

การทำนายความผิดพลาดระยะต้นของเครื่องวิเคราะห์อินทรีย์คาร์บอนโดยการเรียนรู้เชิงลึก

นายธนาภัทร ภัทรวินิจ

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2563
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

2924680901
CD IThesis 6270116021 thesis / rev: 02072564 00:00:45 / seq: 21

6270116021_2924680901

Prediction of Early Failure of TOC Analyzer using Deep Learning

Mr. Thanaphat Patravinij

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2020

Copyright of Chulalongkorn University



2924680901

CU ThesIs 6270116021 thesis / recv: 02072564 00:00:45 / seq: 21

หัวข้อวิทยานิพนธ์

การทำนายความผิดพลาดระยะต้นของเครื่องวิเคราะห์
อินทรีย์คาร์บอน โดยการเรียนรู้เชิงลึก

โดย

นายชนาภัทร ภัทรวินิจ

สาขาวิชา

วิทยาศาสตร์คอมพิวเตอร์

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

ศาสตราจารย์ ดร.ประภาส จงสถิตย์วัฒนา

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้รับวิทยานิพนธ์ฉบับนี้เป็นส่วน
หนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์

(ผู้ช่วยศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.สุกรี สินธุภิญโญ)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(ศาสตราจารย์ ดร.ประภาส จงสถิตย์วัฒนา)

..... กรรมการภายนอกมหาวิทยาลัย

(รองศาสตราจารย์ ดร.วรเศรษฐ์ สุวรรณิก)

ชนาภัทร ภัทรวินิจ : การทำนายความผิดพลาดระยะต้นของเครื่องวิเคราะห์อินทรีย์คาร์บอน โดยการเรียนรู้เชิงลึก. (Prediction of Early Failure of TOC Analyzer using Deep Learning) อ.ที่ปรึกษาหลัก : ศ. ดร.ประภาส จงสถิตย์วัฒนา

การทำนายระยะเวลาของเครื่องวิเคราะห์อินทรีย์คาร์บอน ก่อนที่จะเสีย มีความสำคัญเนื่องจากเครื่องดังกล่าวมีความสำคัญต่อกระบวนการผลิตโซดาไฟ โดยใช้น้ำเกลือเป็นวัตถุดิบหลักเป็นอย่างมาก ภายในกระบวนการผลิตนั้นจะต้องนำน้ำเกลือมาตรวจสอบที่เครื่องวิเคราะห์อินทรีย์คาร์บอนก่อนเสมอ เพราะอินทรีย์คาร์บอนนั้นสามารถเข้าไปอุดตันในกระบวนการผลิตจนกระทั่ง Membrane มีปัญหา ถ้าหากน้ำเกลือมีค่าอินทรีย์คาร์บอนสูง ทางโรงงานจะทำการกำจัดน้ำเกลือดังกล่าวทั้งหมด ดังนั้นถ้าสามารถคำนวณเวลาซ่อมได้อย่างแม่นยำ ก็จะลดความเสี่ยงในการสูญเสียโอกาสในการผลิตลงได้ ภายในประกอบไปด้วยเซนเซอร์จำนวนมากเพื่อทำการวัดค่าในระหว่างการผลิต ซึ่งค่าที่สามารถวัดได้จากเซนเซอร์ภายในมีมากถึง 26 ค่าด้วยกัน การเก็บข้อมูลของเครื่องจะจัดเก็บโดยหนึ่ง Cycle จะใช้เวลาเก็บทุกๆ 15 นาที เริ่มนับปริมาณ Cycle ใหม่ทุกครั้งที่เครื่องจักรมีการหยุดซ่อมเนื่องจากพังเสียหาย นำปริมาณ Cycle ทั้งหมดของเครื่องในหนึ่งรอบการทำงาน มาคำนวณหา Remaining Useful Lifetime (RUL) ได้ แบ่งเป็น Class 0, 1 และ 2 เพื่อชี้แจงเตือนผู้ใช้งาน นำค่าจากเซนเซอร์ทุกๆ Cycle ไปเรียนรู้ด้วยการเรียนรู้เชิงลึก และทำ Classification โดยผลลัพธ์ที่ได้มีความแม่นยำ 81%

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2563

ลายมือชื่อนิติ
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6270116021 : MAJOR COMPUTER SCIENCE

KEYWORD: Deep learning, Failure prediction, Total organic carbon analyzer

Thanaphat Patraviniij : Prediction of Early Failure of TOC Analyzer using Deep Learning. Advisor: Prof. PRABHAS CHONGSTITVATANA

Prediction of early failure of the total organic carbon analyzer (TOC) is important. The analyzer is used in the production of chlorine from brine. TOC in brine is measured by the analyzer. Too much TOC can cause damage and clog the production machine. The ability to predict the early failure of the analyzer will reduce the loss from production. An analyzer consists of many sensors. There are 26 parameters reading from the analyzer. All parameters are collected every 15 minutes. The cycle will restart once the machine is stopped for maintenance. This is called one cycle. Remaining useful lifetime (RUL) can be calculated from all data from one cycle. It is classified into three classes: Class 0, 1 and 2. This is useful to notify the user. This work proposed using deep learning to learn RUL class from data of the analyzer collected from the real machines in used. The result shows the prediction accuracy of 81%.

Field of Study: Computer Science

Student's Signature

Academic Year: 2020

Advisor's Signature

กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จลุล่วงได้ด้วยความกรุณาจากอาจารย์ประสาท จงสถิตย์วัฒนา อาจารย์ที่ปรึกษางานวิจัยที่ได้ให้คำแนะนำ แนวคิด ตลอดจนแก้ไขข้อบกพร่องต่างๆ มาโดยตลอด งานวิจัยนี้เสร็จสมบูรณ์ ผู้ศึกษาจึงขอกราบขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณคุณพ่อและคุณแม่ที่เป็นที่ปรึกษาและเป็นกำลังใจที่ดีให้กันเสมอมา

ขอขอบคุณเพื่อนๆ พี่ๆ น้องๆ ทุกคนที่บริษัท วินิไทย จำกัด (มหาชน) ที่ช่วยเหลือและให้ความรู้เกี่ยวกับงานวิจัยนี้ รวมไปถึงการเป็นที่ระบายในยามทุกข์ใจ

ขอบคุณคุณณัฐวดี เทียมธรรมวงศ์มากๆ ที่คอยอยู่เคียงข้างกันมาตลอด

และสุดท้ายนี้ขอบคุณเพื่อนๆ พี่ๆ ปริญญาโทสาขาวิทยาศาสตร์คอมพิวเตอร์มากๆ ที่คอยให้คำแนะนำและให้ความรู้ในสาขาวิชานี้ ขอขอบคุณครับ

ธนาภัทร ภัทรวินิจ

สารบัญ

หน้า

.....	ก
บทคัดย่อภาษาไทย	ก
.....	ง
บทคัดย่อภาษาอังกฤษ	ง
กิตติกรรมประกาศ.....	จ
สารบัญ	ฉ
สารบัญตาราง	ญ
สารบัญภาพ	ฎ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตการวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.5 ขั้นตอนการดำเนินงาน.....	3
1.6 ผลงานวิจัยที่ตีพิมพ์.....	3
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	4
2.1 การผลิตโซดาไฟ.....	4
2.1.1 Brine saturation.....	4
2.1.2 Brine filtration.....	4
2.1.3 Brine purification	4
2.1.4 NaCl electrolysis	4

3.1 Failure Prediction in Open-Hole Wireline Logging of Oil and Gas Drilling Operation Using Support Vector Machine.....	27
3.2 Machine Learning for Long Cycle Maintenance Prediction of Wind Turbine	29
3.3 Predicting Remaining Useful Life of Rotating Machinery Based Artificial Neural Network	32
บทที่ 4 แนวคิดและวิธีการวิจัย	35
4.1 ทำการเก็บรวบรวมข้อมูลจากเครื่อง Total Organic Analyzer (TOC).....	35
4.2 File ที่ได้จาก Notepad.....	35
4.3 การ Import file	36
4.4 ข้อมูล Error log.....	37
4.5 Import Data และ Error log.....	38
4.6 ทำการเปลี่ยนข้อมูล Time และ Date.....	38
4.7 จากหัวข้อ 4.6 ทำให้ Data ของเราเปลี่ยนไปเป็นดังรูปด้านล่าง	39
4.8 การหา Remaining Useful Lifetime	39
4.9 การทำ Classification	39
4.10 ทำการ Normalization Input data.....	41
4.1.1 รูปแบบการทำ Predictive Remaining Useful Lifetime	41
บทที่ 5 ผลการทดลอง.....	43
5.1 ผลการวิจัยแบบปกติ	43
5.2 ผลการวิจัยที่ใช้ Input จาก Operation Extraction	44
5.3 ผลการวิจัยที่ใช้ Input จาก Correlation matrix เพื่อทำ Feature Extraction.....	47
6. สรุปผลการวิจัย.....	50
บรรณานุกรม	52
ประวัติผู้เขียน	55



CU IThesis 6270116021 thesis / recv: 02072564 00:00:45 / seq: 21

2924680901

สารบัญตาราง

	หน้า
ตารางที่ 1 รูปแบบของ Confusion matrix แบบ Binary Classification.....	19
ตารางที่ 2 รูปแบบของ Confusion matrix แบบ Multi-Classification.....	19
ตารางที่ 3 การหา True Positive ของ Multi-Classification.....	20
ตารางที่ 4 การหา True Negative ของ Multi-Classification	20
ตารางที่ 5 การหา False Negative ของ Multi-Classification	20
ตารางที่ 6 การหา False Positive ของ Multi-Classification	21
ตารางที่ 7 การจัด Attribute ให้กับข้อมูล	30
ตารางที่ 8 ข้อมูลหลังจากการ Import.....	36
ตารางที่ 9 ข้อมูลหลังจากการ Import Data และ Error log.....	38
ตารางที่ 10 ข้อมูลหลังจากการเปลี่ยนวันและเวลา.....	39
ตารางที่ 11 วิธีการคำนวณ Remaining Useful Lifetime	39
ตารางที่ 12 วิธีการระบุ Classification	41
ตารางที่ 13 ข้อมูลหลังการทำ Normalization	41
ตารางที่ 14 ปริมาณของข้อมูลที่ใช้ในการ Training และ Testing.....	48
ตารางที่ 15 จำนวนของข้อมูลภายใน Confusion matrix แต่ละ Class.....	50

สารบัญภาพ

	หน้า
รูปที่ 1 หลักการทำงานของ Electrolysis.....	4
รูปที่ 2 กระบวนการผลิตโซดาไฟ.....	6
รูปที่ 3 ความสำคัญของเครื่อง TOC analyzer	6
รูปที่ 4 ผลลัพธ์ของค่า Total Inorganic Carbon	7
รูปที่ 5 ผลลัพธ์ของค่า Total Inorganic Carbon และ Total Organic Carbon	8
รูปที่ 6 เปรียบเทียบ Neural network กับการทำงานของสมอง	9
รูปที่ 7 ภาพรวมของ Neural network.....	9
รูปที่ 8 ส่วนประกอบภายใน Layer ของ Neural network.....	10
รูปที่ 9 รูปแบบของ Feed forward neural network	11
รูปที่ 10 Function การทำงานของ Sigmoid.....	12
รูปที่ 11 Function การทำงานของ Tanh.....	12
รูปที่ 12 Function การทำงานของ Softmax.....	13
รูปที่ 13 Function การทำงานของ Sigmoid เทียบกับ ReLu.....	14
รูปที่ 14 เปรียบเทียบ Optimization Algorithms.....	15
รูปที่ 15 เปรียบเทียบระหว่าง Stochastic Gradient descent และ Gradient descent.....	16
รูปที่ 16 เปรียบเทียบ Mini Batch Gradient Descent และ Algorithms ตัวอื่น	16
รูปที่ 17 เปรียบเทียบ Momentum ก่อนและหลัง Update	17
รูปที่ 18 ลักษณะของ Correlation matrix.....	22
รูปที่ 19 ตัวอย่างการใช้งาน Correlation Matrix	23
รูปที่ 20 เปรียบเทียบการทำ Normalization แต่ละวิธี	24
รูปที่ 21 แนวคิด K-Fold Cross Validation	25

รูปที่ 22 ตัวอย่างการใช้งาน 10-Fold Cross Validation.....26

รูปที่ 23 ลักษณะของข้อมูลที่เป็น Input และ Output ให้กับ Model.....27

รูปที่ 24 การแบ่งกลุ่มของข้อมูลตามเทคนิคการสุดเจาะ28

รูปที่ 25 5-Fold Cross validation กับ Training data.....28

รูปที่ 26 เปรียบเทียบ Accuracy เมื่อใช้ Algorithm ที่ต่างกัน.....29

รูปที่ 27 Flow chart ภาพรวม ของงานวิจัย.....30

รูปที่ 28 Flow chart โดยละเอียดของงานวิจัย31

รูปที่ 29 ผลลัพธ์ของงานวิจัย31

รูปที่ 30 ตำแหน่งของ Bearing ในเครื่องจักร.....32

รูปที่ 31 Feature ที่ใช้เป็น Input ทั้งหมด.....33

รูปที่ 32 Flow chart การทำ Predictive model.....33

รูปที่ 33 การเปรียบเทียบระหว่าง Actual และ Prediction.....34

รูปที่ 34 เครื่อง Total Organic Carbon analyzer.....35

รูปที่ 35 ข้อมูลที่ได้จาก Notepad36

รูปที่ 36 ข้อมูลที่ได้จาก Error log37

รูปที่ 37 วิธีการนับ Machine และ Number of Cycle38

รูปที่ 38 แนวคิดการสร้าง Model Neural network ในงานวิจัยนี้.....42

รูปที่ 39 Flow chart สำหรับงานวิจัย43

รูปที่ 40 ผลลัพธ์ของการวิจัยแบบปกติ44

รูปที่ 41 Confusion matrix ของการวิจัยแบบปกติ44

รูปที่ 42 การตัด Operation ที่ไม่เกี่ยวข้องกับการวิจัย45

รูปที่ 43 ผลลัพธ์ของการวิจัยแบบ Input จาก Operation Extraction46

รูปที่ 44 Confusion matrix ของการวิจัยแบบ Input จาก Operation Extraction.....46

รูปที่ 45 Correlation matrix ของแต่ละ Feature47

รูปที่ 46 ผลลัพธ์ของการวิจัยแบบ Input จาก Correlation matrix เพื่อทำ Feature Extraction49

รูปที่ 47 Confusion matrix ของการวิจัยแบบ Input จาก Correlation matrix เพื่อทำ Feature
Extraction.....49

บทที่ 1 บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในโรงงานอุตสาหกรรมปิโตรเคมีประกอบไปด้วยอุปกรณ์วัดค่าต่างๆมากมาย เพื่อให้กระบวนการผลิตสามารถดำเนินการผลิตได้อย่างต่อเนื่อง ปลอดภัย และตรงตามความต้องการของตลาด เมื่ออุปกรณ์วัดค่าเหล่านี้เสียหาย ทางโรงงานจะต้องจัดหาทีมงานเพื่อเข้าไปซ่อมแซมอุปกรณ์ให้เร็วที่สุด เพื่อให้กระบวนการผลิตสามารถผลิตต่อโดยไม่ต้องหยุดการผลิตเป็นเวลานาน เพราะการหยุดผลิตนั้นหมายถึงการเสียโอกาสในการทำกำไรไปอย่างมหาศาล ในทางอุดมคตินั้น โรงงานอุตสาหกรรมคาดหวังให้อุปกรณ์วัดค่าเหล่านี้สามารถทำงานได้ตลอดเวลา แต่ในความเป็นจริงเมื่อใช้งานอุปกรณ์วัดค่าเหล่านี้ต่อเนื่องเป็นเวลานาน ก็มีโอกาสพังเสียหายได้เป็นเรื่องปกติ ดังนั้นทุกโรงงานจึงต้องมีผู้ที่ทำหน้าที่ซ่อมแซมอุปกรณ์วัดค่าเหล่านี้เรียกว่า วิศวกรซ่อมบำรุง หรือ Maintenance Engineer นั่นเอง หน้าที่ของวิศวกรซ่อมบำรุงหลักๆ คือ การซ่อมอุปกรณ์ให้กลับมาใช้งานได้ใหม่ให้เร็วที่สุด แต่ ณ ปัจจุบันรูปแบบของการซ่อมแซมอุปกรณ์จะมีการแบ่งประเภทออกไป ทำให้วิศวกรซ่อมบำรุงมีลักษณะของงานซ่อมที่หลากหลายขึ้น ดังต่อไปนี้

1. Corrective Maintenance คือการซ่อมอุปกรณ์ที่พังเสียหายไปแล้ว ให้กลับมาใช้งานได้ดังเดิม เนื่องจากเป็นงานที่ถูกเงินทำให้มีระยะเวลาปฏิบัติงานที่จำกัด ถ้าหากซ่อมอุปกรณ์เสร็จช้าก็วยิ่งเสียระยะเวลาในการผลิตไปมากเท่านั้น

2. Preventive Maintenance คือการซ่อมอุปกรณ์เพื่อป้องกันความเสียหายที่จะเกิดขึ้นในอนาคต การซ่อมในลักษณะนี้จะอ้างอิงจากสถิติความเสียหายของอุปกรณ์วัดค่า จากนั้นทำการวิเคราะห์และประเมินต้นตอของปัญหา เมื่อทราบต้นตอของปัญหาที่เป็นสาเหตุให้เป็นอุปกรณ์วัดค่าพังเสียหายบ่อยๆ ทางทีมซ่อมบำรุงจะสร้างระบบขึ้นมาเพื่อตรวจสอบและซ่อมแซมต้นตอของปัญหา ก่อนที่อุปกรณ์วัดค่าจะพัง

3. Predictive Maintenance คือ การซ่อมเครื่องจักรก่อนที่จะพังเสียหายโดยมีการประมาณการไว้ล่วงหน้าว่าอุปกรณ์วัดค่าดังกล่าวจะมีการพังเสียหายในช่วงใด การซ่อมในลักษณะนี้จะเป็นการนำประวัติของอุปกรณ์วัดค่ามาคุยย้อนหลัง เพื่อหารูปแบบของการพังเสียหายของอุปกรณ์ว่ามีสัญญาณใดสามารถเป็นตัวบ่งบอก ระยะเวลาก่อนที่อุปกรณ์วัดค่าจะพังเสียหายได้หรือไม่

ในงานวิจัยนี้จะกล่าวถึงกระบวนการผลิตที่เกี่ยวข้องสองกระบวนการผลิต คือ กระบวนการผลิต โซดาไฟ และกระบวนการผลิตอิพิคโลโรไฮดริน โดยจุดเริ่มต้นจะเริ่มจากการผลิตโซดาไฟจากน้ำเกลือก่อน จุดที่สำคัญในกระบวนการนี้คือ Membrane ถ้าหาก Membrane อุดตัน กระบวนการผลิตโซดาไฟจะไม่สามารถแยกประจุทาง ไฟฟ้าได้ ทำให้ผลิตภัณฑ์โซดาไฟใน

ตอนท้ายไม่เกิดขึ้น การป้องกันไม่ให้ Membrane อุดตันทำได้โดยการสังเกตค่า Total Organic Carbon (TOC) ไม่ให้มากเกินไปที่กำหนด การตรวจวัดค่า TOC โดยเครื่อง Total Organic Carbon Analyzer ถ้าหากค่าเกินที่กำหนด น้ำเกลือรีไซเคิลทั้งหมดจะถูกกำจัดทิ้งหรือนำไปบำบัดเพิ่มเติม ดังนั้นเครื่อง Total Organic Carbon Analyzer เป็นเครื่องที่มีความสำคัญอย่างมากต่อกระบวนการผลิต โซดาไฟ ดังนั้นถ้าสามารถประเมินเวลาพังเสียหายของอุปกรณ์ล่วงหน้าได้ ก็จะสามารถวางแผนรับมือได้อย่างทันเวลา และกระทบต่อกระบวนการผลิตทั้งสองน้อยที่สุด

1.2 วัตถุประสงค์ของการวิจัย

วัตถุประสงค์ของงานวิจัยนี้คือการ Predict Remaining Useful Lifetime (RUL) ของเครื่อง Total Organic Carbon analyzer ให้ได้ โดยสร้างระบบแจ้งเตือนเพื่อให้ฝ่ายปฏิบัติงานซ่อมบำรุงสามารถทราบล่วงหน้าก่อนที่เครื่อง TOC analyzer จะพังเสียหาย เมื่อมีสัญญาณเตือนแจ้งให้ “Need Maintenance” นั้นแสดงว่าทางทีมซ่อมบำรุงต้องเตรียมอะไหล่สำรองและวางแผนเข้างานล่วงหน้า เมื่อซ่อมบำรุงเครื่องเสร็จสามารถใช้ Model ตัวนี้ในการตรวจสอบประสิทธิภาพงานซ่อมได้อีกด้วย สุดท้ายนี้ถ้า Output ของ Model มีความแม่นยำมากกว่า 70% ขึ้นไปในการทำ Prediction ก็จะสามารถนำ Model ดังกล่าวไปใช้ในงานจริงเพื่อลดงานซ่อมด่วนที่อาจเกิดขึ้นในอนาคตและเพิ่มกำไรสูงสุดให้กับบริษัท

1.3 ขอบเขตการวิจัย

- งานวิจัยนี้นำข้อมูลมาจากเครื่อง Total Organic Carbon Analyzer ภายในโรงงานผลิต โซดาไฟจากน้ำเกลือเท่านั้น
- งานวิจัยนี้จัดทำขึ้น โดยได้ผลลัพธ์เป็นการ Classification Output จำนวน 3 Class
- งานวิจัยนี้ใช้ข้อมูลในช่วงเวลา 01-01-2020 ถึง 31-06-2020 มาเพื่อเรียนรู้เชิงลึกเท่านั้น
- งานวิจัยนี้มีการอ้างอิงประวัติย้อนหลังการพังเสียหายของเครื่อง TOC analyzer ในช่วง 01-01-2020 ถึง 31-06-2020 เพื่อให้สามารถระบุ Class ของข้อมูลที่ได้รับมาได้
- งานวิจัยนี้มีการนำค่าต่างๆที่วัดได้จาก Sensor ภายในเครื่อง Total Organic Carbon Analyzer มาหา Correlation กับระยะเวลาที่เครื่องยังสามารถทำงานได้
- สร้างแบบจำลองที่ใช้ในการทำนาย Remaining Useful Lifetime (RUL)
- ทดสอบแบบจำลองที่สร้างขึ้นมากับ Input data ชุดใหม่และเปรียบเทียบกับ Output data จริงกับ Output data ที่ทำนายได้ว่ามีความแตกต่างกันแค่ไหน
- เป้าหมายของแบบจำลองที่คาดหวังไว้คือ ความแม่นยำ 80%

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- สามารถตรวจสอบระยะเวลาที่เหลือที่เครื่องจักรสามารถทำงานได้
- สามารถเตรียมอะไหล่สำรอง กำลังพล และวางแผนงานได้อย่างมีประสิทธิภาพ
- ลดโอกาสที่จะเกิดการพังเสียหายแบบฉุกเฉินเร่งด่วนและสูญเสียโอกาสในการผลิต
- สามารถต่อ ยอดกระบวนการนี้ไปใช้กับเครื่องจักรชนิดอื่นได้ในอนาคต

1.5 ขั้นตอนการดำเนินงาน

- ปรึกษาทีมงานและรวบรวมข้อมูลของปัญหาที่เกิดขึ้นพร้อมทั้งวิเคราะห์หาสาเหตุของปัญหา
- ศึกษาหลักการการทำงานของเครื่อง Total Organic Carbon analyzer และศึกษาหลักการผลิต โซดาไฟเบื้องต้นเพื่อให้เข้าใจความสำคัญของเครื่องมากยิ่งขึ้น
- ทำการเก็บรวบรวมข้อมูลย้อนหลังเป็นระยะเวลา 6 เดือน เพราะเครื่องสามารถเก็บข้อมูลย้อนหลังได้เพียง 3 เดือนเท่านั้น
- พัฒนากระบวนการหา Remaining Useful Lifetime ของเครื่องจักร
- ทดสอบกระบวนการหา Remaining Useful Lifetime ของเครื่องจักรด้วย Data ย้อนหลัง และตรวจสอบผลลัพธ์
- สรุปผลการวิจัย
- เรียบเรียงและจัดทำบทความทางวิชาการ
- เรียบเรียงและจัดทำวิทยานิพนธ์

1.6 ผลงานวิจัยที่ตีพิมพ์

“การทำนายความผิดพลาดระยะต้นของเครื่องวิเคราะห์อินทรีย์คาร์บอน โดยการเรียนรู้เชิงลึก” โดย ธนาภัทร ภัทรวินิจ และ ศ.ดร. ประภาส จงสถิตย์วัฒนา ในงานประชุมวิชาการระดับชาติ วิทยาศาสตร์และเทคโนโลยี ครั้งที่ 5 (The 5th National Conference on Science and Technology, NCOST)

บทที่ 2 ทฤษฎีที่เกี่ยวข้อง

2.1 การผลิตโซดาไฟ

2.1.1 Brine saturation

ในกระบวนการผลิตโซดาไฟโดยใช้วัตถุดิบหลักเป็นสารละลายน้ำเกลือเริ่มต้นขึ้นจากการนำเข้าเกลือจากผู้ผลิตภายนอกเข้ามาเก็บไว้ในคลังเกลือ ก่อนที่จะนำเกลือดังกล่าวมาผสมเข้ากับน้ำเพื่อให้ได้น้ำเกลือที่อิ่มตัวไปใช้ในกระบวนการผลิตต่อไป เราจะเรียกขั้นตอนนี้ว่า Brine Saturation

2.1.2 Brine filtration


น้ำเกลือที่อิ่มตัวแล้วจะยังไม่ได้ส่งเข้ากระบวนการผลิตโดยตรง เนื่องจากน้ำเกลือจะยังไม่บริสุทธิ์เพียงพอ อาจทำให้เกิดความเสียหายต่อกระบวนการผลิตต่อไปได้ จึงต้องเข้าสู่กระบวนการ Brine filtration ก่อน โดยในกระบวนการนี้จะใช้ Filter สองตัวคือ Anthracite และ Cartridge เพื่อทำการกรองอนุภาคของสารที่ไม่ต้องการออกไป

2.1.3 Brine purification

หลังจากผ่านกระบวนการ Brine filtration ตัวน้ำเกลือจะยังมีค่าความไม่บริสุทธิ์อยู่เช่น อนุภาคของ Ca^{++} , Mg^{++} หรือ Sr^{++} ซึ่งอนุภาคเหล่านี้มีผลต่อกระบวนการผลิต ดังนั้นต้องมีการกำจัดออกโดยใช้ Resin tower

2.1.4 NaCl electrolysis

หลังจากได้สารละลายน้ำเกลือ (NaCl) ที่มีความบริสุทธิ์สูง ขั้นตอนที่ต่อไปคือการนำสารละลายน้ำเกลือไปเข้า Electrolysis เพื่อใช้กระแสไฟฟ้าในการแยกวัตถุดิบ โดยผลผลิตที่ได้หลักๆมีสามองค์ประกอบด้วยกันคือ แก๊สคลอรีน (Cl_2), แก๊สไฮโดรเจน (H_2) และ โซดาไฟ (NaOH)



รูปที่ 1 หลักการทำงานของ Electrolysis

2.1.5 Cl₂ cooling

แก๊สคลอรีนที่ได้จาก Electrolysis จะมีอุณหภูมิที่สูงเป็นอย่างมากจำเป็นต้องลดอุณหภูมิลงเพื่อยืดอายุการใช้งานของเครื่องจักรในกระบวนการผลิตถัดไป

2.1.6 Cl₂ drying

การลดอุณหภูมิอย่างรวดเร็วของแก๊สคลอรีนส่งผลให้เกิดการควบแน่นตามมาทำให้แก๊สคลอรีนหลังจาก Cl₂ cooling มีความชื้นสะสมมาก จึงต้องมี Cl₂ drying unit มาทำให้แก๊สคลอรีนแห้งก่อนจะส่งไปกระบวนการผลิตถัดไป

2.1.7 Cl₂ compression

ในขั้นตอนนี้แก๊สคลอรีนพร้อมที่จะนำไปใช้ในขั้นตอนต่อไปแล้ว แต่ด้วยระยะทางของกระบวนการผลิตแต่ละโรงงานนั้นมีระยะห่างกันมาก จึงต้องใช้ Compressor ในการสร้างแรงดันเพื่อส่งแก๊สคลอรีนไปยังกระบวนการผลิตถัดไปได้

2.1.8 H₂ cooling

แก๊สไฮโดรเจนที่ได้จาก Electrolysis จะมีอุณหภูมิที่สูงเป็นอย่างมากจำเป็นต้องลดอุณหภูมิลงเพื่อยืดอายุการใช้งานของเครื่องจักรในกระบวนการผลิตถัดไป

2.1.9 H₂ compression

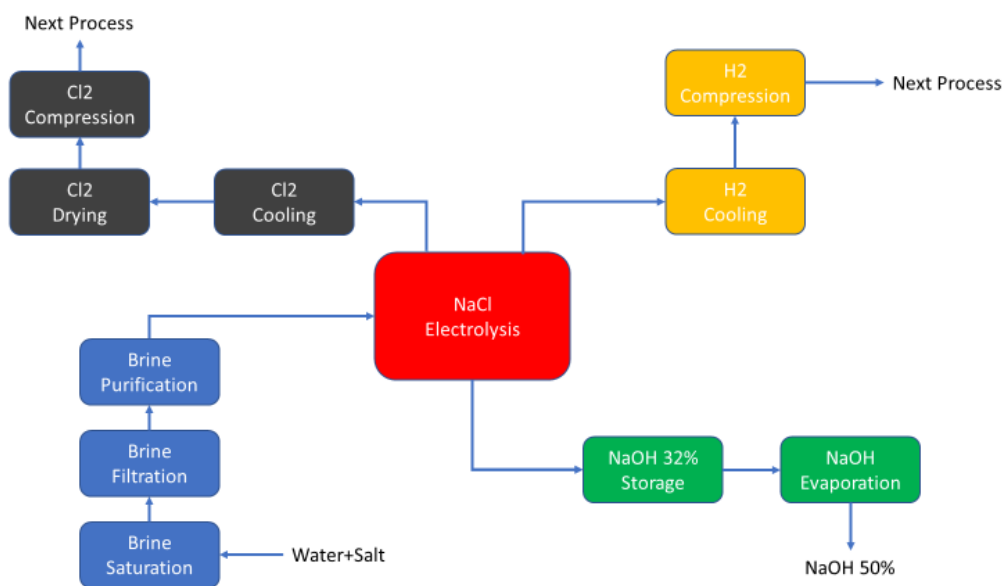
ในขั้นตอนนี้แก๊สไฮโดรเจนพร้อมที่จะนำไปใช้ในขั้นตอนต่อไปแล้ว แต่ด้วยระยะทางของกระบวนการผลิตแต่ละโรงงานนั้นมีระยะห่างกันมาก รวมไปถึงแก๊สไฮโดรเจนมีการใช้ในหลายๆกระบวนการผลิต จึงต้องใช้ Compressor เพื่อให้แก๊สไฮโดรเจนมีแรงดันมากเพียงพอที่จะส่งไปยังทุกกระบวนการผลิต

2.1.10 NaOH 32%

โซดาไฟที่ได้จาก Electrolysis จะมีความเข้มข้น 32% ด้วยความเข้มข้นปริมาณนี้สามารถขายให้กับลูกค้าบางเจ้าได้ทันที แต่ถ้าอยากได้โซดาไฟความเข้มข้นมากกว่านี้จะต้องส่งต่อไปยัง Unit ถัดไป

2.1.11 NaOH evaporation

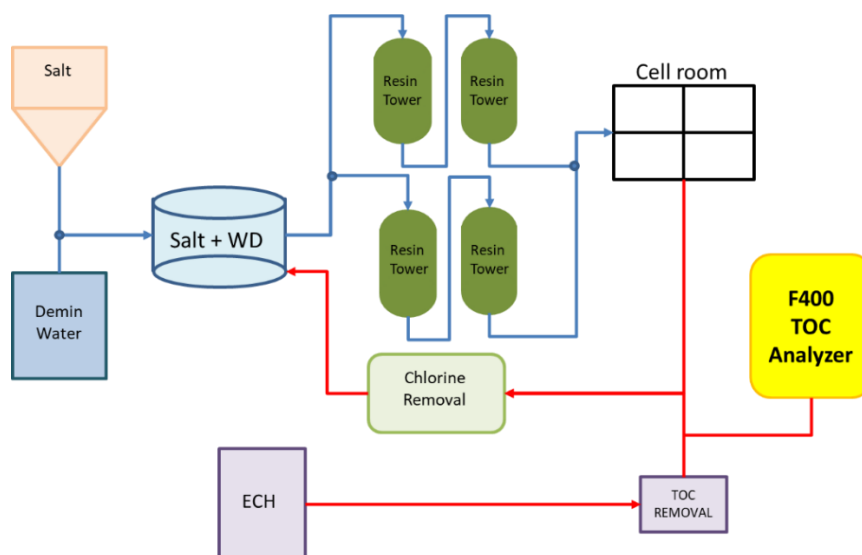
ใช้กระบวนการระเหยโดยใช้ไอน้ำจ่ายให้กับ Unit นี้หลังจากผ่าน Unit นี้จะได้โซดาไฟความเข้มข้น 50%



รูปที่ 2 กระบวนการผลิตโซดาไฟ

2.2 เครื่อง Total Organic Carbon analyzer

2.2.1 ความสำคัญของเครื่อง



รูปที่ 3 ความสำคัญของเครื่อง TOC analyzer

Recycle Brine ที่ได้มาจากกระบวนการผลิตอพิคตอโรไฮดริน จะถูกนำไปเข้ากระบวนการ Chlorine Removal เพื่อดึงคลอรีนในน้ำเกลือออกและนำไปเข้าถังเก็บน้ำเกลืออีกครั้ง ก่อนที่จะ


นำไปใช้ในกระบวนการผลิตโซดาไฟต่อไป แต่ก่อนที่จะถึงกระบวนการนั้น Recycle Brine จะเข้า Unit Total Organic Carbon (TOC) Removal ก่อนเพราะถ้าหาก Recycle brine มี TOC ปริมาณมาก จะทำให้ Membrane ภายใน Cell room [รูปที่ 1] เกิดการอุดตันและพังเสียหายได้ ดังนั้นต้องมีการติดตั้งเครื่อง TOC analyzer เพื่อตรวจสอบค่า Total Organic Carbon ภายใน Recycle Brine แต่ถ้าไม่มีเครื่อง TOC analyzer ปัญหาที่เกิดขึ้นคือ

- 1) ไม่สามารถทราบค่า Total Organic Carbon ภายใน Recycle brine ได้
- 2) ทางโรงงานผลิตโซดาไฟไม่สามารถรับ Recycle brine มาใช้ได้ เพราะกลัวว่าจะก่อให้เกิดปัญหาที่ Cell room และถ้าหากไม่รับ Recycle brine จาก ECH ก็จะต้องมีการผสมน้ำเกลือในปริมาณที่มากขึ้นเพื่อให้ได้ผลิตภัณฑ์ตามเป้าหมายที่วางไว้
- 3) เมื่อโรงงานผลิตอิมัลชันไฮดรินไม่สามารถส่ง Recycle brine กลับไปที่โรงงานผลิตโซดาไฟได้ จำเป็นต้องนำ Recycle brine ทั้งหมดไปเก็บไว้ในถังๆหนึ่ง แต่ถ้าหากถังนั้นเต็ม โรงงานนี้จำเป็นต้องทิ้ง Recycle brine ทั้งหมด หรือเลือกที่จะลดกำลังการผลิตลง เพื่อให้ปริมาณ Recycle brine ที่เกิดขึ้นน้อยลง

2.2.2 หลักการทำงานของเครื่อง Total Organic Carbon analyzer


เครื่อง Total Organic Carbon มีการทำงาน 4 ขั้นตอนด้วยกัน

- 1) Sampling phase: ขั้นตอนแรกของการวัดค่า TOC นำสารที่ต้องการวัด (Sample) มาวางเข้ากับ Reactor (ภาชนะบรรจุสาร) ในปริมาณที่ตั้งค่าเอาไว้
- 2) TIC phase: ขั้นตอนการกำจัด Total Inorganic Carbon ภายใน Sample เพื่อให้ Sample เหลือเพียง Total Organic Carbon และทำการวัดในภายหลัง



รูปที่ 4 ผลลัพธ์ของค่า Total Inorganic Carbon


- 3) Oxidation phase: หลังจากกำจัด TIC ใน Sample ออกหมดแล้ว ทำการเปลี่ยน pH ของ Sample ให้เป็น Base ก่อนที่จะเติม Ozone เข้าไปเพื่อให้ได้ Hydroxyl Radicals ให้ออนออกมา
- 4) TOC phase: เปลี่ยน Hydroxyl Radicals ให้ออน ให้เป็น Carbon dioxide ที่เป็นสัดส่วน โดยตรงกับความหนาแน่นของ Total Organic Carbon



รูปที่ 5 ผลลัพธ์ของค่า Total Inorganic Carbon และ Total Organic Carbon


2.3 โครงข่ายประสาทเทียม (Neural Network)

Neural Network หรือ NN (โครงข่ายประสาทเทียม) คือ โมเดลทางคณิตศาสตร์ หรือโมเดลทางคอมพิวเตอร์สำหรับประมวลผลต่างๆผ่านการคำนวณแบบคอนเนกชันนิสต์ (Connectionist) แนวคิดเริ่มต้นของ Neural network มาจากการศึกษาโครงข่ายไฟฟ้าชีวภาพ (Bio-electric network) ในสมองของคนเรา ซึ่งประกอบด้วยเซลล์ประสาท (Neurons) และ จุดประสานประสาท (Synapses) ตามโมเดลนี้ทำงานประสาทเกิดจากการเชื่อมต่อระหว่างเซลล์ประสาท จนเป็นเครือข่ายที่ทำงานร่วมกันได้ โดยโมเดลนี้จะได้แรงบันดาลใจมาจากสมองของมนุษย์นั่นเอง โมเดลนี้จะมีการเรียนรู้จากชุดข้อมูลฝึกสอนเพื่อทำนายผลลัพธ์ของข้อมูลทดสอบที่ไม่ได้เรียนรู้มาก่อนได้



รูปที่ 6 เปรียบเทียบ Neural network กับการทำงานของสมอง


2.3.1 ภาพรวมของ Neural network



รูปที่ 7 ภาพรวมของ Neural network

- 1) Input layer (จากรูปจะเป็นสี่เหลี่ยม)
 - มีหน้าที่รับข้อมูลเข้ามาในโครงข่ายประสาทเทียม โดย Input layer จะมีเพียงชั้นเดียวเท่านั้น และทำหน้าที่ส่งข้อมูลต่อไปยังชั้น Hidden Layer
- 2) Hidden Layer (จากรูปจะเป็นสี่เหลี่ยม)
 - มีหน้าที่รับข้อมูลมาจาก Layer ก่อนหน้า จะสังเกตได้ว่า Hidden layer สามารถมีมากกว่า 1 ชั้นได้ ซึ่งในทางปฏิบัติเราสามารถเพิ่มหรือลดจำนวนชั้นของ Hidden layer เพื่อปรับความแม่นยำของโมเดล
- 3) Output Layer (จากรูปจะเป็นสี่เหลี่ยม)
 - ทำหน้าที่รับค่าจาก Hidden layer โดยในชั้นของ Output จะมีจำนวนโหนดเท่ากับจำนวน Class ที่ต้องการทำนาย โดยหลักการคือถ้าผ่าน Hidden layer ออกมาแล้ว Perceptron ภายใน Output layer จะมีค่าไม่เท่ากัน โหนดตัวไหนมีค่ามากกว่าแสดงว่าผลลัพธ์ออกมาเป็น Class นั้น

2.3.2 ส่วนประกอบของ Neural Network



รูปที่ 8 ส่วนประกอบภายใน Layer ของ Neural network

2.3.2.1 เพอร์เซปตรอน (Perceptron)

เพอร์เซปตรอนสามารถนำมาใช้จำแนกผลลัพธ์เป็นสองกลุ่ม โดยกำหนดให้ฟังก์ชันของเพอร์เซปตรอน แทนด้วย $f(x)$ โดยมีข้อมูลรับเข้าคือ x และข้อมูลส่งออกคือ \hat{y} โดยแสดงการคำนวณข้อมูลที่ส่งออกได้

$$\hat{y} = f(x) = \begin{cases} 1, & \text{if } \sum_{i=1}^m w_i x_i + b > 0 \\ 0, & \text{otherwise} \end{cases}$$

โดยกำหนดให้ w = น้ำหนัก (Weight)

b = ค่าไบแอส (Bias)

m = จำนวนของข้อมูลที่รับเข้ามาสำหรับกระบวนการเรียนรู้ของ Perceptron

กำหนดให้ชุดข้อมูลทุกอย่างแทนด้วย x และผลลัพธ์จริงแทนด้วย y จะได้สมการดังนี้


$$W_i \leftarrow W_i + \Delta W_i$$

$$W_i = \alpha (\hat{y} - y) x_i$$

โดย α คืออัตราเรียนรู้ (Learning rate) ซึ่งเป็นค่าที่บ่งบอกว่าการเรียนรู้ในแต่ละรอบจะมีการเปลี่ยนแปลงน้ำหนักด้วยอัตราส่วนของผลต่างของผลลัพธ์ไปมากเท่าใด

2.3.2.2 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feed forward neural network)

นิเวศน์ตวิร์กแบบป้อนไปข้างหน้ามีลำดับในการคำนวณและส่งผ่านข้อมูลไปในทิศทางเดียว โดยโครงสร้างจะแบ่งออกเป็นลำดับชั้น ซึ่งในแต่ละชั้นจะมีโหนดจำนวนหนึ่งซึ่งมีเส้นเชื่อมถึงกันภายในชั้นเดียวกัน แต่จะมีเส้นเชื่อมกับ โหนดตัวอื่นที่อยู่ในลำดับชั้นที่ติดกันทั้งหมด โดยข้อมูลส่งออกของโหนดในชั้นก่อนหน้า จะเป็นข้อมูลรับเข้าของโหนดในชั้นปัจจุบัน โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าสามารถแสดงได้ดังรูปด้านล่าง



รูปที่ 9 รูปแบบของ Feed forward neural network

กำหนดสัญลักษณ์แทนการคำนวณไปข้างหน้า (feedforward) โดยให้ a_k^{l-1} แทนผลลัพธ์ของโหนดตัวที่ k ในลำดับชั้นที่ $l-1$ และ w_{jk}^l แทนน้ำหนักสำหรับโหนดตัวที่ j ในลำดับชั้น l ที่มีเส้นเชื่อมมาจากโหนดตัวที่ k ในลำดับชั้นก่อนหน้า และ b_j^l คือ ไบแอส

นอกจากนี้ให้ g แทนฟังก์ชันกระตุ้น และให้ n แทนจำนวนโหนดในลำดับชั้นที่ $l-1$ จะสามารถแสดงการคำนวณค่า a_k^l ได้โดยสมการดังต่อไปนี้


$$z_j^l = \sum_{k=1}^n w_{jk}^l a_k^{l-1} + b_j^l$$

$$a_j^l = g(z_j^l)$$

2.3.2.3 ฟังก์ชันกระตุ้น (Activation Function)

สำหรับข้อมูลส่งออกของแต่ละโหนด จะมีการใช้ฟังก์ชันกระตุ้น $g(z)$ เพื่อทำให้โครงข่ายประสาทเทียมมีความซับซ้อนและสามารถแก้ปัญหาได้หลายหลายมากขึ้น ฟังก์ชันกระตุ้นที่นิยมกันมีดังต่อไปนี้

- 1) ฟังก์ชันซิกมอยด์ (Sigmoid Function)




รูปที่ 10 Function การทำงานของ Sigmoid

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง 0 ถึง 1 ฟังก์ชันซิกมอยด์สามารถเขียนแทนด้วย σ ซึ่งคำนวณได้จากสมการ

$$\sigma(Z) = \frac{1}{1 + e^{-z}}$$

2) ฟังก์ชันแทนเจนต์ไฮเพอร์โบลิก (Hyperbolic Tangent Function)




รูปที่ 11 Function การทำงานของ Tanh

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง -1 ถึง 1 ฟังก์ชันแทนเจนต์ไฮเพอร์โบลิกสามารถเขียนแทนด้วย \tanh ซึ่งคำนวณได้จากสมการ

$$\text{Tanh}(Z) = \frac{e^Z - e^{-Z}}{e^Z + e^{-Z}}$$

3) ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax Function)




รูปที่ 12 Function การทำงานของ Softmax

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง 0 ถึง 1 ซึ่งสามารถเทียบได้กับความน่าจะเป็นของผลลัพธ์ กำหนดให้ชั้นของนิวรอนเน็ตเวิร์กที่ต้องการคำนวณมีผลลัพธ์ทั้งหมด k ตัว ค่าของผลลัพธ์นั้นแทนด้วยสัญลักษณ์ z จะได้ว่า ฟังก์ชันค่าสูงสุดอย่างอ่อนของผลลัพธ์ตัวที่ j หรือ แทนด้วยสัญลักษณ์ f_j ซึ่งคำนวณได้จากสมการ

$$f(z)_j = \frac{e^{z_j}}{\sum_{i=1}^k e^{z_i}}$$

4) ฟังก์ชันเรกติไฟต์เชิงเส้น (Rectified Linear Unit function หรือ ReLU)



รูปที่ 13 Function การทำงานของ Sigmoid เทียบกับ ReLU

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาเป็นค่ามากกว่าหรือเท่ากับศูนย์เสมอ สมการฟังก์ชันเรกติไฟต์เชิงเส้นสามารถแทนด้วยสัญลักษณ์ f ซึ่งคำนวณได้จากสมการ

$$f(x) = \begin{cases} 0 & \text{if } z < 0 \\ z & \text{if } z \geq 0 \end{cases}$$

5) ฟังก์ชันขีดแบ่ง (Threshold Function)


เป็นฟังก์ชันรูปทั่วไปของฟังก์ชันเรกติไฟต์เชิงเส้น โดยจะมีค่าขีดแบ่ง t ตามที่กำหนด สมการของฟังก์ชันขีดแบ่ง สามารถแทนด้วยสัญลักษณ์ f ซึ่งคำนวณได้จากสมการ

$$f(z, t) = \begin{cases} 0 & \text{if } z < t \\ z & \text{if } z \geq t \end{cases}$$

2.3.2.4 อัลกอริทึมการเพิ่มประสิทธิภาพ (Optimization Algorithms)

ในยุคสมัยที่โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ หรือ Backpropagation ถือกำเนิดขึ้น การปรับน้ำหนักในแต่ละจุดสามารถปรับปรุงเพื่อให้ได้ค่าที่แม่นยำมากยิ่งขึ้นกว่าเดิมจากวิธีการหาค่าน้ำหนัก (W) ใหม่โดยการใช้สิ่งที่เรียกว่า Optimization Algorithms ซึ่งหน้าที่ของมันคือปรับปรุงค่าต่างๆ ในโหนด ทำให้ output จาก Model สามารถทำได้ใกล้เคียงเป้าหมายมากขึ้น





รูปที่ 14 เปรียบเทียบ Optimization Algorithms

โดยจุดประสงค์ของการเลือกใช้ optimize function คือการทำให้ Output อยู่ใกล้กับเป้าหมายที่สุด และใช้เวลาน้อยที่สุดเช่นกัน


1) Stochastic Gradient Descent

Stochastic Gradient Descent (SGD) เป็นอัลกอริทึมที่อัปเดตค่าพารามิเตอร์ในทุกๆชุดข้อมูลฝึกฝน เป็นอัลกอริทึมที่ค่อนข้างไว และมีการอัปเดตเพียง 1 ครั้งต่อการเทรน 1 รอบ

$$\theta = \theta - \eta \cdot \nabla J(\theta; x(i); y(i))$$

เมื่อ $\{x(i), y(i)\}$ คือชุดข้อมูลฝึกฝน


โดยในทุกๆครั้งที่มีการอัปเดต ค่าพารามิเตอร์ที่อัปเดตจะมีค่าความแปรปรวนสูงและส่งผลกระทบต่อค่า Loss function แปรผันไปตาม different intensities โดยขั้นตอนเหล่านี้เป็นสิ่งที่ดีเพราะมันช่วยให้สามารถค้นพบค่าที่น้อยที่สุดได้ แต่วิธีนี้มีข้อเสียคือยิ่งลู่ลงต่ำเท่าไร ค่าที่ได้ก็จะยิ่งแปรปรวนและซับซ้อนมากยิ่งขึ้น



รูปที่ 15 เปรียบเทียบระหว่าง Stochastic Gradient descent และ Gradient descent

2) Mini Batch Gradient Descent

ถูกพัฒนาขึ้นเพื่อแก้ปัญหของ Gradient Descent ที่หลายโดยการนำข้อดีของ Gradient Descent และ Stochastic Gradient Descent มารวมกันและสำหรับอัลกอริทึมนี้จะอัปเดตค่าเป็น “ชุด” โดยภายในชุดจะประกอบด้วยข้อมูลจำนวน n ข้อมูลนั่นเอง




รูปที่ 16 เปรียบเทียบ Mini Batch Gradient Descent และ Algorithms ตัวอื่น

3) Momentum

ในการปรับค่าในแต่ละครั้งของ SGD จะสร้างความแปรปรวนเกิดขึ้นมาก ทำให้ยากที่ลู่เข้าจุดที่ดีที่สุดได้ (best optimize) จึงได้มีอัลกอริทึมที่ชื่อว่า “Momentum” เกิดขึ้น Momentum ถูกคิดค้นเพื่อเร่งความเร็วในการ optimize ของ SGD โดยการให้ความสำคัญในการพุ่งไปยังทิศทางที่ใกล้จุดกลางมากที่สุดก่อนแล้วทำให้ทิศทางที่ไม่เกี่ยวข้องความสำคัญลดลง ทำให้เกิดทิศทางที่ “ถูกต้อง” เกิดขึ้น โดยเป็นการเพิ่ม fraction ‘ γ ’ เข้ามาในการ update ทิศทางในแต่ละครั้ง

$$V(t) = \gamma V(t - 1) + \eta \nabla J(\theta)$$

โดยอัปเดตค่าพารามิเตอร์ด้วย $\theta = \theta - \gamma \nabla L(\theta)$ และ ค่า γ นิยมตั้งไว้ที่ 0.9 หรือค่าที่ใกล้เคียงกัน



รูปที่ 17 เปรียบเทียบ Momentum ก่อนและหลัง Update

4) Adagrad

เป็น Optimize ที่สามารถปรับค่า Learning Rate ให้เหมาะสมกับพารามิเตอร์ได้ โดยจะมีการอัปเดตจำนวนมากสำหรับค่าพารามิเตอร์ที่มีจำนวนน้อย และอัปเดตน้อยนักถ้าค่าพารามิเตอร์มีจำนวนมาก และด้วยเหตุนี้ Optimizer ตัวนี้จึงเป็นที่นิยมสำหรับข้อมูลที่กระจายโดยค่า Learning Rate จะถูกเปลี่ยนทุกๆครั้งสำหรับพารามิเตอร์ θ (ทิศทางในการเคลื่อนที่) โดยอ้างอิงจากทิศทางที่ผ่านมาที่ผ่านการคำนวณจาก Gradient descent มาแล้ว เปรียบเทียบได้ดังรูปสมการด้านล่าง

$$\text{SGD} \quad \theta_{t+1,i} = \theta_{t,i} - \eta \cdot g_{t,i}$$

$$\text{Adagrad} \quad \theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} \cdot g_{t,i}$$

5) AdaDelta

AdaDelta พัฒนามาจาก AdaGrad โดยสามารถแก้ปัญหา Decaying learning Rate ที่เกิดขึ้นใน AdaGrad ได้ โดยแทนที่จะเก็บสะสมการคำนวณทั้งหมดที่ผ่านมาของ Gradient แต่ AdaDelta จะถูกจำกัดการสะสมค่าการคำนวณของ Gradient ให้นั้นเองเพื่อแก้ขนาดค่าของ W ที่เกิดขึ้น แทนที่จะเก็บค่า W ที่ได้รับการอัปเดตมาก่อนหน้านี้แต่ไม่สามารถใช้งานได้ จึงเปลี่ยนเป็นการหาผลรวมของ Gradients หากใช้วิธีนี้ไปเรื่อยๆก็จะสามารถแก้ปัญหา Decaying learning rate ของ gradients ที่ผ่านมาทั้งหมด

$$\text{Adagrad} \quad \theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} \cdot g_{t,i}$$

AdaDelta
$$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{E[g^2]_{t+\epsilon}}} \cdot g_{t,i}$$

6) Adam

Adam ย่อมาจาก Adaptive Moment Estimation เป็น optimizer ที่สามารถปรับ learning rates สำหรับพารามิเตอร์ในแต่ละครั้งได้และยังสามารถแก้ปัญหา decaying ของ gradients ในแต่ละสแต็ปที่ผ่านมาได้เหมือนกับ AdaDelta อีกทั้งยังอธิบายการเกิด decaying average ของ gradients $M(t)$ ที่ผ่านมาได้อีกด้วย เหมือนกับ Momentum

Adam เป็น optimizer ที่เป็นที่ยอมรับมากที่สุดเพราะรวมจุดเด่นของแต่ละ Optimizer แล้วลบจุดด้อยต่างๆออกไปทั้งการ decaying learning rate ของ Adagrad และช่วยให้โมเดลสามารถเรียนรู้ได้อย่างต่อเนื่อง อีกทั้งยังใช้เวลาน้อยกว่า Gradient Descent และลดปัญหาการแกว่งของพารามิเตอร์ได้อีกด้วย

2.3.2.5 การวัดประสิทธิภาพ

ประสิทธิภาพในด้านการทำนายแนวโน้มของเครื่อง Total Organic Carbon analyzer คือ การวัดประสิทธิภาพการจำแนกแบบ Multiclass (Multi-Class Classification) เนื่องจากมี Class ที่ต้องทำ Prediction มากกว่า 2 Class ซึ่งสามารถแสดงได้ดังนี้

1) คอนฟิวชันเมทริกซ์ (Confusion Matrix) แบบ Binary Classification

คือ เมทริกซ์ที่แสดงผลของการจำแนกโดยแจกแจงจำนวนที่จำแนกได้ตามคลาส ดังตัวอย่างในตารางที่ 1 ซึ่งแสดงการจำแนกข้อมูลเป็น 2 คลาส โดยค่าแต่ละแถวแสดงจำนวนข้อมูลที่มีคลาสนั้นเป็นคำตอบที่ถูกต้อง ส่วนค่าในแต่ละหลักแสดงจำนวนข้อมูลที่ทำนายได้ในคลาสนั้น กำหนดให้สำหรับคลาสใด ๆ

TP คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายถูก (True Positive)

FP คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายผิด (False Positive)

TN คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายถูก (True Negative)

FN คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและทำนายผิด (True Negative)

		คลาสที่ทำนาย	
		แนวโน้มขาขึ้น	แนวโน้มขาลง
คลาสจริง	แนวโน้มขาขึ้น	TP	FN
	แนวโน้มขาลง	FP	TN

ตารางที่ 1 รูปแบบของ Confusion matrix แบบ Binary Classification

2) คอนฟิวชันเมทริกซ์ (Confusion Matrix) แบบ Multi Classification


คือ เมทริกซ์ที่แสดงผลของการจำแนกโดยแจกแจงจำนวนที่จำแนกได้ตามคลาส ดังตัวอย่างในตารางที่ 1 ซึ่งแสดงการจำแนกข้อมูลเป็น 3 คลาส โดยค่าแต่ละแถวแสดงจำนวนข้อมูลที่มีคลาสนั้นเป็นคำตอบที่ถูกต้อง ส่วนค่าในแต่ละหลักแสดงจำนวนข้อมูลที่ทำนายได้ในคลาสนั้น ข้อแตกต่างของ Multi Classification และ Binary Classification คือ วิธีการหา TP, TN, FP, FN โดยจะไม่สามารถดูจากตารางได้ เพราะไม่มี Class ที่เป็น Positive และ Negative การหา Class ที่เป็น Positive และ Negative ต้องทำการคำนวณเพิ่มเติม ดูตัวอย่างด้านล่าง

		True Class		
		Apple	Orange	Mango
Predicted Class	Apple	7	8	9
	Orange	1	2	3
	Mango	3	2	1

ตารางที่ 2 รูปแบบของ Confusion matrix แบบ Multi-Classification


การจะหา TP, TN, FP, FN จะต้องหาแยกแต่ละ Class ถ้าจะหา Class Apple ผลลัพธ์ที่ได้จะเป็นตามด้านล่าง

- True Positive ของ Apple



ตารางที่ 3 การหา True Positive ของ Multi-Classification

- True Negative ของ Apple



ตารางที่ 4 การหา True Negative ของ Multi-Classification

- False Negative ของ Apple



ตารางที่ 5 การหา False Negative ของ Multi-Classification

- False Positive ของ Apple

		True Class		
		Apple	Orange	Mango
Predicted Class	Apple		8	9
	Orange			
	Mango			

FP = 8+9 = 17

ตารางที่ 6 การหา False Positive ของ Multi-Classification

- 3) ตัววัดประสิทธิภาพจำแนกตามคลาส

โดยทั่วไปตัววัดประสิทธิภาพที่นิยมใช้กันในงานวิจัยมีอยู่ 4 ค่า ดังนี้

- ค่าความเที่ยง (Precision) เป็นการวัดความแม่นยำของแบบจำลองโดยการพิจารณาแยกทีละคลาส ตัวอย่างเช่นการวัดว่าแบบจำลองทำนายว่าคำตอบที่เป็นบวกถูกต้องเท่าไร จากผลการทำนายคลาสบวกทั้งหมดเท่าไร

$$Precision = \frac{TP}{TP + FP}$$

- ค่าความระลึก (Recall) เป็นการวัดความถูกต้องของแบบจำลองโดยการพิจารณาแยกทีละคลาส ตัวอย่างเช่น การวัดว่าผลการทำนายคลาสบวกความถูกต้องเท่าไรเมื่อเทียบกับคลาสบวกจริงทั้งหมด

$$Recall = \frac{TP}{TP + FN}$$

- ค่าเอฟวัน (F1) เป็นการวัดความเที่ยงและความระลึกของแบบจำลองไปพร้อม ๆ กันโดยคำนวณได้จากสมการดังต่อไปนี้

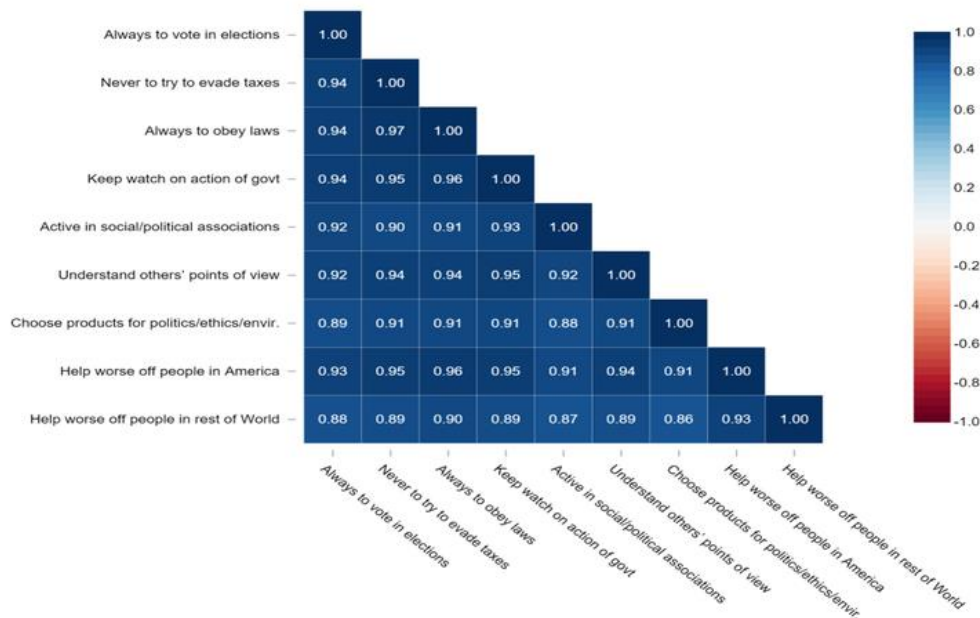
$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

- ค่าความแม่นยำ (Accuracy) เป็นการวัดความแม่นยำของแบบจำลองโดยรวม กล่าวคือ แบบจำลองทำนายถูกกี่ครั้งจากจำนวนการทำนายทั้งหมด

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

ในเบื้องต้นงานวิจัยนี้ใช้ค่าความแม่นยำในการวัดประสิทธิภาพของแบบจำลอง เพื่อทำนายหา ระยะเวลาก่อนที่เครื่องจักรจะเสีย

2.3.2.6 Correlation Matrix



รูปที่ 18 ลักษณะของ Correlation matrix

Correlation matrix เป็นตารางที่แสดงความสัมพันธ์ (Correlation coefficients) ระหว่างค่าต่างๆ โดยใน เซลล์แต่ละเซลล์ในตารางนั้นจะแสดงค่าความสัมพันธ์ของค่าสองค่า Correlation matrix ทำหน้าที่สรุปข้อมูลเพื่อที่จะนำไปใช้วิเคราะห์ต่อไปในอนาคต เป้าหมายสำคัญในการสร้าง Correlation matrix คือ วิเคราะห์ข้อมูลที่ใช้, การเขียนโปรแกรม, ดูข้อมูลที่ขาดหายไป และใช้สำหรับการนำเสนอให้เห็นภาพ

1) ตัวอย่างการใช้งาน Correlation matrix

โดยปกติแล้ว Correlation matrix จะเป็นรูปแบบของ Square ที่มี Variables แสดงทั้ง Column และ Row เหมือนกัน ดังเช่นรูปด้านล่าง ตารางนี้จะแสดงค่าความสัมพันธ์ของสิ่งต่างๆ มากมายต่อมนุษย์ เส้น 1.00 จากซ้ายมือบนสุดจนถึงขวามือล่างสุดเรียกว่าเส้น Diagonal ที่แสดงค่าความสัมพันธ์ของตัวเอง

	Always to vote in elections	Never to try to evade taxes	Always to obey laws	Keep watch on action of govt	Active in social/political associations	Understand others' points of view	Choose products for politics/ethics/envir.	Help worse off people in America	Help worse off people in rest of World
Always to vote in elections	1.00	.94	.94	.94	.92	.92	.89	.93	.88
Never to try to evade taxes	.94	1.00	.97	.95	.90	.94	.91	.95	.89
Always to obey laws	.94	.97	1.00	.96	.91	.94	.91	.96	.90
Keep watch on action of govt	.94	.95	.96	1.00	.93	.95	.91	.95	.89
Active in social/political associations	.92	.90	.91	.93	1.00	.92	.88	.91	.87
Understand others' points of view	.92	.94	.94	.95	.92	1.00	.91	.94	.89
Choose products for politics/ethics/envir	.89	.91	.91	.91	.88	.91	1.00	.91	.86
Help worse off people in America	.93	.95	.96	.95	.91	.94	.91	1.00	.93
Help worse off people in rest of World	.88	.89	.90	.89	.87	.89	.86	.93	1.00

รูปที่ 19 ตัวอย่างการใช้งาน Correlation Matrix

2) การใช้งาน Correlation matrix

1. เพื่อสรุปข้อมูลที่มีปริมาณมากเพื่อหาเป้าหมายหลักคือ Pattern ของข้อมูล ในตัวอย่างด้านบนจะเห็นได้ว่าค่าแต่ละค่ามีความเกี่ยวข้องกับค่าอื่นๆสูงมาก
2. เพื่อใช้เป็นข้อมูล Input ในการวิเคราะห์ค่าอื่นๆ เช่น โดยปกติคนทั่วไปจะใช้ในการสำรวจ Factor analysis หรือใช้เป็นข้อมูลสำหรับทำ Linear regression เมื่อต้องการแยก Missing value ออกไป
3. ใช้สำหรับเป็นข้อมูลเปรียบเทียบการวิเคราะห์อื่นๆ ยกตัวอย่างเช่นการใช้ Linear Regression ในการทำ Prediction พบว่าการที่ข้อมูลมี Correlation กันมากๆจะทำให้ Linear Regression ค่อนข้างมีประสิทธิภาพ

2.3.2.7 การทำ Normalization

การทำ Feature Scaling คือ วิธีการปรับช่วงขอบเขตของข้อมูลชนิดตัวเลข Cardinal แต่ละ Feature (Field) ให้อยู่ในช่วงเดียวกัน ที่เหมาะกับการนำไปประมวลผลต่อ เข้าสู่ตรรกานวนได้ง่าย เช่น ช่วง [0, 1] หรือ [-1, 1] ได้ผลลัพธ์อยู่ในช่วงที่กำหนด เรียกว่า Data Normalization นิยมทำในขั้นตอน Preprocessing จัดเตรียมข้อมูล ก่อนป้อนให้โมเดลใช้เทรน

ความสำคัญของการทำ Normalization ข้อมูล

ข้อมูลดิบที่ได้รับมานั้นมีความหลากหลาย ทั้งชนิดข้อมูล รูปแบบข้อมูล และ Scale ช่วงของข้อมูล (ข้อมูลตัวเลข Cardinal) เช่น ข้อมูลเด็กมัธยม มี 3 Feature คือ อายุ [10, 20], น้ำหนัก [30, 200] ส่วนสูง [120, 180] สำหรับอัลกอริทึม Machine Learning หลาย ๆ ตัว ไม่สามารถรับข้อมูลหลากหลาย Scale แบบนี้ได้โดยตรง จำเป็นที่เราต้องทำ Normalization ก่อนที่เราจะป้อนข้อมูลให้กับโมเดล อัลกอริทึมถึงจะสามารถทำงานได้ยกตัวอย่างเช่น L2 Loss หรือ Mean Square Error ถ้าค่ายิ่งแตกต่างกันมาก Loss ก็จะมีค่ามาก เนื่องจากยกกำลังสอง ทำให้ Feature น้ำหนักที่มีค่ามากกว่า จะบดบัง Feature อื่นๆ แต่ถ้ามีการทำ Normalize ทุก Feature ให้เป็น [0, 1] เท่ากันหมด ก็จะแก้ปัญหานี้ได้

1) Rescaling (Min-Max Normalization)


Rescaling หรือ Min-Max Normalization เป็นวิธีที่ง่ายที่สุด ที่จะปรับช่วงข้อมูล ให้เป็นอยู่ในช่วง [0, 1] ด้วยการนำ Feature / Column นั้น ๆ ลบด้วยค่าที่น้อยที่สุด (Min) แล้วหารด้วยช่วงของข้อมูลนั้น (Max - Min)

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$

2) Mean Normalization

Mean Normalization คล้ายกับ Rescaling แตกต่างกันที่ใช้ Mean แทน Min ทำให้ช่วงของ Output [-0.5, 0.5] มีทั้งบวกและลบ Balance กัน

$$x' = \frac{x - \text{average}(x)}{\max(x) - \min(x)}$$



รูปที่ 20 เปรียบเทียบการทำ Normalization แต่ละวิธี


3) Standardization (Z-Score Normalization)

Standardization หรือ Z-Score Normalization คือ การนำข้อมูล Feature / Column มาปรับให้ Mean = 0 และ Standard Deviation = 1 (Unit Variance)

$$x' = \frac{x - \bar{x}}{\sigma} \quad x' = \frac{x - \bar{x}}{\sigma}$$


2.3.2.8 K-Fold Cross Validation

การสร้าง Prediction Model ขึ้นมาสิ่งที่ยากคือการเลือกข้อมูลที่จะนำมา Train และ Test ให้กับ Model เนื่องจากข้อมูลอาจจะ Overfitting ทำให้ Accuracy ที่ได้จากการ Predict นั้นสูงกว่าความเป็นจริง หากต้องการจะหลีกเลี่ยงปัญหานี้จะต้องทำการ Cross Validation ข้อมูลควบคู่ไปกับการ Split Train data และ Test data เพื่อให้ได้ข้อมูลสองชุดขึ้นมาก่อนที่จะแบ่ง Data ที่เป็น Train data ออกเป็น Subset ย่อยๆ เพื่อนำข้อมูลเหล่านั้นมา Validate Model หลัง Train ก่อนที่จะนำไป Test ด้วย Test data



รูปที่ 21 แนวคิด K-Fold Cross Validation

การทำ K-Fold Cross validation จะแบ่งข้อมูลออกเป็น K subsets ภายใน K subsets จะใช้ K-1 subsets เป็น Train data และเหลือ Subset สุดท้ายให้เป็น Validation data ด้วยวิธีนี้ทำให้สามารถดูค่าเฉลี่ย Accuracy ของ Model ได้และหลังจากนั้นจะทำการ Test ด้วย Test data ที่แยกไว้แล้ว



รูปที่ 22 ตัวอย่างการใช้งาน 10-Fold Cross Validation

บทที่ 3 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์นี้ เนื้อหาหลักๆจะมาจากการทำ Predictive maintenance ของอุปกรณ์เพื่อป้องกันการซ่อมบำรุงแบบ Unplanned โดยรูปแบบของ Model ที่ใช้จะมีความแตกต่างกันไป บางงานวิจัยใช้หลักการ Support Vector Machine บางงานวิจัยใช้ Convolution Neural Network เพื่อทำนายสถานะของเครื่องในปัจจุบัน หรือแม้แต่การทำนายวันเวลาที่เหลืออยู่ที่เครื่องจักรยังทำงานได้ก็สามารถทำได้เช่นกัน โดยงานวิจัยที่ยกมานั้นมาจากหลากหลายอุตสาหกรรมทั้ง โรงงานไฟฟ้า แท่นขุดเจาะ เครื่องจักรบนเรือ จะสังเกตได้ว่าไม่ว่าจะลักษณะงานแบบใดการทำ Predictive Maintenance ก็สามารถก่อให้เกิดประโยชน์ได้เหมือนกัน

3.1 Failure Prediction in Open-Hole Wireline Logging of Oil and Gas Drilling Operation Using Support Vector Machine


งานวิจัยของคุณ Maylada ที่ใช้ Support Vector Machine มาทำ Failure Prediction in Open-hole Wireline Logging of Oil and Gas Drilling Operation

งานวิจัย [6] อาจจะไม่ได้อ้างอิงถึงงานซ่อมบำรุงที่เป็นหัวข้อของข้าพเจ้าโดยตรง แต่ก็เป็นการทำ Predictive เช่นกัน โดยจุดเริ่มต้นของงานวิจัยนี้คือในงานขุดเจาะน้ำมันนั้น การที่จะขุดหลุมลงไปเพื่อคั่นหาน้ำมันมีความเสี่ยงที่จะขุดลงไปแล้วขาดทุนเช่นกัน เนื่องจากในการขุดเจาะทุกครั้งบริษัทนายทุนไม่ได้มองว่ามีน้ำมันอยู่แน่นอน เพียงแต่มีโอกาสที่จะมีมากกว่าไม่มี ทำให้คู้มูลค่าที่จะเสี่ยงลงทุน ดังนั้นการทำ Model Prediction ก็จะสามารถช่วยเพิ่มความมั่นใจในการลงทุนได้ โดยการเก็บข้อมูลที่สำคัญทางธรณีวิทยาย้อนหลัง 4 ปี มี Input 32 ค่า เพื่อ Predict ผลลัพธ์ว่าจะ Success หรือ Fail

	1	2	3	.	.	.	32	Class
Logging#1								Success
Logging#2								Fail
Logging#3								Success


รูปที่ 23 ลักษณะของข้อมูลที่เป็น Input และ Output ให้กับ Model

แต่เนื่องจากข้อมูลที่เก็บมาได้ในงานวิจัยนี้มาจากการเทคนิคการขุดเจาะ 2 แบบ ทำให้ Data ที่มีนั้นไม่สามารถใช้ Train กันและกันได้ต้องแบ่งข้อมูล Input ออกมาเป็น 2 เทคนิคเช่นกัน




รูปที่ 24 การแบ่งกลุ่มของข้อมูลตามเทคนิคการชุดเจาะ

เนื่องจากปริมาณของ Data ที่เก็บมาไม่ได้เยอะดังนั้นจึงใช้เทคนิค 5-fold cross validation เพื่อลดอัตราความผิดพลาดในการ Predict โดยการ Random ข้อมูลครั้งละ 30% เพื่อทำการ Validate และทำแบบนี้ซ้ำๆทั้งหมด 5 ครั้ง



รูปที่ 25 5-Fold Cross validation กับ Training data

Data ด้านบนจะถูกนำมาเข้า Algorithm ที่แตกต่างกันเพื่อหา Result ของงานวิจัยนี้ ซึ่งผลลัพธ์จากการ Predict ด้วย Support Vector Machine, Naives Bayes และ Decision tree จะได้ผลลัพธ์ตามกราฟด้านล่าง



รูปที่ 26 เปรียบเทียบ Accuracy เมื่อใช้ Algorithm ที่ต่างกัน


จะเห็นได้ว่า Support Vector Machine นั้นมี Accuracy สำหรับ Data Input Group1 มากที่สุดที่ 94.75% และ Decision Tree มี Accuracy สำหรับ Data Input Group2 มากที่สุดที่ 95.65%

3.2 Machine Learning for Long Cycle Maintenance Prediction of Wind Turbine

งานวิจัยของ Chia-Hung Yeh สำหรับการนำ Machine Learning มาทำ Long Cycle Maintenance Prediction of Wind Turbine

เนื้อหาภายในงานวิจัย [10] เกี่ยวข้องกับงาน Predictive maintenance โดยตรง จุดเริ่มต้นของงานวิจัยเกิดจากการที่เทคโนโลยี IOT (Internet of Thing) เริ่มเข้ามามีบทบาทในชีวิตของคนเราและในโรงงานของเราก็มี IOT เช่นกันโดยเก็บค่าต่างๆภายในโรงงานจาก Sensor คำถามคือค่าที่เก็บมาได้เหล่านี้สามารถนำไปทำให้เกิดประโยชน์อะไรได้บ้าง ซึ่งในงานวิจัยนี้ผู้วิจัยได้ทำการเก็บข้อมูลมาจากโรงงานไฟฟ้าพลังงานงานลม ที่มีกังหันลมเป็นเครื่องจักรหลักในการสร้างพลังงานทั้งหมด 31 เครื่องจาก 2 Wind farm และจะนำข้อมูลเหล่านี้ประกอบการตัดสินใจในการหยุด Plant เพื่อซ่อมบำรุง ถ้าการ Predict แม่นยำเราจะสามารถเพิ่มกำไรในอนาคตให้กับกระบวนการผลิตได้

งานวิจัยนี้มีการนำ Input data ไปเข้า Model สำหรับ Predictive 2 model ด้วยกัน โดยผู้วิจัยเรียกว่า Hybrid Model ที่นำ model ของ Convolutional neural network (CNN) กับ Support Vector machine (SVM) มารวมกัน



รูปที่ 27 Flow chart ภาพรวม ของงานวิจัย

เริ่มต้นทางโรงงานไฟฟ้าจะรับค่าจาก Sensor ที่วัดที่ Wind turbine มาทั้งหมด 3 แบบ ด้วยกันคือ Operation data, Event codes และ Maintenance data และจะกรองข้อมูลที่ Error พร้อมกับ Extract ข้อมูลที่จำเป็นมาใช้ หลังจาก Cleaning ข้อมูลเรียบร้อยแล้วให้นำมาข้อมูลที่เก็บได้มา จัด Attribute แบ่งเป็น NAN time, time condition, and NAN period


Time	Machine	No. 1	No. 2	No. 3	No. 4	No. 5	No. 6	No. 7	No. 8	No. 9	No. 10	No. 11
'2015/10/06 11:40:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 11:50:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 12:00:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 12:10:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 12:20:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 12:30:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 12:40:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 12:50:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 13:00:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 13:10:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 13:20:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 13:30:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 13:40:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 13:50:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 14:00:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 14:10:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 14:20:00'	1381	1036	1121	912	807	484	763	1289	602	183	1114	
'2015/10/06 14:30:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 14:40:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 14:50:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 15:00:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 15:10:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 15:20:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 15:30:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 15:40:00'	1381	1036	1121	912	807	484	763	1289	602	183	NaN	
'2015/10/06 15:50:00'	1381	1036	1121	912	807	484	763	1289	602	183	1115	
'2015/10/06 16:00:00'	1381	1036	1121	912	807	484	763	1289	602	183	1115	

ตารางที่ 7 การจัด Attribute ให้กับข้อมูล

หลังจากจัด Attribute ให้กับข้อมูลแล้วขั้นตอนต่อไปให้แบ่ง Class ให้กับ NAN period ทั้งหมด 4 Class โดยแยกตามจำนวนของ NAN time ใน NAN period โดยที่ Class 4 จะเป็น Class ที่

มี NAN time มากที่สุด ซึ่งส่งผลถึงระยะเวลาการซ่อมบำรุงที่นานที่สุดเช่นกัน และเราจะทำการหา Event code ที่เกิดขึ้นและส่งผลต่อ Class 4 เมื่อเราพบ Event code ที่มีผลต่อ Long Period Maintenance มากที่สุดให้ทำการนับจำนวนของ Event code ที่เกิดขึ้นและบันทึกไว้

โครงสร้างของ Model ทั้งหมดจะมี 2 Layers ของ CNN เพื่อแยก Features ที่เกี่ยวข้อง ออกมาพร้อมทั้งนำ Features ที่แยกออกมาได้นั้น ไปเป็น Input ให้กับ RBF-SVM (Radial Basis Function) โดยสรุปแล้วจะได้ Input ทั้งหมด 6 Features ด้วยกันคือ Wind speed, power output of the wind turbines, oil temperature for the wind turbine gearbox, temperature of the high-speed bearings, จำนวนครั้งของ Short NAN periods และความถี่ของ Event code ที่เกิดขึ้น



รูปที่ 28 Flow chart โดยละเอียดของงานวิจัย

ผลลัพธ์ที่ได้จากการทำ Prediction Long Period Maintenance ถูกแบ่งออกเป็น

Class	Accuracy
2	95%
3	92%
4	87%
5	84%
6	76%
7	77%
8	76%
9	73%

รูปที่ 29 ผลลัพธ์ของงานวิจัย


โดย Class ต่างๆ หมายถึงการที่สมมติให้ระยะเวลาในการซ่อมทั้งหมด คือ 900 วัน และเลข Class คือเลขที่นำไปแบ่งเช่นถ้าเป็น Class 2 คือ 0-450 วันเป็นช่วงเวลาซ่อมหนึ่งและ 451-900 เป็นอีกช่วงเวลาซ่อมหนึ่ง ส่วน Class 9 ก็จะแบ่งออกได้ 9 ส่วนคือ 0-100, 101-200, ..., 801-900 จากผลของ Accuracy ที่ได้จะเห็นได้ว่ายิ่งแบ่งช่วงเวลาของ Long Period Maintenance มากเท่าไรค่าของ Accuracy ก็จะยิ่งลดลงเท่านั้น

3.3 Predicting Remaining Useful Life of Rotating Machinery Based Artificial Neural Network

งานวิจัยของ Abd Kadir Mahamad, Sharifah Saon และ Takashi Hiyama สำหรับการนำ Artificial Neural Network (ANN) มา Predict Remaining Useful Lifetime (RUL) สำหรับ Rotating machinery

ในปัจจุบันโรงงานอุตสาหกรรมมีการนำ Predict การทำงานของเครื่องจักรมากขึ้นเพื่อเพิ่มประสิทธิภาพของกระบวนการผลิต และเพิ่มประสิทธิภาพการซ่อมบำรุง หรือ Condition Based Maintenance (CBM) โดยงานวิจัย [7] ได้มีการนำ Artificial Neural Network (ANN) แบบ Feed forward เพื่อหาระยะเวลาที่เครื่องจักรยังสามารถทำงานได้ หรือ Remaining Useful Lifetime (RUL) ของ Bearing Failure


ซึ่ง Bearing เป็นอุปกรณ์ที่มีความสำคัญอย่างมากของเครื่องจักรที่มีเพลลาหมุน ถ้าหากตัว Bearing แตกก็จะทำให้โลหะกระทบกันและเกิดเป็นเพลิงไหม้ได้



รูปที่ 30 ตำแหน่งของ Bearing ในเครื่องจักร

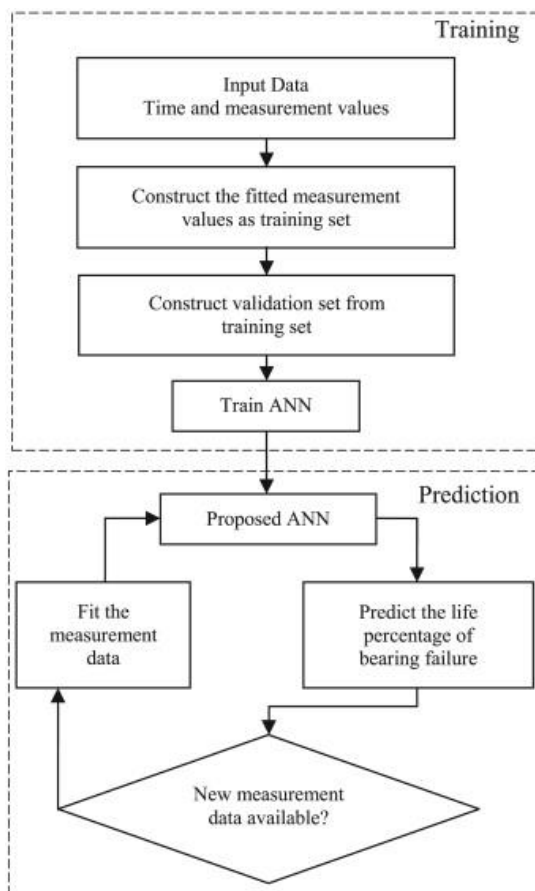
การตรวจหา Vibration ของลูกปืนสามารถบ่งบอกค่าที่แสดงถึงการเสื่อมสภาพของลูกปืนได้ ค่าที่วัดได้สองค่าที่เกี่ยวข้องกับ Bearing failure นั่นก็คือ RMS (Root Mean Square) และ Kurtosis เมื่อได้ค่าทั้งสองมาแล้วให้ทำการ Feed input เข้าไปใน Model ของ Feed Forward Neural Network โดยค่า Input ที่ใช้ทั้งหมด 6 features ด้วยกันคือ 1. เวลาปัจจุบัน, 2. เวลาในก่อนหน้า, 3. ค่า RMS

ปัจจุบัน, 4. ค่า RMS ก่อนหน้านี้, 5. ค่า Kurtosis ปัจจุบัน และ 6. ค่า Kurtosis ก่อนหน้านี้ และ ได้รับ Output ออกมาเป็น Life Percentage ที่ผ่านการ Normalized มาแล้ว




รูปที่ 31 Feature ที่ใช้เป็น Input ทั้งหมด

และนี่คือ Cycle ทั้งหมดในการทำ Predictive model ให้กับ Bearing Failure



รูปที่ 32 Flow chart การทำ Predictive model

ผลลัพธ์จากการทดลองนี้จะเห็นได้ว่าค่าที่เป็น Actual และค่าที่ Predict ได้นั้นแทบจะเป็น 100%



รูปที่ 33 การเปรียบเทียบระหว่าง Actual และ Prediction



2924680901

บทที่ 4 แนวคิดและวิธีการวิจัย

เบื้องต้นได้มีความคิดที่จะนำเสนอเป็นตัวเลขอายุการใช้งานที่เหลือของเครื่องจักรออกมา เพื่อดูระยะเวลาในการเข้าไปซ่อมอุปกรณ์ที่เหมาะสม แต่ถ้าหากนำ Model ดังกล่าวไปใช้งานจะไม่สามารถตอบ โจทย์ของผู้ใช้งานได้ เนื่องจากสิ่งที่ซ่อมบำรุงต้องการรู้ไม่ใช่ระยะเวลาที่เหลือ แต่เป็นสัญญาณที่จะบอกให้เข้าไปซ่อมแซมอุปกรณ์มากกว่า นั้นหมายความว่าต่อให้ระยะเวลาเครื่องจักร เหลือหนึ่งวันหรือเจ็ดวันก็ไม่ต่างกัน เพราะไม่สามารถซ่อมอุปกรณ์ได้ทันเวลา ดังนั้นแนวคิดหลัก ของงานวิจัยนี้คือ หาสัญญาณที่คอยแจ้งเตือนฝ่ายซ่อมบำรุงให้เข้าทำงาน

4.1 ทำการเก็บรวบรวมข้อมูลจากเครื่อง Total Organic Analyzer (TOC)

จากโรงงานทั้งหมด 2 เครื่อง โดยระยะเวลาในการเก็บข้อมูลคือ ระยะเวลา 6 เดือนตั้งแต่ มกราคม 2563 จนถึง มิถุนายน 2563 โดยเครื่องจากโรงทั้ง 2 เครื่องนี้เป็นยี่ห้อเดียวกันและ Model เดียวกันรวมไปถึงสารที่เครื่องที่ได้ทำการวัดก็เป็นสารเดียวกัน



รูปที่ 34 เครื่อง Total Organic Carbon analyzer

4.2 File ที่ได้จาก Notepad

ข้อมูลที่ได้จากเครื่อง TOC analyzer นั้นจะเป็นไฟล์ Notepad โดยภายในไฟล์ Notepad นั้น จะมีค่าที่บันทึกจากเซนเซอร์ภายในเครื่องจำนวนมาก แต่ทางผู้ทำการวิจัยไม่สามารถทราบ ความหมายได้ จึงได้ทำการปรึกษากับทางเจ้าของเครื่อง TOC analyzer

1	23:54:45	6/5/2019	-6	518.61	718.73	9999.99	54.34	61.71
2	0:05:25	6/6/2019	-5	528.18	718.42	9999.99	54.83	61.85
3	0:16:18	6/6/2019	-5	537.93	724.1	9999.99	54.99	62.11
4	0:27:07	6/6/2019	-4	531.56	730.01	9999.99	54.22	62.05
5	0:37:49	6/6/2019	-5	526.67	729.33	9999.99	53.97	61.68
6	0:48:17	6/6/2019	-4	519.78	721.04	9999.99	54.02	61.25
7	0:58:54	6/6/2019	-5	527.34	719.12	9999.99	54.05	61.18
8	1:09:35	6/6/2019	-5	527.55	719.53	9999.99	53.45	60.95

รูปที่ 35 ข้อมูลที่ได้จาก Notepad

4.3 การ Import file

หลังจากปรึกษาเจ้าของเครื่องจึงได้มีการ Import file ของ Notepad ให้มาอยู่ภายใน File Excel เพื่อให้ง่ายต่อการ Filter หาข้อมูล

TIME	DATE	CO2z	TICmgu	TICmgc	TICmgu/TI	CO2p	TOCmgu	TOCmgc	Rate (TOCmgu/TOCmgc)	CO2t	DegC	Atm
9:47:11	4/30/2020	-11	615.34	747.66	0.82	9999.99	49.61	53.12	0.93	1290	40	100.9
9:36:28	4/30/2020	-11	616.77	747.91	0.82	9999.99	49.16	53.47	0.92	1296	40	100.9
9:25:49	4/30/2020	-12	611.04	743.27	0.82	9999.99	50.16	53.72	0.93	1314	39.9	100.9
9:14:53	4/30/2020	-12	615.89	741.33	0.83	9999.99	50.51	54.59	0.93	1303	39.9	100.9
9:04:16	4/30/2020	-12	605.3	737.99	0.82	9999.99	49.81	54.45	0.91	1277	39.9	100.9
8:54:41	4/30/2020	-11	605.54	745.16	0.81	9999.99	52.32	54.57	0.96	1374	39.9	100.8
8:43:51	4/30/2020	-11	606.92	750.07	0.81	9999.99	50.09	53.97	0.93	1300	39.9	100.8
8:32:52	4/30/2020	-11	622.23	749.15	0.83	9999.99	50.07	54.15	0.92	1317	39.9	100.8
8:18:59	4/30/2020	-12	617.63	745	0.83	9999.99	50.78	54.25	0.94	1341	39.9	100.8

ตารางที่ 8 ข้อมูลหลังจากการ Import

ภายในแต่ละ Column มีที่มาแตกต่างกัน โดยเซนเซอร์แต่ละเซนเซอร์ที่วัดค่าได้มีดังนี้

- 1) Date: วันที่ที่ค่าถูกบันทึก
- 2) Time: เวลาที่ค่าถูกบันทึก
- 3) TICmgu: ค่าของ Total Inorganic Carbon ในสารก่อน Calibrate
- 4) TICmgc: ค่าของ Total Inorganic Carbon ในสารหลัง Calibrate
- 5) CO2p: ค่าปริมาณของคาร์บอนไดออกไซด์ก่อนที่เครื่องจะทำงาน
- 6) TOCmgu: ค่าของ Total Organic Carbon ในสารก่อน Calibrate
- 7) TOCmgc: ค่าของ Total Organic Carbon ในสารหลัง Calibrate
- 8) CO2p.1: ค่าปริมาณของคาร์บอนไดออกไซด์หลังจากที่เครื่องทำงาน
- 9) DegC: ค่าอุณหภูมิ ณ ขณะที่เครื่องทำการเก็บค่า
- 10) Atm: ค่าความดันบรรยากาศของเครื่อง ณ ขณะที่วัด
- 11) Sample: ปริมาณ Sample ในระบบ
- 12) Sample pump operation mode: บอกสถานะของ Sample pump
- 13) Sample pump number of pulses: จำนวนครั้งที่ Sample pump ทำงาน
- 14) Sample pump time for operation (ms): เวลาทั้งหมดที่ Sample pump ทำงาน

- 15) Sample pump time for last pulse (ms): เวลาที่ใช้ก่อนที่ Sample pump จะถึงการทำงานครั้งสุดท้าย
- 16) Sample pump error counter: บอกจำนวนครั้งที่ Sample pump ไม่ทำงาน
- 17) Acid pump operation mode: บอกสถานะของ Acid pump
- 18) Acid pump number of pulses: จำนวนครั้งที่ Acid pump ทำงาน
- 19) Acid pump time for operation (ms): เวลาทั้งหมดที่ Acid pump ทำงาน
- 20) Acid pump time for last pulse (ms): เวลาที่ใช้ก่อนที่ Acid pump จะถึงการทำงานครั้งสุดท้าย
- 21) Acid pump error counter: บอกจำนวนครั้งที่ Acid pump ไม่ทำงาน
- 22) Base pump operation mode: บอกสถานะของ Base pump
- 23) Base pump number of pulses: จำนวนครั้งที่ Base pump ทำงาน
- 24) Base pump time for operation (ms): เวลาทั้งหมดที่ Base pump ทำงาน
- 25) Base pump time for last pulse (ms): เวลาที่ใช้ก่อนที่ Base pump จะถึงการทำงานครั้งสุดท้าย
- 26) Base pump error counter: บอกจำนวนครั้งที่ Base pump ไม่ทำงาน

4.4 ข้อมูล Error log

จากข้อมูลทั้งหมดในข้อ 4.3 จะสังเกตได้ว่าค่าทั้งหมดไม่มี Parameter ที่บ่งบอกสถานะของเครื่อง ได้เลยว่าจะช่วงเวลาใดที่เครื่องทำงานปกติ ช่วงเวลาใดที่เครื่องใกล้จะมีปัญหา จึงต้องนำข้อมูลทั้งหมดมาคู่กับ Error log ที่ได้บันทึกไว้ภายในตัวเครื่อง (Error log คือ ชุดข้อมูลที่ใช้บอกผู้ซ่อมแซมอุปกรณ์ว่าเครื่อง TOC Analyzer นั้น ได้มีปัญหาเกิดขึ้นช่วงเวลาใด) ลักษณะของ Error Log จะมีวันที่และเวลาที่เครื่องเกิด Error ขึ้น

```

FAULT ARCHIVE
01:09:52 23-11-19 [01:36:44 23-11-19] 20_NO REAGENTS
01:09:52 23-11-19 [01:36:46 23-11-19] 85_LOW REAGENTS
21:53:20 22-11-19 [01:08:56 23-11-19] 20_NO REAGENTS
21:53:20 22-11-19 [01:08:57 23-11-19] 85_LOW REAGENTS
13:11:48 08-11-19 [21:50:03 22-11-19] 20_NO REAGENTS

```

รูปที่ 36 ข้อมูลที่ได้จาก Error log

4.5 Import Data และ Error log

เมื่อนำข้อมูลทั้ง Data จากเครื่อง TOC analyzer และ Data จาก Error log มาใส่ไว้ใน File เดียวกันจะ
ได้ลักษณะของข้อมูลภายใน Excel ตามภาพด้านล่าง

Time	Date	TICmgu	TICmgc	CO2p	.	.	.	S18
10:16:12	6/25/2019	569.16	577.28	9976	.	.	.	0
10:05:09	6/25/2019	581.8	590.11	9972	.	.	.	0
04:33:58	6/25/2019	SAMPLE VALVE SENSOR 3 FAILED						
04:15:17	6/25/2019	570.77	579.29	9986	.	.	.	0
04:05:46	6/25/2019	568.38	578.09	9982	.	.	.	0

ตารางที่ 9 ข้อมูลหลังจากการ Import Data และ Error log

4.6 ทำการเปลี่ยนข้อมูล Time และ Date

เปลี่ยน Time และ Date ภายใน Data ให้เป็น Operation และ Number of Cycle ซึ่งความหมายของ
- Operation คือ เลขที่ที่เครื่อง TOC analyzer ทำงานตั้งแต่เริ่มต้น จนถึงอุปกรณ์พังเสียหาย เช่น
เครื่องเริ่ม Start ใหม่นับเป็น Operation ที่ 1 จนกระทั่งเครื่องพังเสียหาย เมื่อทำการ Start เครื่องใหม่
จึงจะนับเป็น Operation ที่ 2
- Number of Cycle คือ จำนวน Cycle ที่สามารถทำงานได้ใน 1 Operation จากข้อมูลของเครื่อง
TOC analyzer ที่เก็บมาได้พบว่าใน 1 Operation จะมีการบันทึก Cycle ทุกๆ 15 นาที ทำให้ใน 1
Operation สามารถมี Number of Cycle ได้เป็นจำนวนมากถ้าเครื่องสามารถใช้งานได้นาน

Machine	Number of cycle
1	2553
1	2554
1	2555
1	2556
1	2557
2	1
2	2
2	3
2	4
2	5

← จุดที่อุปกรณ์
พังเสียหาย

รูปที่ 37 วิธีการนับ Machine และ Number of Cycle

4.7 จากหัวข้อ 4.6 ทำให้ Data ของเราเปลี่ยนไปเป็นดังรูปด้านล่าง

Operation	Cycle	TICmgu	TICmgc	CO2p	.	.	.	S18
2	2	569.16	577.28	9976	.	.	.	0
2	1	581.8	590.11	9972	.	.	.	0
SAMPLE VALVE SENSOR 3 FAILED								
1	2040	570.77	579.29	9986	.	.	.	0
1	2039	568.38	578.09	9982	.	.	.	0

ตารางที่ 10 ข้อมูลหลังจากการเปลี่ยนวันและเวลา

4.8 การหา Remaining Useful Lifetime

เมื่อได้ข้อมูลในรูปแบบของ Operation และ Cycle ออกมาแล้วให้เราทำการคำนวณหา Remaining Useful Lifetime ของเครื่อง TOC analyzer ซึ่งถ้าเราทราบปริมาณ Cycle ที่เครื่องสามารถทำงานได้มากที่สุด ใน Operation นั้นๆเป็นเท่าไร ก็จะสามารถหาได้ว่าเครื่องเหลือระยะเวลาที่สามารถทำงานได้ที่ Cycle ก่อนที่เครื่องจะพังเสียหาย

$$RUL = \text{Max cycle ของ Operation} - \text{cycle ของ Operation}$$

รูปแบบของข้อมูลจะมี Column ใหม่เพิ่มเข้ามาซึ่งเป็น Column ของ Remaining Useful Lifetime

Operation	Cycle	TICmgu	TICmgc	CO2p	.	.	.	S18	RUL
2	2	569.16	577.28	9976	.	.	.	0	5570 - 2 = 5568
2	1	581.8	590.11	9972	.	.	.	0	5570 - 1 = 5569
SAMPLE VALVE SENSOR 3 FAILED									
1	2040	570.77	579.29	9986	.	.	.	0	2040 - 2040 = 0
1	2039	568.38	578.09	9982	.	.	.	0	2040 - 2039 = 1

ตารางที่ 11 วิธีการคำนวณ Remaining Useful Lifetime

4.9 การทำ Classification

เมื่อทราบระยะเวลาที่เหลือที่เครื่องจักรสามารถทำงานได้ ก็จะทำการ Classification RUL ให้เป็น Class ต่างๆ โดยการจัด Classification จะใช้ประสบการณ์ที่ได้รับมาจากทีมงานซ่อมบำรุง และ Vendor ผู้ที่ทำการขายเครื่องจักรให้กับทางโรงงาน โดย

Class 1 จะมี Remaining Useful Lifetime $\geq 1,920$ Cycle

Class 2 จะมี Remaining Useful Lifetime ที่ระหว่าง 1,344 – 1,919 Cycle

Class 3 จะมี Remaining Useful Lifetime \leq 1343 Cycle

สาเหตุที่มาของ Range จำนวนของ Cycle ในแต่ละ Class นั้นมีความหมายดังต่อไปนี้

Class 1 หมายถึงเครื่องจักรสามารถทำงานได้มากกว่าหรือเท่ากับ 1,920 Cycle นั้น

หมายความว่า ถ้าหากเครื่อง TOC analyzer ใช้เวลาทำงาน Cycle ละ 15 นาที

ภายในเวลา 1 ชั่วโมง \rightarrow เครื่อง TOC analyzer ทำงานได้ 4 Cycle

ภายในเวลา 1 วัน \rightarrow เครื่อง TOC analyzer ทำงานได้ 96 Cycle

ภายในเวลา 20 วัน \rightarrow เครื่อง TOC analyzer ทำงานได้ 1,920 Cycle

ซึ่งระยะเวลา 20 วันขึ้นไป เป็นระยะเวลาที่ได้คุยกับทีมงานรวมไปถึง Vendor ที่ Supply เครื่อง TOC analyzer และตกลงร่วมกันว่าเครื่องจักรสามารถทำงานได้ปกติ ทีมงานซ่อมบำรุงยังไม่มีหน้าที่ต้องเข้าไปทำอะไรหน้างาน Class 1 จึงสามารถเรียกอีกชื่อได้ว่า Class “Healthy”

Class 2 หมายถึงเครื่องจักรทำงานได้เพียง 1,344 Cycle ถึง 1,919 Cycle ถ้าหากคิดระยะเวลาเป็นวันนั้นก็คือ 14 วันถึง 20 วันเป็นระยะเวลาที่ได้คุยกับทีมงานรวมไปถึง Vendor ที่ Supply เครื่อง TOC analyzer และตกลงร่วมกันว่า สามารถสั่ง Spare part เพื่อมาซ่อมแซมเครื่องจักรได้ทันเวลา โดยตัวเลขนี้แบ่งเป็นสั่งทำของ 14 วันและขนส่งอีก 5 วัน เมื่อได้ Spare part มาทีมงานต้องรีบทำการนำ Spare part ที่ได้เข้าไปเปลี่ยน สามารถเรียก Class นี้ชื่อหนึ่งได้ว่า Class “Need maintenance”

Class 3 หมายถึงเครื่องจักรสามารถทำงานได้น้อยกว่า 1,344 Cycle คิดเป็นตัวเลข 1,344 Cycle เป็นวันก็คือน้อยกว่า 14 วัน ถ้าหากมีการทำ Prediction ได้ Class นี้ขึ้นมาแสดงว่าการสั่ง Spare part จากผู้รับเหมาไม่สามารถทำได้ทันการมีหนทางแก้ไขคือ มีการประชุมกับทีมงานฝ่ายผลิตเพื่อจัดเตรียมแผนการสำหรับรับมือกับปัญหาที่อาจจะเกิดขึ้นเมื่อเครื่องจักรเสียหาย Class นี้สามารถเรียกอีกชื่อหนึ่งได้ว่า Class “Breakdown”

เพิ่ม Column ด้านหลังเป็น Result ของการ Classification ตามหัวข้อที่ 4.9 จะเห็นได้ว่าจากข้อมูล Input Column TICmgv จนถึง Column S18 จะใช้ในการทำ Prediction โดยมี Output เป็น Class 1,2 และ 3

Operation	Cycle	TICmgu	TICmgc	CO2p	.	.	.	S18	RUL	Class	Remark
2	2	569.16	577.28	9976	.	.	.	0	$5570 - 2 = 5568$	1	Healthy
2	1	581.8	590.11	9972	.	.	.	0	$5570 - 1 = 5569$	1	Healthy
SAMPLE VALVE SENSOR 3 FAILED											
1	2040	570.77	579.29	9986	.	.	.	0	$2040 - 2040 = 0$	3	Breakdown
1	2039	568.38	578.09	9982	.	.	.	0	$2040 - 2039 = 1$	3	Breakdown

ตารางที่ 12 วิธีการระบุ Classification

4.10 ทำการ Normalization Input data

เนื่องจาก Input Data ในงานวิจัยนี้มีลักษณะของข้อมูลที่ต่างกันเป็นจำนวนมากบาง Column มีค่าที่วัดได้จากเซนเซอร์มากถึง 9999 ในขณะที่อีก Column หนึ่งมีข้อมูลเพียงหลักสิบ หลักร้อย หากนำ Data Input ที่ไม่ได้มีการทำ Normalization เข้าไป Training จะทำให้ Model เกิดการ Bias ขึ้น ดังนั้นจึงต้องทำการ Normalization ข้อมูลดังกล่าวขึ้น


Operation	Cycle	TICmgu	TICmgc	CO2p	.	.	.	S18	RUL	Class	Remark
2	2	0.174699	0.170164	0.95774	.	.	.	0	$5570 - 2 = 5568$	1	Healthy
2	1	0.176274	0.170527	0.97309	.	.	.	0	$5570 - 1 = 5569$	1	Healthy
SAMPLE VALVE SENSOR 3 FAILED											
1	2040	0.174313	0.171046	0.95994	.	.	.	0	$2040 - 2040 = 0$	3	Breakdown
1	2039	0.173509	0.170086	0.94955	.	.	.	0	$2040 - 2039 = 1$	3	Breakdown

ตารางที่ 13 ข้อมูลหลังการทำ Normalization

จากตารางด้านบนนี้คือลักษณะของข้อมูลที่จะใช้ในการ Training และ Testing Prediction Model ของงานวิจัยนี้

4.1.1 รูปแบบการทำ Predictive Remaining Useful Lifetime

จะใช้ Neural Network แบบ Deep learning เพื่อหาระยะเวลาที่อุปกรณ์สามารถทำงานได้




รูปที่ 38 แนวคิดการสร้าง Model Neural network ในงานวิจัยนี้

บทที่ 5 ผลการทดลอง

ในงานวิจัยนี้ได้มีการทดลอง 3 รูปแบบด้วยกัน คือ

- ผลการวิจัยแบบปกติ
- ผลการวิจัยที่ใช้ Input จาก Operation Extraction
- ผลการวิจัยที่ใช้ Input จาก Correlation matrix ที่ใช้ Data ที่เกี่ยวข้องกับงานซ่อม

โดย Process การทำงาน ของ Model training จะเป็นไปตามภาพด้านล่างนี้



รูปที่ 39 Flow chart สำหรับงานวิจัย

5.1 ผลการวิจัยแบบปกติ

คือการใช้ Input Data ทั้งหมด 24 Features โดยยังไม่ได้ผ่าน Features Extraction

กำหนด Input Layer: 24 Features

Hidden Layer 1: 15 neurons, Activation = Relu

Hidden Layer 2: 15 neurons, Activation = Relu

Hidden Layer 3: 15 neurons, Activation = Relu

Output layer: 3 neurons, Activation = Softmax

Optimizer: Adam

Epoch = 150

Loss = Sparse_categorical_crossentropy

Amount of Data = 49,024 data → Training data = 39,219 data + Testing data = 9805 data

Result


Confusion Matrix:
 [[3329 418 114]
 [714 3861 72]
 [780 264 253]]

Accuracy: 75.9%
 Precision: 75.1%
 Recall: 75.9%

Classification Report:

	precision	recall	f1-score	support
Healthy	0.69	0.86	0.77	3861
Need maintenance	0.85	0.83	0.84	4647
Breakdown	0.58	0.20	0.29	1297
accuracy			0.76	9805
macro avg	0.71	0.63	0.63	9805
weighted avg	0.75	0.76	0.74	9805

รูปที่ 40 ผลลัพธ์ของการวิจัยแบบปกติ



รูปที่ 41 Confusion matrix ของการวิจัยแบบปกติ

5.2 ผลการวิจัยที่ใช้ Input จาก Operation Extraction

หลังจากผลลัพธ์ในงานวิจัยที่ 5.1 สามารถทำการ Prediction ได้ต่ำกว่าเป้าหมายที่วางไว้ ดังนั้น เพื่อที่จะเพิ่ม Accuracy ของการ Prediction จึงได้มีการสอบถามทีมงานเรื่องของ Data ที่นำมาใช้

พบว่าเมื่อได้มีการวิเคราะห์ร่วมกับทีมงานข้อมูลบาง Operation 1 ไม่ได้เป็นข้อมูลที่เครื่องจักรทำงานอยู่ แต่เป็นช่วงเวลาที่เครื่องจักรกำลัง Test Run เพื่อทดสอบระบบหลังซ่อม หรืออาจจะเป็นช่วงเวลาที่เครื่องจักร Run แบบไม่ได้มีการใช้งานจริง ซึ่งมีสาเหตุมาจากการซ่อมบำรุงใหญ่ภายในโรงงาน ดังนั้นเพื่อให้การ Prediction แม่นยำขึ้นจึงต้องคัดเพียง Cycle ที่มีการใช้งานจริงๆ เท่านั้น

Operation	MaxCycleID		
0	1	2557	
1	2	25	ทดสอบ Run ระบบ
2	3	5507	
3	4	261	ทดสอบ Run ระบบ
4	5	468	ทดสอบ Run ระบบ
5	6	12768	ระบบไม่ได้มีการใช้งาน
6	7	18	ทดสอบ Run ระบบ
7	8	1399	ทดสอบ Run ระบบ
8	9	6371	
9	10	3606	
10	11	1718	ระบบไม่ได้มีการใช้งาน
11	12	1351	ระบบไม่ได้มีการใช้งาน
12	13	2021	
13	14	558	ทดสอบ Run ระบบ
14	15	1864	ทดสอบ Run ระบบ
15	16	1964	ทดสอบ Run ระบบ
16	17	555	ทดสอบ Run ระบบ
17	18	3093	
18	19	2775	

รูปที่ 42 การตัด Operation ที่ไม่เกี่ยวข้องกับงานวิจัย

- กำหนด
- Input Layer: 24 Features
 - Hidden Layer 1: 15 neurons, Activation = Relu
 - Hidden Layer 2: 15 neurons, Activation = Relu
 - Hidden Layer 3: 15 neurons, Activation = Relu
 - Output layer: 3 neurons, Activation = Softmax

Optimizer: Adam

Epoch = 150

Loss = Sparse_categorical_crossentropy

Amount of Data = 25,955 data → Training data = 20,764 data + Testing data = 5191 data

Result


Confusion Matrix:
 [[1418 323 99]
 [225 2294 16]
 [431 182 203]]

Accuracy: 75.4%
 Precision: 74.3%
 Recall: 75.4%

Classification Report:

	precision	recall	f1-score	support
Healthy	0.68	0.77	0.72	1840
Need maintenance	0.82	0.90	0.86	2535
Breakdown	0.64	0.25	0.36	816
accuracy			0.75	5191
macro avg	0.71	0.64	0.65	5191
weighted avg	0.74	0.75	0.73	5191


รูปที่ 43 ผลลัพธ์ของการวิจัยแบบ Input จาก Operation Extraction



รูปที่ 44 Confusion matrix ของการวิจัยแบบ Input จาก Operation Extraction

5.3 ผลการวิจัยที่ใช้ Input จาก Correlation matrix เพื่อทำ Feature Extraction

ที่เกี่ยวข้องกับงานซ่อม เมื่อทดลองงานวิจัยด้วยการคัดแต่ Operation ที่ใช้งานจริงมาเป็น Input data เท่านั้น พบว่าผลลัพธ์ที่ได้มีความใกล้เคียงกับงานวิจัยที่ 5.1 ดังนั้นในการวิจัยรอบนี้จะทำการคัดแต่ Feature ที่สำคัญจาก 24 Features มาเพื่อทำการ Training Model แทน โดยใช้ Correlation matrix



รูปที่ 45 Correlation matrix ของแต่ละ Feature

โดยสามารถดูความสัมพันธ์จากความเข้มของสีภายใน Confusion Matrix ถ้าหากความเข้มของสีมีปริมาณมากจะมีผลต่อค่า Remaining Useful Lifetime มาก (สีน้ำเงินเข้มหมายถึงแปรผันตรง, สีส้ม หมายถึงแปรผกผัน) สามารถสรุปได้ว่า Parameter ที่มีผลต่อ Remaining Useful Lifetime มีดังต่อไปนี้

1. TICmgu: ค่าของ Total Inorganic Carbon ในสารก่อน Calibrate
2. TICmgc: ค่าของ Total Inorganic Carbon ในสารหลัง Calibrate
3. TOCmgu: ค่าของ Total Organic Carbon ในสารก่อน Calibrate
4. TOCmgc: ค่าของ Total Organic Carbon ในสารหลัง Calibrate
5. CO2p.1: ค่าปริมาณของคาร์บอนไดออกไซด์หลังจากที่เครื่องทำงาน
6. S1: ค่าอุณหภูมิ ณ ขณะที่เครื่องทำการเก็บค่า

7. S2: ค่าความดันบรรยากาศของเครื่อง ณ ขณะที่วัด
8. S6: เวลาทั้งหมดที่ Sample pump ทำงาน
9. S7: เวลาที่ใช้ก่อนที่ Sample pump จะถึงการทำงานครั้งสุดท้าย
10. S11: เวลาทั้งหมดที่ Acid pump ทำงาน
11. S12: เวลาที่ใช้ก่อนที่ Acid pump จะถึงการทำงานครั้งสุดท้าย
12. S16: เวลาทั้งหมดที่ Base pump ทำงาน
13. S17: เวลาที่ใช้ก่อนที่ Base pump จะถึงการทำงานครั้งสุดท้าย

กำหนด Input Layer: 13 Features

Hidden Layer 1: 15 neurons, Activation = Relu

Hidden Layer 2: 15 neurons, Activation = Relu

Hidden Layer 3: 15 neurons, Activation = Relu

Output layer: 3 neurons, Activation = Softmax

Optimizer: Adam

Epoch = 150

Loss = Sparse_categorical_crossentropy

Amount of Data = 25,955 data → Training data = 20,764 data + Testing data = 5191 data

โดยเราจะใช้ Input data ทั้งหมดแบ่งออกเป็นชุดข้อมูล 2 ชุดคือ Training data 80% ของชุดข้อมูลทั้งหมด และ Testing data 20% ของข้อมูลทั้งหมด จะสามารถแบ่งข้อมูลในแต่ละ Class ออกได้ตามข้อมูลด้านล่าง

Categorical	Training Set	Testing Set
Healthy	7565	1840
Need Maintenance	9995	2535
Breakdown	3204	816
Total	20764	5191

ตารางที่ 14 ปริมาณของข้อมูลที่ใช้ในการ Training และ Testing

Result


Confusion Matrix:
 [[1543 224 73]
 [136 2332 67]
 [221 252 343]]

Accuracy: 81.3%
 Precision: 80.5%
 Recall: 81.3%

Classification Report:

	precision	recall	f1-score	support
Healthy	0.81	0.84	0.83	1840
Need maintenance	0.83	0.92	0.87	2535
Breakdown	0.71	0.42	0.53	816
accuracy			0.81	5191
macro avg	0.78	0.73	0.74	5191
weighted avg	0.81	0.81	0.80	5191

รูปที่ 46 ผลลัพธ์ของการวิจัยแบบ Input จาก Correlation matrix เพื่อทำ Feature Extraction



รูปที่ 47 Confusion matrix ของการวิจัยแบบ Input จาก Correlation matrix เพื่อทำ Feature Extraction

6. สรุปผลการวิจัย

เห็นได้อย่างชัดเจนว่าเมื่อมีการทำ Data cleaning ด้วย Feature extraction และคัดมาแต่ข้อมูลที่ใช้งานจริง ผลลัพธ์ที่ได้ในการทำ Prediction ก็ดีขึ้นอย่างชัดเจน โดยมีผลลัพธ์ที่

	Healthy	Need maintenance	Breakdown
Healthy	1543	224	73
Need maintenance	136	2332	67
Breakdown	221	252	343

ตารางที่ 15 จำนวนของข้อมูลภายใน Confusion matrix แต่ละ Class

จะเห็นได้ว่าผลลัพธ์จากการ Predict ด้วย Model ที่ผ่านการ Training มาแล้วเทียบกับผลลัพธ์ของ Test data ที่ทราบค่าอยู่แล้วมีค่าดังนี้

Healthy ทายถูกทั้งหมด 1543 จาก 1840 คิดเป็น Accuracy 84%

Need maintenance ทายถูกทั้งหมด 2203 จาก 2535 คิดเป็น Accuracy 92%

Breakdown ทายถูกทั้งหมด 343 จาก 816 คิดเป็น Accuracy 42%

จากผลการทดลองอ้างอิงจากรูปที่ 4 จะพบว่าค่า Precision, Recall และ F1-score ของ Class Healthy และ Need maintenance มีค่าที่สูงประมาณ 75% ขึ้นไป แต่ใน Class Breakdown นั้นมีค่าที่ต่ำมาก

จากผลการวิจัยพบว่าเมื่อนำ Model ดังกล่าวไปใช้ในการ Predict งานจริงๆ จะสามารถ Predict เครื่องจักร ได้ในช่วงการทำงานเหลือ 14 วันขึ้นไป ได้ดีที่ Accuracy 86% ซึ่งการ Predict ระยะเวลาที่เหลือได้มากกว่า 14 วันก็มากเพียงพอต่อการสั่งซื้ออะไหล่สำรองและจัดเตรียมกำลังพลสำหรับงานซ่อม ถึงแม้ว่าช่วงการ Predict class Breakdown จะเหลือความแม่นยำเพียง 42.64% แต่ก็ไม่ได้เป็นประเด็นสำคัญเนื่องจากระยะเวลาที่เหลือน้อยกว่า 14 วันทางทีมงานซ่อมไม่สามารถเตรียมอะไหล่สำรองได้ทันเวลาและได้ทำได้เพียงรอรับผลกระทบเท่านั้น

จากผลการวิจัยในครั้งนี้สามารถสรุปได้ว่า Model ที่ได้ทำการวิจัยมานั้นสามารถนำไปใช้งานในกระบวนการผลิตได้ เนื่องจากมี Accuracy รวมสูงถึง 80.5% ซึ่งด้วย Accuracy ที่สูงจะทำให้เราสามารถทำ Alarm แจ้งเตือนผู้ปฏิบัติงานให้สามารถจัดเตรียมแผนการทำงานที่จะเกิดขึ้นในอนาคต และลดผลกระทบจากการที่กระบวนการผลิตหยุดการผลิตลงจากงานที่ไม่ได้วางแผน

ในงานวิจัยนี้มีการกำหนด Output เพียง 3 Categories เท่านั้น คือ Healthy, Need Maintenance, Breakdown แต่ในความเป็นจริงงานวิจัยนี้สามารถพัฒนาต่อยอดไปได้อีก โดย

แผนการพัฒนาต่อไปคือจะให้ Output Categories มากกว่า 3 Categories ทำให้การแจ้งเตือนแต่ละครั้งเป็นการบอกได้เจาะจงมากขึ้น เช่น ใช้งานได้อีกกี่วัน ใช้งานได้อีกกี่สัปดาห์ ใช้งานได้อีกกี่เดือน ถ้าหากสามารถทำ RUL Prediction ได้ตามที่ได้อ้างมา กระบวนการผลิตก็จะมีประสิทธิภาพยิ่งขึ้น และไม่มีการซ่อมแซมแบบ Corrective maintenance อีกเลยก็เป็นได้



2924680901

CU Theslis 6270116021 thesis / recv: 02072564 00:00:45 / seq: 21

บรรณานุกรม

- [1] Berghout, Tarek, Leïla-Hayet Mouss, Toufik Bentrchia, Elhoussin Elbouchikhi, and Mohamed Benbouzid. "A Deep Supervised Learning Approach for Condition-Based Maintenance of Naval Propulsion Systems." *Ocean Engineering* 221 (2021): 108525.
- [2] Elasha, Faris, Suliman Shanbr, Xiaochuan Li, and David Mba. "Prognosis of a Wind Turbine Gearbox Bearing Using Supervised Machine Learning." *Sensors* 19, no. 14 (2019): 3092.
- [3] Kanawaday, Ameeth, and Aditya Sane. "Machine Learning for Predictive Maintenance of Industrial Machines Using Iot Sensor Data." Paper presented at the 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS), 2017.
- [4] Kimera, David, and Fillemon Nduvu Nangolo. "Predictive Maintenance for Ballast Pumps on Ship Repair Yards Via Machine Learning." *Transportation Engineering* 2 (2020): 100020.
- [5] Ordóñez, Celestino, Fernando Sánchez Lasheras, Javier Roca-Pardinas, and Francisco Javier de Cos Juez. "A Hybrid Arima–Svm Model for the Study of the Remaining Useful Life of Aircraft Engines." *Journal of Computational and Applied Mathematics* 346 (2019): 184-91.
- [6] Pootisirakorn, Miss Maylada. "Failure Prediction in Open-Hole Wireline Logging of Oil and Gas Drilling Operation Using Support Vector Machine." Chulalongkorn University, 2018.
- [7] Saon, Sharifah, and Takashi Hiyama. "Predicting Remaining Useful Life of Rotating Machinery Based Artificial Neural Network." *Computers & Mathematics with Applications* 60, no. 4 (2010): 1078-87.
- [8] Saxena, Abhinav, Kai Goebel, Don Simon, and Neil Eklund. "Damage Propagation Modeling for Aircraft Engine Run-to-Failure Simulation." Paper presented at the 2008 international conference on prognostics and health management, 2008.
- [9] Scalabrini Sampaio, Gustavo, Arnaldo Rabello de Aguiar Vallim Filho, Leilton Santos da Silva, and Leandro Augusto da Silva. "Prediction of Motor Failure Time Using an Artificial Neural Network." *Sensors* 19, no. 19 (2019): 4342.

- [10] Yeh, Chia-Hung, Min-Hui Lin, Chien-Hung Lin, Cheng-En Yu, and Mei-Juan Chen. "Machine Learning for Long Cycle Maintenance Prediction of Wind Turbine." *Sensors* 19, no. 7 (2019): 1671.



CU IThesis 6270116021 thesis / recv: 02072564 00:00:45 / seq: 21

2924690901

ประวัติผู้เขียน

ชื่อ-สกุล	Thanaphat Patravinij
วัน เดือน ปี เกิด	03 April 1991
สถานที่เกิด	Bangkok Thailand
วุฒิการศึกษา	King Mongkut's Institute of Technology Ladkrabang
ที่อยู่ปัจจุบัน	1999/78 Banfargreenpark village Ladphrao 101 Klongchan Bangkok Bangkok 10240



292469001

CD IThesis 6270116021 thesis / rev: 02072564 00:00:45 / seq: 21