตอร์ตามลำดับความสำคัญ ดังนี้

1. จำนวนของชั้น layer
2. จำนวนของ neuron ในหนึ่ง layer
3. ร้อยละของ neuron ที่ถูกสุมปิดในชั้นดรอปเอาท์

ชั้นดรอปเอาท์คือวิธี regularization ที่เอาไว้ลด overfitting โดยการสุมปิด neuron เพื่อสร้างแบบจำลองร่วมตัดสินใจ (ensemble model) ในโครงข่ายประสาทเทียม [40]

4. batch size และ epoch

3.4 การเก็บข้อมูล และการเตรียมข้อมูล

เนื้อหาในบทนี้จะเกี่ยวข้องกับขั้นตอนการเตรียมข้อมูลก่อนที่จะนำไปใช้สอนหรือทดสอบในแบบจำลอง LSTM Autoencoder

3.4.1 การเก็บรวบรวมข้อมูล (Data Collection)

เก็บข้อมูลการทำงานในอดีตของคอมเพรสเซอร์แบบลูกสูบประเภท Multistage Vertical Reciprocating Compressor รหัสรุ่น J4D300-2M ผลิตโดย JSW LTD. ที่มีกำลังไฟฟ้าสูงสุด 1,250.00 KW, มีความดันขาเข้าและขาออกที่ 0.5-0.8/22 kg/cm²G และมีอัตราการไหลของก๊าซอยู่ที่ 5,300 m³/hr รวบรวมข้อมูลของเครื่องจักรในขณะที่ทำงานเป็นปกติในช่วงวันที่ 22 พฤศจิกายน 2019 เวลา 16.40 น. จนถึงวันที่ 31 กรกฎาคม 2021 เวลา 06.00 น. โดยจะเก็บข้อมูลทุก 5 นาที จากเซ็นเซอร์ทั้งหมด 16 ตัว

3.4.2 การเตรียมข้อมูล (Data Preprocessing)

ก่อนที่จะนำข้อมูลที่รวบรวมได้มาวิเคราะห์ด้วยการเรียนรู้ของเครื่องหรือการเรียนรู้เชิงลึก จำเป็นที่จะต้องตรวจสอบความถูกต้องของข้อมูลที่รวบรวมมาเสียก่อน ถ้าหากข้อมูลนั้นมีความผิดปกติ ไม่สมบูรณ์หรือมีลักษณะที่ไม่เหมาะสมต่อการนำไปใช้งานจะทำให้ผลการวิเคราะห์ข้อมูลชุดนั้นผิดพลาด หรืออาจมีความเที่ยงตรงต่ำกว่าความเป็นจริง เพื่อแก้ปัญหาดังกล่าวจึงใช้วิธีการการเตรียมข้อมูลซึ่งเป็นขั้นตอนหนึ่งในการทำเหมืองข้อมูล (data mining) ที่จะเปลี่ยนข้อมูลดิบที่รวบรวมมาให้อยู่ในรูปแบบที่แบบจำลองของเราสามารถทำความเข้าใจและนำไปใช้งานได้

1. การทำความสะอาดข้อมูล (Data Cleaning)

- กรณีข้อมูลสูญหายหรือไม่สมบูรณ์จะลบข้อมูลในแถว (row) นั้นทิ้งทั้งหมด หรือเติมค่าที่หายไปด้วยตนเอง โดยจะใส่ค่าที่มีความเป็นไปได้มากที่สุดแทน ในงานวิจัยนี้คือข้อมูลช่วงเริ่มต้นที่เครื่องจักรยังติดตั้งไม่สมบูรณ์

- กรณีข้อมูลรบกวน คือข้อมูลที่มีความผิดพลาดแบบสุ่มหรือคาดเคลื่อนจากการวัด ซึ่งเป็นข้อมูลไม่พึงประสงค์ เช่นเป็นค่าผิดปกติที่เกิดจากความผิดพลาดในขณะที่ยู่สังเกตการณ์กำลังป้อนข้อมูล, เซ็นเซอร์ทำงานผิดปกติ หรือปัญหาการส่งข้อมูล (data transmission) ผิดพลาด เราจำเป็นต้องกำจัดข้อมูลเหล่านี้ทิ้ง ไม่เช่นนั้นขั้นตอนฝึกสอนแบบจำลองจะเข้าใจผิดว่าข้อมูลรบกวนที่ผิดปกติเหล่านี้คือข้อมูลที่มีรูปแบบเป็นปกติ วิธีการกำจัดข้อมูลรบกวนในงานวิจัยนี้จะตรวจสอบจากค่าพิสัยระหว่างควอร์ไทล์ (Inter Quartile Range: IQR) ซึ่งเป็นวิธีการทางสถิติ [41]

ค่าพิสัยระหว่างควอร์ไทล์ คือข้อมูลจำนวน 50% ที่อยู่ตรงกลางของชุดข้อมูล วัดจากผลต่างของควอร์ไทล์ที่ 1 และ 3 ดังสมการ

$$IQR = Q3 - Q1 \quad (10)$$

เมื่อกำหนดให้ควอร์ไทล์ที่ 1 หรือ $Q1$ คือข้อมูลที่อยู่ในช่วง 25% แรกของจำนวนข้อมูลทั้งหมด และควอร์ไทล์ที่ 3 หรือ $Q3$ คือข้อมูลที่อยู่ได้ 75% ของจำนวนข้อมูลทั้งหมด

หลังจากนั้นจะคำนวณค่าขีดจำกัดบน (Upper bound) และขีดจำกัดล่าง (Lower bound) ของข้อมูล ด้วยสมการ

$$Lower\ bound = Q1 - IQR * 1.5 \quad (11)$$

และ

$$Upper\ bound = Q3 + IQR * 1.5 \quad (12)$$

ตามลำดับ ข้อมูลที่มีค่าน้อยกว่า lower bound หรือมากกว่า upper bound คือข้อมูลรบกวน

2. การแปลงข้อมูล (Data Transformation)

คือการเปลี่ยนแปลงรูปแบบหรือโครงสร้างของข้อมูลให้มีลักษณะที่เหมาะสมต่อการนำไปใช้ในแบบจำลอง วิธีที่ใช้ทั่วไปคือ Normalization (การแปลงค่าของข้อมูลให้อยู่ในช่วง [0.0 ถึง 1.0]) ในงานวิจัยนี้เราจะใช้เทคนิค Standardization ในการแปลงข้อมูล

Standardization (Z-score) คือการปรับมาตรฐานส่วนของข้อมูลใหม่ให้มีค่าเฉลี่ยอยู่ที่ 0 และมีค่าเบี่ยงเบนมาตรฐานเท่ากับ 1

เนื่องจากข้อมูลดิบที่ถูกรวบรวมมามีหน่วยของการวัด (measurement unit) ของข้อมูลที่แตกต่างกัน เช่น Ampair, degree Celsius, kg/cm²G รวมถึงมีมาตราส่วนของข้อมูลที่แตกต่างกันมาก ส่งผลให้แต่ละพารามิเตอร์ของข้อมูลอาจมีอิทธิพล (dominate) เหนือกันและกัน [42] ยกตัวอย่างเช่น ความดันขาออกมีค่าอยู่ที่ 0-5 kg/cm²G ในขณะที่อุณหภูมิขาออกมีค่า 20-140 องศาเซลเซียส ในกรณีนี้จะถือว่าพารามิเตอร์ของอุณหภูมิซึ่งมีช่วงของข้อมูลกว้างจะมีอิทธิพลเหนือความดัน ซึ่งการที่ข้อมูลในแต่ละพารามิเตอร์ มีช่วงข้อมูลที่แตกต่างกันมากจะส่งผลต่อการวิเคราะห์ด้วยแบบจำลอง ดังนั้นเราจึงต้อง standardize ข้อมูลก่อนที่จะนำไปใช้งานด้วยสมการ

$$Z = \frac{x - \mu}{\sigma} \quad (13)$$

เมื่อกำหนดให้ :

Z คือค่าของข้อมูลที่ถูก standardize แล้ว

x คือข้อมูล ณ จุดที่สนใจ


μ คือค่าเฉลี่ยของข้อมูลทั้งหมด

σ คือค่าเบี่ยงเบนมาตรฐานของข้อมูล

3.5 การประเมินงานวิจัย

หลังจากที่เตรียมข้อมูลเสร็จแล้วจะแบ่งข้อมูล (Data Segmentation) ออกเป็น 2 ส่วนคือ ข้อมูลที่ใช้สอนแบบจำลอง และข้อมูลที่ใช้ทดสอบแบบจำลองเมื่อได้แบบจำลองที่ดีที่สุดมาแล้ว โดยจะแบ่งเป็นข้อมูลฝึกสอน 80% และข้อมูลทดสอบ 20% จากข้อมูลทั้งหมด ในวิทยานิพนธ์นี้จะแบ่งตามวันที่และเวลาแทนที่จะเป็นการสุ่มข้อมูลแบบสับเปลี่ยน (shuffle split) เพราะต้องการให้แบบจำลองเก็บข้อมูลเป็นลำดับอนุกรมเวลา

จากนั้นจะแบ่งข้อมูลที่ใช้ตรวจสอบความถูกต้องของแบบจำลอง (Validation data) ออกมาจากข้อมูลสอน ในสัดส่วนข้อมูลฝึกสอน 80% ต่อข้อมูลตรวจสอบ 20% เพื่อแก้ปัญหา overfitting โดยจะเปรียบเทียบกับผลลัพธ์ที่ได้จากข้อมูลฝึกสอนแล้วปรับแก้ค่าไฮเปอร์พารามิเตอร์ของแบบจำลองเพื่อให้มีประสิทธิภาพดีขึ้น หรือให้ได้ค่าความผิดพลาดจากการสร้างใหม่ที่น้อยที่สุด โดยจะวนซ้ำตามจำนวน epoch ที่ถูกกำหนดไว้ เพื่อให้ได้แบบจำลองที่มีประสิทธิภาพดีที่สุดก่อนที่จะนำไปใช้กับข้อมูลทดสอบ ขั้นตอนและสัดส่วนการแบ่งข้อมูลฝึกสอน ข้อมูลทดสอบ และข้อมูลตรวจสอบแสดงในรูปที่ 8 เมื่อกำหนดให้ข้อมูลฝึกสอนจริงคือ 80% ของข้อมูลฝึกสอน 80% คิดเป็น $0.8 \times 80\% = 64\%$ และข้อมูลตรวจสอบ 20% ของข้อมูลฝึกสอน 80% คิดเป็น $0.2 \times 80\% = 16\%$



รูปที่ 8 สัดส่วนการแบ่งข้อมูล Train, Test และ Validate

เพื่อประเมินความถูกต้องของแบบจำลอง (performance evaluation) จะต้องสร้างป้ายกำกับให้กับข้อมูลที่ใช้ทดสอบ โดยข้อมูลที่ใช้จะเป็นข้อมูลที่แบ่งมาจากข้อมูลดิบซึ่งเป็นช่วงที่เครื่องจักรทำงานตามปกติ แล้วจำลองความผิดปกติขึ้นมาในข้อมูลชุดนั้น จากนั้นจะกำหนดป้ายกำกับให้กับข้อมูลช่วงที่เป็นปกติเป็น “0” และข้อมูลที่จำลองความผิดปกติเข้าไปจะกำหนดให้เป็น “1” อย่างไรก็ตามป้ายกำกับดังกล่าวจะถูกใช้เป็นผลเฉลยของชุดข้อมูล (ground truth) เพื่อประเมินความถูกต้องเพียงอย่างเดียวจึงไม่ถูกนำไปรวมกับชุดข้อมูลทดสอบที่ถูกใช้กับแบบจำลอง

3.5.1 การจำลองรูปแบบความเสียหายสังเคราะห์ของเครื่องจักร (Synthetic Fault Simulation)

ข้อมูลความเสียหายของเครื่องจักรที่อยู่ในข้อมูลทดสอบจะถูกจำลองขึ้นมาจากรูปแบบความเสียหายของเครื่องจักรที่ถูกกล่าวถึงในหัวข้อ 3.1.3 ทั้งหมด 5 รูปแบบ ได้แก่

- กระบอกสูบที่ stage 1 ด้านขาเข้าเกิดรอยร้าว (C1S)
- กระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว (C1D)
- กระบอกสูบที่ stage 2 ด้านขาเข้าเกิดรอยร้าว (C2S)
- กระบอกสูบที่ stage 2 ด้านขาออกเกิดรอยร้าว (C2D)
- ตัวแลกเปลี่ยนความร้อนระหว่าง stage เสียหาย (ICI)

แบบจำลองสัญญาณรบกวนแบบทางลาด (noisy ramp model) คือชุดข้อมูลสัญญาณสังเคราะห์ที่ถูกสร้างขึ้นจากชุดข้อมูลจริงเพื่อเลียนแบบสัญญาณรบกวน โดยสัญญาณรบกวนจะค่อยๆ เพิ่มขึ้นเหมือนทางลาด [43]

เกณฑ์ที่จะต้องคำนึงถึงเมื่อต้องจำลองความผิดปกติให้กับข้อมูลอนุกรมเวลา คือ [44]

- เศษส่วนของความเสียหาย = 50 %


เพื่อให้ชุดข้อมูลทดสอบมีประเภทของข้อมูลที่สมดุลจึงเริ่มสร้างความเสียหายขึ้นมาที่ครึ่งหลังของข้อมูลทดสอบ หรือก็คือการจำลองความเสียหายขึ้นที่ 50th percentile ของข้อมูล เพื่อให้ประเภทของป้ายกำกับมี 0 และ 1 อย่างละครึ่ง

- ขนาดของความเสียหาย = เริ่มตั้งแต่ 0 จนถึง 3 SD

ความเสียหายที่ถูกจำลองขึ้นจะเป็นความเสียหายแบบสะสม (cumulative fault) เนื่องจากรูปแบบความเสียหายที่ต้องการตรวจจับเป็นความเสียหายสะสม เช่น กระบอกสูบจะรั่วอย่างถาวรและจะรั่วมากขึ้นเรื่อยๆ

- ทิศทางของความเสียหาย = เป็นได้ทั้งมากขึ้นและน้อยลง ขึ้นอยู่กับชนิดของเซ็นเซอร์
- กลุ่มก้อนของความเสียหาย = 1

สรุปคือจะเริ่มจำลองความเสียหายจากจุดที่เครื่องจักรเริ่มต้นเสียหายไปจนถึงจุดที่เสียหายอย่างรุนแรง (critical fault) ความผิดปกติจะถูกเพิ่มลงไปข้อมูลดิบที่เป็นปกติจากน้อยไปมาก เริ่มจาก 0 SD ที่ 50th percentile เพิ่มขึ้นจนถึง 3 SD ที่ข้อมูลตำแหน่งสุดท้าย ดังที่แสดงในรูปที่ 9



รูปที่ 9 การจำลองความผิดปกติให้กับข้อมูล

ค่า 3SD ที่ใช้มาจากกฎเชิงประจักษ์ (Empirical rule) หรือกฎสามซิกมา (Three-sigma rule) หรือกฎ 68-95-99.7 (68-95-99.7 rule) ซึ่งเป็นกฎทางสถิติที่แสดงว่าในข้อมูลที่มีการแจกแจงตามปกติ (normal distribution) ค่าของข้อมูลเกือบทั้งหมดจะอยู่ภายใต้สามเท่าของส่วนเบี่ยงเบนมาตรฐานของค่าเฉลี่ยของข้อมูลชุดนั้น ชุดตัวเลข 68-95-99.7 มีที่มาจาก : [45]

- โดยทั่วไปแล้วกฎเชิงประจักษ์จะคาดการณ์ว่า 68% ของข้อมูลทั้งหมดจะอยู่ภายใต้ค่าเบี่ยงเบนมาตรฐานแรก ($\mu \pm 1\sigma$)
- 95% ของข้อมูลทั้งหมดจะอยู่ภายใต้ค่าเบี่ยงเบนมาตรฐานสองค่าแรก ($\mu \pm 2\sigma$)
- 99.7% ของข้อมูลทั้งหมดจะอยู่ภายใต้ค่าเบี่ยงเบนมาตรฐานสามค่าแรก ($\mu \pm 3\sigma$)

ดังนั้นจึงสามารถสรุปได้ว่าข้อมูล 99.7% นี้คือข้อมูลที่เป็นปกติและข้อมูล 0.3% ที่เหลือคือข้อมูลที่มีรูปแบบเบี่ยงเบนออกไปจากความเป็นปกติ หรือก็คือค่าผิดปกติ ดังนั้นจึงจำลองให้ข้อมูลที่มีความผิดปกติของเครื่องจักรอยู่คือค่าของข้อมูลที่จุดนั้น (ซึ่งเป็นข้อมูลปกติ) บวกกับ 3SD ของข้อมูลชุดนั้น จากนั้นกำหนดให้ข้อมูลดังกล่าวมีป้ายกำกับเป็น “1”

3.5.2 การประเมินผลลัพธ์ของแบบจำลอง

เมื่อกำหนดป้ายกำกับ 0 ให้กับข้อมูลปกติและ 1 ให้กับข้อมูลที่ผิดปกติในข้อมูลทดสอบแล้ว จะสามารถใช้ Confusion Matrix เพื่อประเมินแบบจำลองเหมือนการเรียนรู้แบบมีผู้สอนได้

Confusion Matrix คือตารางเมทริกซ์ที่ใช้ประเมินความสามารถของแบบจำลองในการแก้ปัญหาประเภทการจำแนก โดยการแสดงความสัมพันธ์ระหว่างป้ายกำกับของข้อมูลจริงกับป้ายกำกับที่แบบจำลองคาดการณ์เพื่อตรวจสอบความถูกต้องของผลลัพธ์ โดยจะแบ่งออกเป็น

- TP (True Positive) คือข้อมูลความเสียหาย และแบบจำลองทำนายว่าเสียหาย
- TN (True Negative) คือข้อมูลปกติ และแบบจำลองทำนายว่าปกติ
- FP (False Positive) คือข้อมูลปกติ แต่แบบจำลองทำนายว่าเสียหาย
- FN (False Negative) คือข้อมูลความเสียหาย แต่แบบจำลองทำนายว่าปกติ

รูปของ confusion matrix แสดงในรูปที่ 10

Actual Values	Negative [0]	TN	FP
	Positive [1]	FN	TP
		Negative [0]	Positive [1]
		Predicted Values	

จุฬาลงกรณ์มหาวิทยาลัย
รูปที่ 10 Confusion Matrix
CHULALONGKORN UNIVERSITY

เมื่อกำหนดให้ข้อมูลที่มีค่าเป็นจริง (Positive) คือข้อมูลที่สนใจและต้องการให้แบบจำลองตรวจจับ จะกำหนดให้ข้อมูลที่เป็นจริงคือข้อมูลที่ผิดปกติ หลักการวัดเพื่อประเมินแบบจำลองที่ถูกลำบากใช้คือ :

- Precision คือการวัดความแม่นยำของแบบจำลอง โดยพิจารณาแยกทีละ class (ในกรณีนี้คือป้ายกำกับ) แสดงในสมการ

$$Precision = \frac{TP}{TP+FP} \quad (14)$$

- Recall หรือ Sensitivity คือการวัดความถูกต้องของแบบจำลอง โดยพิจารณาเฉพาะข้อมูลที่มีค่าเป็นจริง แสดงในสมการ

$$Recall = \frac{TP}{TP+FN} \quad (15)$$

- Accuracy คือความเที่ยงตรง เป็นการวัดความถูกต้องของแบบจำลองโดยรวม เมื่อพิจารณาทุก class แสดงในสมการ

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

- F1 Score คือค่าเฉลี่ยแบบฮาร์โมนิก (harmonic mean) ของค่า precision และ recall แสดงในสมการ

$$F1\ Score = 2 \cdot \left(\frac{precision \cdot recall}{precision + recall} \right) \quad (17)$$

3.6 การสร้างระดับสัญญาณเตือน (Alarm levels)

ในการนำแบบจำลองไปใช้งานจริงเพื่อบำรุงรักษาเชิงพยากรณ์ในโรงงาน แบบจำลองอาจถูกใช้เพื่อตรวจสอบสภาพของเครื่องจักรแบบเรียลไทม์ (Real-time condition monitoring) ซึ่งจะมีการสร้างสัญญาณเตือนในขณะที่แบบจำลองสามารถตรวจจับความเสียหายที่เกิดขึ้นจากเครื่องจักรได้ สัญญาณเตือน 3 ระดับตามความรุนแรงของความผิดปกติที่ถูกตรวจจับได้ประกอบด้วย :

1. ตรวจจับความผิดปกติตามตำแหน่งได้ (point outlier) คือข้อมูลจุดเดี่ยวๆที่มีความแตกต่างจากจุดข้างเคียงอย่างชัดเจน เป็นความผิดปกติที่ตรวจจับได้ง่ายที่สุด สามารถจำแนกได้เป็นข้อมูลที่มีค่ามากกว่าหรือน้อยกว่าข้อมูลอื่นๆอย่างมีนัยสำคัญ ส่วนใหญ่ความผิดปกติประเภทนี้จะเกิดขึ้นนานๆครั้ง และมักจะเกิดในช่วงระยะเวลาสั้นๆ [46]
2. ตรวจจับรูปแบบความผิดปกติได้ (collective outlier) คือกลุ่มของจุดข้อมูลที่มีพฤติกรรมหรือรูปแบบที่เบี่ยงเบนออกไปจากรูปแบบของข้อมูลตามปกติ ยกตัวอย่างเช่น ข้อมูลจุดหนึ่งอาจมีค่าใกล้เคียงกับค่าที่เป็นปกติ แต่เมื่อวิเคราะห์พฤติกรรมของกลุ่มของจุดข้อมูลที่อยู่ใกล้เคียงแล้วกลับพบว่าข้อมูลกลุ่มนั้นมีรูปแบบที่เบี่ยงเบนจากจุดข้อมูลโดยรวม [46] ในการบำรุงรักษาเครื่องจักรความผิดปกติประเภทนี้มักเป็นความผิดปกติสะสมเนื่องจากเครื่องจักรทำงานผิดปกติ

3. ตรวจจับความผิดปกติอย่างรุนแรงได้ เมื่อกำหนดให้ความผิดปกติอย่างรุนแรงถูกคำนวณจากความแตกต่างระหว่างเกณฑ์ตรวจจับความผิดปกติกับค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยความผิดพลาดกำลังสองของจุดข้อมูลนั้นที่ได้จากการคาดการณ์โดยแบบจำลอง โดยนับเฉพาะจุดข้อมูลที่มีผลต่างมากกว่า 3 SD (จากกฎเชิงประจักษ์)

เงื่อนไขการสร้างระดับสัญญาณเตือนแสดงในตารางที่ 2


ตารางที่ 2 เงื่อนไขการสร้างระดับสัญญาณเตือน

Alarm Types	Alarm description	Alarm coding
Point Novelty	ตรวจจับความผิดปกติตามตำแหน่งได้	Anomaly == True
Novelty Pattern	ตรวจจับรูปแบบความผิดปกติได้	Group of continuous fault pattern -> drop duplicate -> combine data
Critical Novelty	ตรวจจับความผิดปกติอย่างรุนแรงได้	$ \text{Loss-Threshold} \geq 3SD * \text{Loss}$

บทที่ 4

การสอบทานแนวคิด LSTM Autoencoder

วิธีการที่นำเสนอในวิทยานิพนธ์นี้ถูกประเมินโดยการนำไปใช้ตรวจจับความแปลกใหม่ในชุดข้อมูลความสั่นสะเทือนที่ drive end และ fan end ของตลับลูกปืนเม็ดกลม (rolling-element bearing) ซึ่งถูกเก็บข้อมูลมาจาก Case Western Reserve University (CWRU) Bearing Data Centre [47] ชุดข้อมูลดังกล่าวถูกใช้เป็นข้อมูลทดสอบมาตรฐานในงานวิจัยที่เกี่ยวข้องกับการตรวจจับความผิดปกติ [48] [49] [50] เนื่องจากมีความแตกต่างระหว่างรูปแบบความปกติและความเสียหายของเครื่องจักรที่ชัดเจน โครงสร้างของแท่นทดสอบตลับลูกปืนเม็ดกลมแสดงในรูปที่ 11 ประกอบด้วยมอเตอร์เหนี่ยวนำไฟฟ้า ทรานสดิวเซอร์แรงบิด ไดนาโมมิเตอร์ และเซ็นเซอร์วัดความเร่ง ถูกติดตั้งที่ drive-end และ fan-end ของตลับลูกปืนเพื่อรวบรวมข้อมูลการสั่นสะเทือน



รูปที่ 11 โครงสร้างของแท่นทดสอบตลับลูกปืนเม็ดกลม

ชุดข้อมูลดังกล่าวประกอบด้วยข้อมูลความสั่นสะเทือนในขณะที่ตลับลูกปืนทำงานเป็นปกติ (normal baseline) และทำงานผิดปกติ (12k drive end bearing fault data) ซึ่งเป็นความเสียหายประเภทจุดเดี่ยวที่เกิดจากตลับลูกปืนเคลื่อนออกจากรางเนื่องจากความสั่นสะเทือนเมื่อตลับลูกปืนถูกใช้รองรับเครื่องกัดเนื้อโลหะ (Electro-discharge machining: EDM) รูปแบบความเสียหายมีจำนวน 4 รูปแบบ ประกอบด้วย

1. เส้นผ่านศูนย์กลางของรางด้านในเคลื่อนจาก baseline 0.007 นิ้ว (Inner race 0.007")
2. เส้นผ่านศูนย์กลางของรางด้านนอกเคลื่อนจาก baseline 0.007 นิ้ว (Outer race 0.007")
3. เส้นผ่านศูนย์กลางของรางด้านในเคลื่อนจาก baseline 0.021 นิ้ว (Inner race 0.021")
4. เส้นผ่านศูนย์กลางของรางด้านนอกเคลื่อนจาก baseline 0.021 นิ้ว (Outer race 0.021")

แบบจำลอง LSTM Autoencoder เรียนรู้จากข้อมูลฝึกสอนในช่วงที่ตลับลูกปืนทำงานเป็นปกติ แล้วประเมินความแม่นยำจากชุดข้อมูลทดสอบจำนวน 4 ชุด ในข้อมูลทดสอบแต่ละชุดจะประกอบด้วยข้อมูลปกติครึ่งหนึ่งและข้อมูลผิดปกติตามรูปแบบความเสียหายทั้ง 4 ชนิดอีกครั้งหนึ่ง

แบบจำลองประกอบด้วยโครงข่ายประสาทเทียมจำนวน 8 ชั้น ประกอบด้วย

- ชั้นข้อมูลรับเข้า 1 ชั้น
- encoder 2 ชั้นคือ ชั้น LSTM ที่มี neuron 16 ตัว มีพารามิเตอร์ซ่อนเร้น 1,216 ตัว และชั้นดรอปเอาต์ที่สุ่มปิด neuron ไป 20%
- code 1 ชั้นที่มี timestep = 5
- decoder 2 ชั้นคือ ชั้น LSTM ที่มี neuron 16 ตัว มีพารามิเตอร์ซ่อนเร้น 2,112 ตัว และชั้นดรอปเอาต์ที่สุ่มปิด neuron ไป 20%
- ชั้น time distribute 1 ชั้นเพื่อคืนค่าข้อมูลใน code กลับเป็นลำดับอนุกรมเวลา
- ชั้นข้อมูลส่งออก 1 ชั้น

Activation function คือ ReLU, L2 regularization = 0.0, Optimizer คือ Adam, Loss function คือ MSE, epochs = 20, batch size = 20 รูปภาพของแบบจำลองแสดงในรูปที่ 12

Model: "sequential_1"

Layer (type)	Output Shape	Param #
lstm_2 (LSTM)	(None, 16)	1216
dropout_2 (Dropout)	(None, 16)	0
repeat_vector_1 (RepeatVector)	(None, 5, 16)	0
lstm_3 (LSTM)	(None, 5, 16)	2112
dropout_3 (Dropout)	(None, 5, 16)	0
time_distributed_1 (TimeDistributed)	(None, 5, 2)	34


รูปที่ 12 แบบจำลอง LSTM Autoencoder ที่ใช้กับข้อมูลจากตลับลูกปืน
ตัวอย่างผลลัพธ์จากการตรวจจับความแปลกใหม่ในชุดข้อมูลดังกล่าวแสดงในรูปที่ 13

	DE	FE	Loss (MSE)	Threshold	Anomaly	Actual
96929	-0.06342	0.054445	0.001785985	0.004	FALSE	0
96930	0.021487	-0.02815	0.001464336	0.004	FALSE	0
96931	0.084072	-0.0526	0.000289513	0.004	FALSE	0
96932	0.086575	-0.02938	0.001239632	0.004	FALSE	0
96933	0.057995	-0.01808	0.000724101	0.004	FALSE	0

รูปที่ 13 ผลลัพธ์จากการศึกษาเบื้องต้น


- DE และ FE คือความสั้นสะท้อนที่ถูก standardize แล้วของ drive end และ fan end ของ ตลับลูกปืน
- Loss (MSE) คือค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูล ทดสอบในแต่ละจุด
- Threshold คือเกณฑ์ตรวจจับความแปลกใหม่ คำนวณจากการพล็อตกราฟการกระจายตัว ของค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูลฝึกสอน
- Anomaly หรือ Predicted คือผลการคาดการณ์จากแบบจำลอง กำหนดให้ “FALSE” คือ ข้อมูลปกติ และ “TRUE” คือข้อมูลความแปลกใหม่
- Actual คือป้ายกำกับที่ถูกใช้เป็นผลเฉลยของชุดข้อมูลทดสอบ “0” คือข้อมูลปกติจาก normal baseline “1” คือข้อมูลผิดปกติจากรูปแบบความเสียหายทั้ง 4

ชุดข้อมูลทดสอบรูปแบบความเสียหายประเภทเส้นผ่านศูนย์กลางของรางด้านในเคลื่อนจาก baseline 0.007 นิ้ว (Inner race 0.007”) หลังจากที่ถูก standardize แล้วแสดงในรูปที่ 14 โดยข้อมูล ปกติในครั้งแรกมีค่าประมาณ 0 SD และข้อมูลความเสียหายในครั้งหลังมีค่าอยู่ในช่วง 0.5-1.5 SD ทั้ง DE และ FE




รูปที่ 14 ชุดข้อมูลทดสอบของรูปแบบความเสียหาย Inner race 0.007”

Loss (MSE) ของชุดข้อมูลทดสอบและเกณฑ์ตรวจจับความแปลกใหม่แสดงในรูปที่ 15 เมื่อจุดข้อมูลใดมีค่า Loss (MSE) เกินเกณฑ์ที่กำหนดจะถูกตรวจจับเป็นความแปลกใหม่



รูปที่ 15 Loss (MSE) ของรูปแบบความเสียหาย Inner race 0.007”

รูปที่ 16 แสดงป้ายกำกับของชุดข้อมูลทดสอบ เมื่อ “0” คือข้อมูลปกติและ “1” คือข้อมูลความเสียหาย เนื่องจาก actual (ground truth) คือป้ายกำกับที่เป็นผลเฉลย ดังนั้นครั้งแรกจึงเป็น “0” และครั้งหลังเป็น “1” ทั้งหมด ส่วน Predicted คือป้ายกำกับของความแปลกใหม่ที่ถูกระบุจากการคำนวณจากแบบจำลอง Confusion Matrix ของทุกรูปแบบความเสียหายแสดงในตารางที่ 3



รูปที่ 16 ผลลัพธ์ของรูปแบบความเสียหาย Inner race 0.007”

ตารางที่ 3 Confusion Matrix จากผลการศึกษาเบื้องต้น

Fault Pattern	Precision	Recall	F1 Score	Accuracy
Inner race (0.007")	99.60 %	84.95 %	91.69 %	92.30 %
Outer race (0.007")	99.60 %	84.74 %	91.57 %	92.20 %
Inner race (0.021")	99.59 %	83.52 %	90.85 %	91.59 %
Outer race (0.021")	99.86 %	60.35 %	75.23 %	80.13 %

- ผลลัพธ์แสดงว่าค่าความผิดพลาดจากการสร้างใหม่ (Loss MSE) มีค่ามากขึ้นเมื่อตลับลูกปืนได้รับความเสียหาย
- รูปแบบความเสียหาย Inner race 0.007", Outer race 0.007" และ Inner race 0.021" มีค่า precision, recall, F1 score และ accuracy ใกล้เคียงกัน
- รูปแบบความเสียหาย Outer race 0.021" มี precision ใกล้เคียงรูปแบบอื่น แต่มีค่า recall, F1 score และ accuracy น้อยกว่ามาก เนื่องจากรูปแบบความเสียหายดังกล่าวมีข้อมูลหลายจุดที่มีค่าใกล้เคียงกับรูปแบบที่เป็นปกติ และเบี่ยงเบนจากความปกติน้อยกว่ารูปแบบความเสียหายอื่นๆ
- เมื่อความแตกต่างระหว่างความปกติและความเสียหายมีค่าน้อยมาก LSTM Autoencoder จึงคาดการณ์ผิดว่าความเสียหายเป็นความปกติ ส่งผลให้ accuracy ของรูปแบบความเสียหาย Outer race 0.021" มีค่าน้อยที่สุด
- เราสามารถสรุปได้ว่าถ้ารูปแบบความเสียหายเป็นแบบสะสม แบบจำลองอาจไม่แม่นยำมากพอที่จะตรวจจับความเสียหายในช่วงเริ่มต้นที่สุดเนื่องจากเบี่ยงเบนจากความปกติน้อยมาก ยิ่งไปกว่านั้นหากข้อมูลปกติในชุดข้อมูลทดสอบเบี่ยงเบนออกไปจากข้อมูลปกติในชุดข้อมูลฝึกสอนมากๆ แบบจำลองอาจคาดการณ์ผิดว่าความปกติดังกล่าวเป็นความแปลกใหม่ ในกรณีนี้เราจะต้องตัดสินใจว่าความแปลกใหม่ดังกล่าวเป็นความเสียหายจริงหรือเป็นรูปแบบความปกติใหม่ที่ไม่เคยพบในชุดข้อมูลฝึกสอนมาก่อน

ผลลัพธ์จากการตรวจจับด้วยแบบจำลอง LSTM Autoencoder ถูกใช้เปรียบเทียบกับผลลัพธ์จากงานวิจัยของ Kamat และคณะ [50] ที่ตรวจจับความเสียหายโดยใช้ชุดข้อมูลเดียวกันโดยใช้แบบจำลอง Random Forest Classification (RF), โครงข่ายประสาทเทียม (ANN) และ Autoencoder ผลลัพธ์จากงานวิจัยของ Kamat แสดงในรูปที่ 17

Table 4 Comparison of the models based on accuracy

	Accuracy		
	RF (%)	ANN (%)	Autoencoders (%)
Inner race (0.007")	85	80	91
Outer race (0.007")	84	81	96
Inner race (0.021")	84	81	97
Outer race (0.021")	75	73	99

รูปที่ 17 ผลลัพธ์จากงานวิจัยของ Kamat และคณะ [50]

ตารางเปรียบเทียบผลลัพธ์ของผลการศึกษาเบื้องต้นกับงานวิจัยของ Kamat แสดงในตารางที่ 4 เมื่อเปรียบเทียบความเที่ยงตรง (accuracy) จาก LSTM Autoencoder กับ RF, ANN, Autoencoder จากงานวิจัยของ Kamat พบว่า LSTM Autoencoder มีความเที่ยงตรงสูงกว่า RF และ ANN อย่างไรก็ตาม Autoencoder มีความเที่ยงตรงสูงกว่า LSTM Autoencoder

ตารางที่ 4 เปรียบเทียบ Accuracy ของ LSTM Autoencoder กับงานวิจัยของ Kamat [50]

Fault Pattern	LSTM Autoencoder	RF	ANN	Autoencoder
Inner race (0.007")	92.30 %	85 %	80 %	91 %
Outer race (0.007")	92.20 %	84 %	81 %	96 %
Inner race (0.021")	91.59 %	84 %	81 %	97 %
Outer race (0.021")	80.13 %	75 %	73 %	99 %

จากผลการศึกษาเบื้องต้นพบว่าวิธีการตรวจจับความแปลกใหม่โดย LSTM Autoencoder ที่นำเสนอในวิทยานิพนธ์นี้มีประสิทธิภาพสูง และเหมาะสมต่อการนำไปใช้ตรวจจับความเสียหายจากเครื่องคอมเพรสเซอร์แบบลูกสูบที่มีความซับซ้อนสูง และมีรูปแบบความเสียหายแบบสะสม ผลการศึกษาเบื้องต้นที่ใช้ LSTM Autoencoder ตรวจจับความแปลกใหม่ในตลับลูกปืนจาก Central West Reserve University ถูกตีพิมพ์ใน “Novelty Detection of a Rolling Bearing using Long Short-Term Memory Autoencoder” [51]



บทที่ 5

ผลลัพธ์และการอภิปรายผล

เนื้อหาในบทนี้จะกล่าวถึงผลลัพธ์จากการเตรียมข้อมูลและการจำลองความผิดปกติ ก่อนที่จะอภิปรายค่าไฮเปอร์พารามิเตอร์ที่ถูกกำหนดเพื่อสร้างแบบจำลอง จากนั้นจึงสรุปผลการวิเคราะห์ข้อมูล และอภิปรายผลลัพธ์ของการตรวจจับความแปลกใหม่ในเครื่องคอมพิวเตอร์แบบลูกสูบด้วย LSTM Autoencoder สุดท้ายจะอภิปรายผลจากสัญญาณแจ้งเตือนความเสียหาย

5.1. การเตรียมข้อมูลและการจำลองความผิดปกติ


ข้อมูลดิบที่ถูกเก็บรวบรวมมาจากเซ็นเซอร์มีทั้งหมด 192,683 จุดข้อมูล ก่อนที่จะทำความสะอาดข้อมูลโดยการลบช่วงเวลาแรกสุดในขณะที่ยังติดตั้งไม่สมบูรณ์ จากนั้นจึงลบข้อมูลรบกวนทิ้งโดยการพล็อตกราฟแสดงช่วงของค่าในแต่ละเซ็นเซอร์แล้วลบข้อมูลตามเงื่อนไขที่เหมาะสมกับแต่ละเซ็นเซอร์ ข้อมูลช่วงที่ถูกลบคือความดันขาเข้าและขาออกที่ stage 1, ความดันขาออกที่ stage 2, ความต่างของความดันที่ stage 2 และ ICDT เฉพาะช่วงที่มีค่าเป็นลบ นอกจากนี้ยังพบว่าตัวแปรที่ถูกเพิ่มมาจากการคำนวณคืออัตรากำลังบีบอัดที่ stage 2 มีข้อมูลบางช่วงมีค่าถึง 700,000,000 เนื่องจากความดันขาเข้าที่เป็นตัวส่วนของเศษส่วนมีค่าเข้าใกล้ 0 จึงต้องลบช่วงดังกล่าวทิ้ง หลังจากทำความสะอาดข้อมูลและ standardize แล้วจะเหลือทั้งหมด 165,646 จุดข้อมูล กราฟสหสัมพันธ์ของตัวแปรทั้งหมดแสดงในรูปที่ 18 ตัวแปรที่มีความสัมพันธ์กันมากจะมีค่าเข้าใกล้ 1 แต่ถ้าไม่สัมพันธ์กันเลยจะมีค่าเข้าใกล้ 0

5.2. ค่าไฮเปอร์พารามิเตอร์ที่ใช้สร้างแบบจำลอง LSTM Autoencoder

แบบจำลอง LSTM Autoencoder ถูกสร้างขึ้นด้วยค่าไฮเปอร์พารามิเตอร์ดังต่อไปนี้

- Random seed = 2
- Time steps = 2 เทียบเท่ากับรับข้อมูลนำเข้าครั้งละ 10 วินาที พบว่ายิ่ง time step มาก ลำดับของข้อมูลนำเข้าจะยาวขึ้น ทำให้แบบจำลองเห็นความสัมพันธ์ต่อเนื่องมากขึ้น อย่างไรก็ตามแบบจำลองจะยิ่ง overfit มากขึ้นตามไปด้วย จึงควรใช้ time step น้อยๆ
- Activation function = ReLU
- L2 regularization = 0.00001 พบว่าช่วงที่พอใช้ได้คือ 0.0001, 0.00001 และ 0.000001 ยิ่งค่าน้อยจะยิ่งลด overfit ค่าที่เหมาะสมที่สุดคือ 0.00001

- Optimizer = Adam
- Loss function = MSE
- Epochs = 50 หลังจาก epoch 30 ค่า loss จะลดลงช้ามาก
- Batch sizes = 256 ยิ่งค่าน้อยจะยิ่งลด overfit แต่จะใช้เวลาฝึกสอนนานขึ้น ค่า batch size ที่เป็นเลขยกกำลังของสองจะทำให้ประมวลผลเร็วขึ้น
- เกณฑ์ในการตรวจจับความแปลกใหม่ (Novelty threshold) = 0.0025



รูปที่ 18 กราฟความสัมพันธ์ของตัวแปรทั้งหมด

แบบจำลองประกอบด้วยโครงข่ายประสาทเทียมจำนวน 7 ชั้น ประกอบด้วย


- ชั้นข้อมูลรับเข้า 1 ชั้น
- encoder 1 ชั้นคือ ชั้น LSTM ที่มี neuron 256 ตัว มีพารามิเตอร์ซ่อนเร้น 282,624 ตัว
- code 1 ชั้นที่มี timestep = 2
- decoder 2 ชั้นคือ ชั้น LSTM ที่มี neuron 256 ตัว มีพารามิเตอร์ซ่อนเร้น 525,312 ตัว และชั้นดรอปเอาต์ที่สุ่มปิด neuron ไป 10 %
- ชั้น time distribute 1 ชั้นเพื่อคืนค่าข้อมูลใน code กลับเป็นลำดับอนุกรมเวลา
- ชั้นข้อมูลส่งออก 1 ชั้น

จากการปรับแต่งค่าไฮเปอร์พารามิเตอร์พบว่าจำนวนชั้นของโครงข่ายประสาทเทียมยิ่งเยอะยิ่งเกิด overfit จึงไม่ควรเกิน 7 ชั้น, จำนวน neuron ยิ่งเยอะยิ่งเกิด overfit แต่ถ้าน้อยเกินไปแบบจำลองจะไม่เข้าใจข้อมูลฝึกสอน พบว่าค่าที่เหมาะสมที่สุดคือ 256 เมื่อกำหนด batch size เป็น 256, ชั้นดรอปเอาต์ถ้ามากกว่า 20 % แบบจำลองจะไม่เข้าใจข้อมูลฝึกสอน พบว่าค่าที่เหมาะสมที่สุดคือ 10 % นอกจากนี้ถ้าใส่ชั้นดรอปเอาต์ใน encoder แบบจำลองจะ overfit จึงใส่ชั้นดรอปเอาต์แค่ในชั้น decoder เพียงอย่างเดียว แบบจำลองใช้เวลาฝึกสอน epoch ละเอียดประมาณ 40 วินาที รูปภาพของแบบจำลอง LSTM Autoencoder แสดงในรูปที่ 19 และรูปภาพของกราฟค่า loss (mse) ในแต่ละ epoch แสดงในรูปที่ 20 พบว่าแบบจำลอง overfit แคลใน epoch 18 เท่านั้น

Model: "sequential_1"


Layer (type)	Output Shape	Param #
=====:		
lstm_2 (LSTM)	(None, 256)	282624
repeat_vector_1 (RepeatVect or)	(None, 2, 256)	0
lstm_3 (LSTM)	(None, 2, 256)	525312
dropout_1 (Dropout)	(None, 2, 256)	0
time_distributed_1 (TimeDis tributed)	(None, 2, 19)	4883
=====:		
Total params: 812,819		
Trainable params: 812,819		
Non-trainable params: 0		

รูปที่ 19 แบบจำลอง LSTM Autoencoder ที่ใช้กับคอมพิวเตอร์วิทัศน์



รูปที่ 20 กราฟแสดงค่า loss (mse) ในแต่ละ epoch

หลังจากนั้นจึงคำนวณค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูลทดสอบในแต่ละจุด ซึ่งเป็นผลต่างระหว่างข้อมูลฝึกสอนกับข้อมูลที่แบบจำลองสร้างขึ้นมาใหม่ พบว่ามีบางจุดข้อมูลที่เป็นค่าผิดปกติ จึงลบช่วงที่ผิดปกติเหล่านั้นด้วยค่าพิสัยระหว่างควอร์ไทล์ (IQR) จากนั้นจึงพล็อตกราฟการกระจายตัวของข้อมูลของค่า loss (mse) เพื่อกำหนดเกณฑ์ในการตรวจจับความแปลกใหม่ โดยกำหนดให้เกณฑ์ดังกล่าวคือ 0.0025 เพราะเป็นค่าที่อยู่เหนือกว่าข้อมูลที่เป็นปกติเกือบทั้งหมดในชุดข้อมูลฝึกสอน รูปภาพของกราฟการกระจายตัวของค่า loss (mse) แสดงในรูปที่ 21




รูปที่ 21 กราฟการกระจายตัวของค่า loss (mse)

หลังจากที่ฝึกสอนให้แบบจำลองเข้าใจข้อมูลเครื่องจักรช่วงที่เป็นปกติและกำหนดเกณฑ์ในการตรวจจับความแปลกใหม่ได้แล้ว แบบจำลอง LSTM Autoencoder จะถูกนำไปทดสอบกับชุดข้อมูลทดสอบทั้ง 5 ชุด

5.3. รูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาเข้าเกิดรอยร้าว (C1S)

รูปภาพแสดงผลลัพธ์ของรูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาเข้าเกิดรอยร้าว แสดงในรูปที่ 22 โดยจะสนใจเฉพาะ label 1 เพราะเป็นความแปลกใหม่ที่ต้องการตรวจจับ

- Precision = 80.79 %
- Recall = 100.00 %
- F1-score = 89.38 %
- Accuracy = 88.11 %




	precision	recall	f1-score	support
0	1.0000	0.7623	0.8651	33091
1	0.8079	1.0000	0.8938	33093
accuracy			0.8811	66184
macro avg	0.9040	0.8811	0.8794	66184
weighted avg	0.9040	0.8811	0.8794	66184

รูปที่ 22 ผลลัพธ์ของรูปแบบความเสียหาย C1S


รูปภาพแสดง Confusion Matrix แสดงในรูปที่ 23

- True Positive = 33,092
- True Negative = 25,225
- False Positive = 7,866
- False Negative = 1




รูปที่ 23 Confusion Matrix ของรูปแบบความเสียหาย C1S

รูปภาพแสดงค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูลทดสอบแสดงในรูปที่ 24 จุดที่มีค่า loss (mse) เกิน 0.0025 จะถูกกำหนดเป็นความแปลกใหม่



รูปที่ 24 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C1S

รูปภาพเปรียบเทียบ label ที่ได้จากการคาดการณ์ของแบบจำลองกับ label ชุดที่เป็นผลเฉลยแสดงในรูปที่ 25 โดยผลเฉลยจะแสดงในช่วง 1 ถึง 2 เมื่อ 1 คือข้อมูลปกติ และ 2 คือความแปลกใหม่ ช่วงครึ่งแรกของข้อมูลทดสอบจะเป็นข้อมูลปกติ ช่วงครึ่งหลังจะเป็นความแปลกใหม่ ผลจากการคาดการณ์จะแสดงในช่วง 0 ถึง 1 เมื่อ 0 คือข้อมูลปกติ และ 1 คือความแปลกใหม่ ช่วงครึ่งแรกของข้อมูลทดสอบส่วนใหญ่จะเป็นข้อมูลปกติ แต่จะมีช่วงที่ถูกคาดการณ์เป็นความแปลกใหม่บ้าง ช่วงครึ่งหลังจะเป็นความแปลกใหม่เกือบทั้งหมด



รูปที่ 25 เปรียบเทียบ label ของรูปแบบ C1S

5.4. รูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว (C1D)

รูปภาพแสดงผลลัพธ์ของรูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าวแสดงในรูปที่ 26


- Precision = 79.47 %
- Recall = 100.00 %
- F1-score = 88.56 %
- Accuracy = 87.08 %

	precision	recall	f1-score	support
0	1.0000	0.7417	0.8517	33091
1	0.7947	1.0000	0.8856	33093
accuracy			0.8708	66184
macro avg	0.8973	0.8708	0.8686	66184
weighted avg	0.8973	0.8708	0.8686	66184

รูปที่ 26 ผลลัพธ์ของรูปแบบความเสียหาย C1D


รูปภาพแสดง Confusion Matrix แสดงในรูปที่ 27

- True Positive = 33,092
- True Negative = 24,543
- False Positive = 8,548
- False Negative = 1




รูปที่ 27 Confusion Matrix ของรูปแบบความเสียหาย C1D

รูปภาพแสดงค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูลทดสอบแสดงในรูปที่ 28



รูปที่ 28 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C1D

รูปภาพเปรียบเทียบ label ที่ได้จากการคาดการณ์ของแบบจำลองกับ label ชุดที่เป็นผล
เฉลยแสดงในรูปที่ 29



รูปที่ 29 เปรียบเทียบ label ของรูปแบบ C1D

5.5. รูปแบบความเสียหายกระบอกสูบที่ stage 2 ด้านขาเข้าเกิดรอยร้าว (C2S)

รูปภาพแสดงผลลัพธ์ของรูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว
แสดงในรูปที่ 30

- Precision = 84.06 %


- Recall = 100.00 %
- F1-score = 91.34 %
- Accuracy = 90.51 %

	precision	recall	f1-score	support
0	1.0000	0.8103	0.8952	33091
1	0.8406	1.0000	0.9134	33093
accuracy			0.9051	66184
macro avg	0.9203	0.9051	0.9043	66184
weighted avg	0.9203	0.9051	0.9043	66184

รูปที่ 30 ผลลัพธ์ของรูปแบบความเสียหาย C2S


รูปภาพแสดง Confusion Matrix แสดงในรูปที่ 31

- True Positive = 33,092
- True Negative = 26,814
- False Positive = 6,277
- False Negative = 1




รูปที่ 31 Confusion Matrix ของรูปแบบความเสียหาย C2S

รูปภาพแสดงค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูลทดสอบแสดงในรูปที่ 32



รูปที่ 32 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C2S

รูปภาพเปรียบเทียบ label ที่ได้จากการคาดการณ์ของแบบจำลองกับ label ชุดที่เป็นผลเฉลยแสดงในรูปที่ 33



รูปที่ 33 เปรียบเทียบ label ของรูปแบบ C2S

5.6. รูปแบบความเสียหายกระบอกสูบที่ stage 2 ด้านขาออกเกิดรอยร้าว (C2D)

รูปภาพแสดงผลลัพธ์ของรูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว แสดงในรูปที่ 34


- Precision = 82.82 %
- Recall = 100.00 %
- F1-score = 90.60 %
- Accuracy = 89.62 %

	precision	recall	f1-score	support
0	1.0000	0.7925	0.8842	33091
1	0.8282	1.0000	0.9060	33093
accuracy			0.8962	66184
macro avg	0.9141	0.8962	0.8951	66184
weighted avg	0.9141	0.8962	0.8951	66184

รูปที่ 34 ผลลัพธ์ของรูปแบบความเสียหาย C2D


รูปภาพแสดง Confusion Matrix แสดงในรูปที่ 35

- True Positive = 33,092
- True Negative = 26,225
- False Positive = 6,866
- False Negative = 1




รูปที่ 35 Confusion Matrix ของรูปแบบความเสียหาย C2D

รูปภาพแสดงค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูลทดสอบแสดงในรูปที่ 36



รูปที่ 36 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ C2D

รูปภาพเปรียบเทียบ label ที่ได้จากการคาดการณ์ของแบบจำลองกับ label ชุดที่เป็นผลเฉลยแสดงในรูปที่ 37



รูปที่ 37 เปรียบเทียบ label ของรูปแบบ C2D

5.7. รูปแบบความเสียหายตัวแลกเปลี่ยนความร้อนระหว่าง stage มีปัญหา (ICI)

รูปภาพแสดงผลลัพธ์ของรูปแบบความเสียหายกระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว แสดงในรูปที่ 38

- Precision = 81.51 %
- Recall = 100.00 %
- F1-score = 89.81 %
- Accuracy = 88.66 %


	precision	recall	f1-score	support
0	1.0000	0.7732	0.8721	33091
1	0.8151	1.0000	0.8981	33093
accuracy			0.8866	66184
macro avg	0.9075	0.8866	0.8851	66184
weighted avg	0.9075	0.8866	0.8851	66184

รูปที่ 38 ผลลัพธ์ของรูปแบบความเสียหาย IC

รูปภาพแสดง Confusion Matrix แสดงในรูปที่ 39


- True Positive = 33,092
- True Negative = 25,586

- False Positive = 7,505
- False Negative = 1




รูปที่ 39 Confusion Matrix ของรูปแบบความเสียหาย ICI

รูปภาพแสดงค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยผลต่างกำลังสองของข้อมูลทดสอบแสดงในรูปที่ 40



รูปที่ 40 Loss(MSE) และเกณฑ์แบ่งของรูปแบบ ICI

รูปภาพเปรียบเทียบ label ที่ได้จากการคาดการณ์ของแบบจำลองกับ label ชุดที่เป็นผล
เฉลยแสดงในรูปที่ 41



รูปที่ 41 เปรียบเทียบ label ของรูปแบบ ICI

5.8. ผลการวิเคราะห์ข้อมูล

จากการตรวจจับความแปลกใหม่โดยใช้ LSTM Autoencoder ในรูปแบบความเสียหายทั้ง 5 รูปแบบสามารถสรุปได้ในตารางที่ 5 เมื่อพิจารณาจาก recall จะพบว่าทุกรูปแบบความเสียหายเป็น 100.00% ทั้งหมด หมายความว่าแบบจำลองสามารถตรวจจับความเสียหายที่อยู่ในชุดข้อมูลทดสอบได้ทั้งหมด เมื่อพิจารณาจาก precision จะพบว่าทั้ง 5 รูปแบบจะมีความแม่นยำใกล้เคียงกันคือ ประมาณ 80% โดยรูปแบบ C1D จะแม่นยำน้อยที่สุดคือ 79.47% และรูปแบบ C2S จะแม่นยำมากที่สุดคือ 84.06% เมื่อพิจารณาจาก F1 Score ซึ่งเป็นค่าเฉลี่ยฮาร์โมนิกของค่า precision และ recall จะพบว่าทั้ง 5 รูปแบบจะมีค่าใกล้เคียงกันคือประมาณ 90% โดยรูปแบบ C1D จะแม่นยำน้อยที่สุดคือ 88.56% และรูปแบบ C2S จะแม่นยำมากที่สุดคือ 91.34% ซึ่งสอดคล้องกับ precision ของทั้งสองรูปแบบ เมื่อพิจารณาจาก accuracy ซึ่งเป็นความถูกต้องของแบบจำลองเมื่อพิจารณารวมทุก class จะพบว่าทั้ง 5 รูปแบบจะมีความเที่ยงตรงใกล้เคียงกันคือประมาณ 90% โดยรูปแบบ C1D จะเที่ยงตรงน้อยที่สุดคือ 87.08% และรูปแบบ C2S จะเที่ยงตรงมากที่สุดคือ 90.51%

ตารางที่ 5 สรุปผลลัพธ์จากการตรวจจับความแปลกใหม่

Fault Pattern	Precision	Recall	F1 Score	Accuracy
C1S	80.79 %	100.00 %	89.38 %	88.11%
C1D	79.47 %	100.00 %	88.56 %	87.08 %
C2S	84.06 %	100.00 %	91.34 %	90.51 %
C2D	82.82 %	100.00 %	90.60 %	89.62 %
ICI	81.51 %	100.00 %	89.81 %	88.66 %

สุดท้ายนี้เมื่อพิจารณาจากเกณฑ์การประเมินแบบจำลองทั้ง 4 แบบข้างต้น สามารถสรุปได้ว่าเมื่อพบความเสียหายในชุดข้อมูลทดสอบ ค่า loss (mse) จะเพิ่มขึ้นจนเกินเกณฑ์ความแปลกใหม่ที่กำหนด โดยแบบจำลองสามารถตรวจจับความเสียหายได้ทั้งหมด อย่างไรก็ตามมีข้อมูลปกติประมาณ 20% ที่แบบจำลองตรวจจับเป็นความแปลกใหม่ ซึ่งอาจเกิดจากการที่ข้อมูลปกติดังกล่าวมีความแตกต่างหรือเบี่ยงเบนจากข้อมูลปกติในชุดข้อมูลฝึกสอนมาก แบบจำลองจึงเข้าใจผิดว่าความปกติดังกล่าวเป็นความแปลกใหม่ ในกรณีนี้เราจะต้องตัดสินใจว่าความแปลกใหม่ที่ถูกระบุว่าเป็นความเสียหายจริงหรือเป็นรูปแบบความปกติใหม่ที่ไม่เคยพบในชุดข้อมูลฝึกสอนมาก่อน นอกจากนี้การที่รูปแบบความเสียหาย C1D มี precision, F1 score, accuracy น้อยที่สุดอาจเป็นเพราะรูปแบบความเสียหายดังกล่าวมีความใกล้เคียงกับข้อมูลปกติมากกว่ารูปแบบอื่น เมื่อแบบจำลองถูกใช้เพื่อคาดการณ์ลำดับอนุกรมเวลาของชุดข้อมูลดังกล่าว ลำดับของข้อมูลปกติอาจใกล้เคียงกับข้อมูลความเสียหายมากทำให้แบบจำลองคาดการณ์ผิดไป ในทางตรงกันข้ามการที่รูปแบบความเสียหาย C2S มี precision, F1 score, accuracy มากที่สุดอาจเป็นเพราะรูปแบบความเสียหายดังกล่าวมีความแตกต่างจากข้อมูลปกติอย่างชัดเจนทำให้แบบจำลองสามารถแยกแยะระหว่างข้อมูลช่วงที่เป็นปกติและช่วงที่เกิดความเสียหายได้อย่างแม่นยำ

5.9. สัญญาณแจ้งเตือนความเสียหาย

หลังจากที่ตรวจจับความแปลกใหม่ได้แล้ว สัญญาณแจ้งเตือนความเสียหายจะจำแนกความแปลกใหม่ที่เกิดขึ้นออกเป็น 3 ประเภท จำนวนของความเสียหายที่เกิดขึ้นจากทั้ง 5 รูปแบบแสดงในตารางที่ 6 ในสัญญาณแจ้งเตือนความผิดปกติตามตำแหน่งพบว่ารูปแบบความเสียหาย C1D ถูกตรวจจับได้มากที่สุด ซึ่งสอดคล้องกับ confusion matrix ของรูปแบบดังกล่าวเพราะแบบจำลอง

ตรวจจับข้อมูลปกติเป็นความแปลกใหม่ รูปแบบที่ตรวจจับได้น้อยที่สุดคือ C2S ในสัญญาณแจ้งเตือนรูปแบบความผิดปกติพบว่ารูปแบบความเสียหาย C1S ถูกตรวจจับได้มากที่สุด อาจเป็นเพราะความเสียหายดังกล่าวมีช่วงของความเสียหายที่ใกล้เคียงกันมากพอที่จะมองรวมกันเป็นรูปแบบได้ยาวกว่ารูปแบบอื่นๆ รูปแบบความเสียหาย ICI ถูกตรวจจับได้น้อยที่สุด ในสัญญาณแจ้งเตือนความผิดปกติอย่างรุนแรงพบว่ารูปแบบความเสียหาย C2S ถูกตรวจจับได้มากที่สุด ซึ่งสอดคล้องกับการที่รูปแบบความเสียหายดังกล่าวมีความแตกต่างจากข้อมูลปกติอย่างชัดเจน รูปแบบความเสียหายที่ตรวจจับได้น้อยที่สุดคือ C2D

ตารางที่ 6 สัญญาณแจ้งเตือนความเสียหาย

Alarm Levels	Point Novelty	Novelty Pattern	Critical Novelty
C1S	40,959	2,520	316
C1D	41,641	2,392	55
C2S	39,370	2,225	331
C2D	39,959	1,989	53
ICI	40,598	1,929	165

บทที่ 6

สรุปผลการวิจัย

การตรวจจับความแปลกใหม่ด้วย LSTM Autoencoder ถูกใช้เพื่อตรวจจับความเสียหาย เริ่มต้นจากข้อมูลของเครื่องคอมพิวเตอร์แบบลูกสูบของบริษัท ระยะเวลาและซ่อมบำรุง จำกัด ในธุรกิจเคมิคอลส์ เอสซีจี วิธีการที่นำเสนอสามารถแก้ปัญหาหลักในการบำรุงรักษาเชิงพยากรณ์คือการขาดข้อมูลความเสียหายของเครื่องจักรสำหรับใช้ฝึกสอนแบบจำลอง, กฎเกณฑ์ที่ใช้ในการกำหนดความผิดปกติไม่เหมาะสมกับรูปแบบความเสียหายที่ซับซ้อน และการขาดความรู้เฉพาะทางในการแยกแยะระหว่างรูปแบบการทำงานของเครื่องจักรที่เป็นปกติและรูปแบบความเสียหาย แผนงานที่นำเสนอthisจะเป็นขั้นตอนเบื้องต้นในการบำรุงรักษาเชิงคาดการณ์ในเครื่องจักร ข้อมูลจากเซ็นเซอร์ของเครื่องจักรในขณะที่ทำงานเป็นปกติถูกทำความสะอาดข้อมูลและแปลงข้อมูลเพื่อให้มีรูปแบบที่เหมาะสมต่อการนำไปใช้ จากนั้นจึงถูกรวมเข้ากับตัวแปรทางกายภาพเพิ่มเติมจากสมการอุณหพลศาสตร์ของคอมพิวเตอร์ ได้แก่อุณหภูมิขาออกและอัตรากำลังบีบอัดในคอมพิวเตอร์เพื่อช่วยให้แบบจำลองเรียนรู้ความสัมพันธ์ระหว่างตัวแปรได้ดียิ่งขึ้น ข้อมูลถูกแบ่งออกเป็นชุดข้อมูลฝึกสอน, ชุดข้อมูลตรวจสอบ และชุดข้อมูลทดสอบ ชุดข้อมูลฝึกสอนซึ่งประกอบด้วยข้อมูลช่วงที่เครื่องจักรทำงานเป็นปกติเพียงอย่างเดียวถูกใช้เพื่อฝึกสอนแบบจำลอง LSTM Autoencoder ซึ่งเป็นตัวเข้ารหัสอัตโนมัติที่ใส่ชั้นของหน่วยความจำระยะสั้นแบบยาวเข้าไปในชั้น encoder เพื่อช่วยในการเรียนรู้ความสัมพันธ์เชิงเวลาที่มีความซับซ้อนและไม่เป็นเชิงเส้น ชั้นดรอปเอาต์ถูกใช้เพื่อช่วยลด overfit ของแบบจำลองด้วยการสร้างแบบจำลองร่วมตัดสินใจ ชุดข้อมูลตรวจสอบถูกใช้เพื่อประเมินประสิทธิภาพของแบบจำลอง จากนั้นใช้ค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยความผิดพลาดกำลังสองซึ่งอ่อนไหวต่อค่าผิดพลาดสูงในการกำหนดเกณฑ์ตรวจจับความแปลกใหม่โดยการพล็อตกราฟการกระจายตัวของข้อมูล ชุดข้อมูลทดสอบประกอบด้วยข้อมูลที่เป็นปกติและข้อมูลความเสียหายที่ถูกจำลองขึ้นทั้งหมด 5 รูปแบบ ได้แก่กระบอกสูบที่ stage 1 ด้านขาเข้าเกิดรอยร้าว, กระบอกสูบที่ stage 1 ด้านขาออกเกิดรอยร้าว, กระบอกสูบที่ stage 2 ด้านขาเข้าเกิดรอยร้าว, กระบอกสูบที่ stage 2 ด้านขาออกเกิดรอยร้าว และตัวแลกเปลี่ยนความร้อนระหว่าง stage มีปัญหา จากนั้นคาดการณ์ความเสียหายในชุดข้อมูลทดสอบโดยการตรวจจับความแปลกใหม่ กำหนดให้เกณฑ์ที่ใช้ในการประเมินแบบจำลองคือค่า precision, recall, F1 score และ accuracy

ระเบียบวิธีการวิจัยที่นำเสนอในวิทยานิพนธ์นี้ได้รับการประเมินประสิทธิภาพโดยใช้ข้อมูลการสั่นสะเทือนของตลับลูกปืนซึ่งเป็นชุดข้อมูลที่ถูกใช้เป็นเกณฑ์มาตรฐานในงานวิจัยโดย Case Western Reserve University ผลลัพธ์การตรวจจับความเสียหายด้วย LSTM Autoencoder ถูกเปรียบเทียบกับผลลัพธ์ของ Random Forest, Artificial Neural Network และ Autoencoder จากงานวิจัยอื่น เบื้องต้นพบว่า การตรวจจับความแปลกใหม่ด้วย LSTM Autoencoder มีประสิทธิภาพสูง โดยมี recall สูงสุด 84%, precision สูงสุด 99%, F1 score สูงสุด 91% และ accuracy สูงสุด 90%

ผลการวิจัยการตรวจจับความแปลกใหม่ในเครื่องคอมเพรสเซอร์แบบลูกสูบด้วย LSTM Autoencoder แสดงให้เห็นว่าเมื่อพบความเสียหายในชุดข้อมูลทดสอบแบบจำลองจะล้มเหลวในการสร้างข้อมูลความเสียหายขึ้นมาใหม่ส่งผลให้ค่าความผิดพลาดจากการสร้างใหม่ประเภทค่าเฉลี่ยความผิดพลาดกำลังสองมีค่าสูงกว่าเกณฑ์ในการจำแนกความแปลกใหม่ที่ถูกกำหนดไว้ เมื่อพิจารณาจากผลลัพธ์พบว่าแบบจำลองสามารถตรวจจับความเสียหายในชุดข้อมูลทดสอบได้ทั้งหมด รวมถึงตรวจจับความปกติบางช่วงเป็นความเสียหายเนื่องจากข้อมูลปกติดังกล่าวมีความแตกต่างจากข้อมูลปกติในชุดข้อมูลฝึกสอนมาก แบบจำลองสามารถตรวจจับความเสียหายโดยมี recall 100%, precision สูงสุด 84%, F1 score สูงสุด 91% และ accuracy สูงสุด 90% จากผลการตรวจจับนี้สามารถสร้างสัญญาณแจ้งเตือนความเสียหาย 3 ระดับเพื่อจำแนกประเภทของความเสียหายที่ตรวจจับได้ รูปแบบของความเสียหายรุนแรงที่ถูกตรวจจับได้มากที่สุดนั้นสอดคล้องกับการที่รูปแบบความเสียหายดังกล่าวมีความแตกต่างจากข้อมูลปกติอย่างชัดเจน

แบบจำลอง LSTM Autoencoder ที่ถูกนำเสนอในวิทยานิพนธ์นี้สามารถตรวจจับความแปลกใหม่ซึ่งเป็นสัญญาณความเสียหายเริ่มต้นในเครื่องคอมเพรสเซอร์แบบลูกสูบได้อย่างมีประสิทธิภาพ เพื่อเพิ่มความปลอดภัยในโรงงาน, เพิ่มระยะเวลาใช้งานเครื่องจักร และลดค่าใช้จ่ายในการซ่อมบำรุง สำหรับการวิจัยในขั้นต่อไปแบบจำลองจะถูกสร้างจากประเภทของ autoencoder ที่มีความซับซ้อนมากยิ่งขึ้น เช่น variational autoencoder นอกจากนี้แบบจำลองจะถูกใช้เพื่อเรียนรู้และตรวจจับความเสียหายจากเครื่องจักรชนิดอื่น ๆ ที่มีรูปแบบแตกต่างกัน

บรรณานุกรม

1. Zhou, K., T. Liu, and L. Zhou. *Industry 4.0: Towards future industrial opportunities and challenges*. in *2015 12th International conference on fuzzy systems and knowledge discovery (FSKD)*. 2015. IEEE.
2. Hermann, M., T. Pentek, and B. Otto. *Design principles for industrie 4.0 scenarios*. in *2016 49th Hawaii international conference on system sciences (HICSS)*. 2016. IEEE.
3. Mobley, R.K., *An introduction to predictive maintenance*. 2002: Elsevier.
4. Ran, Y., et al., *A survey of predictive maintenance: Systems, purposes and approaches*. arXiv preprint arXiv:1912.07383, 2019.
5. Naskos, A., et al. *Detecting anomalous behavior towards predictive maintenance*. in *International Conference on Advanced Information Systems Engineering*. 2019. Springer.
6. Aggarwal, C.C., *An introduction to outlier analysis*, in *Outlier analysis*. 2017, Springer. p. 1-34.
7. Kamat, P. and R. Sugandhi. *Anomaly detection for predictive maintenance in industry 4.0-A survey*. in *E3S Web of Conferences*. 2020. EDP Sciences.
8. Hsieh, R.-J., J. Chou, and C.-H. Ho. *Unsupervised online anomaly detection on multivariate sensing time series data for smart manufacturing*. in *2019 IEEE 12th Conference on Service-Oriented Computing and Applications (SOCA)*. 2019. IEEE.
9. Pimentel, M.A., et al., *A review of novelty detection*. *Signal Processing*, 2014. **99**: p. 215-249.
10. Kramer, M.A., *Nonlinear principal component analysis using autoassociative neural networks*. *AIChE journal*, 1991. **37**(2): p. 233-243.
11. Hochreiter, S. and J. Schmidhuber, *Long Short-Term Memory*. *Neural Computation*, 1997. **9**(8): p. 1735-1780.
12. Pei, J.F., S.X. Qi, and W.Y. He. *The Development of Fault Diagnosis System of Reciprocating Compressor Based on LabVIEW*. in *Advanced Materials Research*. 2010. Trans Tech Publ.

13. Ma, J., Z.-N. Jiang, and J.-J. Gao, *Feature extraction method based on chaotic fractal theory and its application in fault diagnosis of gas valves*. Zhendong yu Chongji(Journal of Vibration and Shock), 2012. **31**(19): p. 26-30.
14. Amruthnath, N. and T. Gupta. *A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance*. in *2018 5th International Conference on Industrial Engineering and Applications (ICIEA)*. 2018. IEEE.
15. Park, P., et al., *Fault detection and diagnosis using combined autoencoder and long short-term memory network*. Sensors, 2019. **19**(21): p. 4612.
16. Chen, X., *Tennessee Eastman simulation dataset*. 2019, IEEE Dataport.
17. Li, Z., et al., *A deep learning approach for anomaly detection based on SAE and LSTM in mechanical equipment*. International Journal of Advanced Manufacturing Technology, 2019. **103**.
18. Ahmad, S., et al. *Autoencoder-based condition monitoring and anomaly detection method for rotating machines*. in *2020 IEEE International Conference on Big Data (Big Data)*. 2020. IEEE.
19. Bampoula, X., et al., *A Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders*. Sensors, 2021. **21**(3): p. 972.
20. Mallak, A. and M. Fathi, *Sensor and Component Fault Detection and Diagnosis for Hydraulic Machinery Integrating LSTM Autoencoder Detector and Diagnostic Classifiers*. Sensors, 2021. **21**(2): p. 433.
21. Lv, Q., et al., *Applications of Machine Learning to Reciprocating Compressor Fault Diagnosis: A Review*. Processes, 2021. **9**(6): p. 909.
22. Charoenchitt, C. and P. Tangamchit. *Anomaly Detection of a Reciprocating Compressor using Autoencoders*. in *2021 Second International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP)*. 2021. IEEE.
23. Buono, F.D., et al. *Data-driven predictive maintenance in evolving environments: A comparison between machine learning and deep learning for novelty detection*. in *Proceedings of the International Conference on*

Sustainable Design and Manufacturing. 2021. Springer.

24. Bloch, H.P. and J.J. Hoefner, *Reciprocating compressors:: operation and maintenance*. 1996: Elsevier.
25. Corken, i. *Vertical Reciprocating Compressor*. 2022; Available from: https://www.corken.com/reciprocating_compressor_ind_vertical.
26. Stewart, M. and K. Arnold, *Surface production operations*. Pump Compress. Syst. Mech, 2008.
27. ToolBox, E. *Gases - Specific Heats and Individual Gas Constants*. 2003 [cited 2022 31 January]; Available from: https://www.engineeringtoolbox.com/specific-heat-capacity-gases-d_159.html.
28. Susto, G.A., et al., *Machine learning for predictive maintenance: A multiple classifier approach*. IEEE transactions on industrial informatics, 2014. **11**(3): p. 812-820.
29. Hinton, G.E. and R.R. Salakhutdinov, *Reducing the dimensionality of data with neural networks*. science, 2006. **313**(5786): p. 504-507.
30. Géron, A., *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. 2019: " O'Reilly Media, Inc."
31. Zhai, J., et al. *Autoencoder and its various variants*. in *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2018. IEEE.
32. Bank, D., N. Koenigstein, and R. Giryes, *Autoencoders*. arXiv preprint arXiv:2003.05991, 2020.
33. Dallapiccola, D., *Predictive maintenance of centrifugal pumps: a Neural Network approach*. 2020, E.T.S. de Ingenieros Informáticos (UPM).
34. Chollet, F., *Deep learning with Python*. 2021: Simon and Schuster.
35. Basodi, S., et al., *Gradient amplification: An efficient way to train deep neural networks*. Big Data Mining and Analytics, 2020. **3**(3): p. 196-207.
36. Hochreiter, S., *Untersuchungen zu dynamischen neuronalen Netzen*. Diploma, Technische Universität München, 1991. **91**(1).
37. Li, Z., et al., *A deep learning approach for anomaly detection based on SAE and LSTM in mechanical equipment*. The International Journal of Advanced

- Manufacturing Technology, 2019. **103**(1): p. 499-510.
38. Yu, Y., et al., *A review of recurrent neural networks: LSTM cells and network architectures*. Neural computation, 2019. **31**(7): p. 1235-1270.
 39. Kingma, D.P. and J. Ba, *Adam: A method for stochastic optimization*. arXiv preprint arXiv:1412.6980, 2014.
 40. Labach, A., H. Salehinejad, and S. Valaee, *Survey of dropout methods for deep neural networks*. arXiv preprint arXiv:1904.13310, 2019.
 41. Dekking, F.M., et al., *A Modern Introduction to Probability and Statistics: Understanding why and how*. Vol. 488. 2005: Springer.
 42. Jaadi, Z. *When and Why to Standardize Your Data?* 2019 February 1, 2022 [cited 2022 June 6]; Available from: <https://builtin.com/data-science/when-and-why-standardize-your-data>.
 43. Repetzki, S., *Uncertainties of Ramp Identification in 100 Noisy Data Points*. 2022.
 44. Sarkar, T., *Create Synthetic Time-series with Anomaly Signatures in Python*, in *Kdnuggets*. 2021, Kdnuggets.
 45. Wackerly, D., W. Mendenhall, and R.L. Scheaffer, *Mathematical statistics with applications*. 2014: Cengage Learning.
 46. Singh, K. and S. Upadhyaya, *Outlier detection: applications and techniques*. International Journal of Computer Science Issues (IJCSI), 2012. **9**(1): p. 307.
 47. Loparo, K., *Case western reserve university bearing data center*. Bearings Vibration Data Sets, Case Western Reserve University, 2012: p. 22-28.
 48. Neupane, D. and J. Seok, *Bearing fault detection and diagnosis using case western reserve university dataset with deep learning approaches: A review*. IEEE Access, 2020. **8**: p. 93155-93178.
 49. Shi, H., et al., *Rolling bearing initial fault detection using long short-term memory recurrent network*. IEEE Access, 2019. **7**: p. 171559-171569.
 50. Kamat, P., et al., *Bearing Fault Detection Using Comparative Analysis of Random Forest, ANN, and Autoencoder Methods*, in *Communication and Intelligent Systems*. 2021, Springer. p. 157-171.
 51. Sunithi Asavalertpalakorn, P.S., Tutpol Ardsomang, *Novelty Detection of a*

Rolling Bearing using Long Short-Term Memory Autoencoder in 37th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC). 2022: Phuket, Thailand.





จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	สุนิธิ อัสวเลิศพลากร
วัน เดือน ปี เกิด	27 กุมภาพันธ์ 2541
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	244/159 ซอย 5/1 หมู่บ้านชวนชื่นพาร์ควิลล์ แขวงศาลาธรรมสพน์ เขตทวี วัฒนา กรุงเทพมหานคร 10170

