

การทำนายความผิดพลาดระยะต้นของเครื่องวิเคราะห์อินทรีย์คาร์บอนโดยการเรียนรู้เชิงลึก

Prediction of Early Failure of TOC Analyzer using Deep Learning

ธนาภัทร ภัทรวิณี¹ ประภาส จงสถิตย์วัฒนา
Thanaphat Patravini¹, Prabhas Chongstitvatana

^{*1} คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

*ผู้รับผิดชอบบทความ โทรศัพท์ 08-1907-1247 อีเมลล์: 6270116021@student.chula.ac.th

บทคัดย่อ

การทำนายระยะเวลาของเครื่อง Total Organic Carbon Analyzer ก่อนที่จะเสีย มีความสำคัญเนื่องจากเครื่องดังกล่าวมีความสำคัญต่อกระบวนการผลิต Chlorine โดยใช้น้ำเกลือเป็นวัตถุดิบหลักเป็นอย่างมากภายในกระบวนการผลิตนั้นจะต้องนำน้ำเกลือมาตรวจสอบที่เครื่อง Total Organic Carbon Analyzer ก่อนเสมอ เพราะ Total Organic Carbon นั้นสามารถเข้าไปอุดตันในกระบวนการผลิตจนกระทั่ง Membrane มีปัญหา ถ้าน้ำเกลือมีค่า Total Organic Carbon สูง ทางโรงงานจะทำการกำจัดน้ำเกลือดังกล่าวทั้งหมด ดังนั้นถ้าสามารถคำนวณเวลาซ่อมได้อย่างแม่นยำ ก็จะลดความเสี่ยงในการสูญเสียโอกาสในการผลิตลงได้ ภายในประกอบไปด้วยเซนเซอร์จำนวนมากเพื่อทำการวัดค่าในระหว่างการผลิต ซึ่งค่าที่สามารถวัดได้จากเซนเซอร์ภายในมีมากถึง 26 ค่าด้วยกัน การเก็บข้อมูลของเครื่องจะจัดเก็บโดยหนึ่ง Cycle จะใช้เวลาเก็บทุกๆ 15 นาที เริ่มนับปริมาณ Cycle ใหม่ทุกครั้งที่เครื่องมีการหยุดซ่อมเนื่องจากพังเสียหาย นำปริมาณ Cycle ทั้งหมดของเครื่องในหนึ่งรอบการทำงานมาคำนวณหา Remaining Useful Lifetime (RUL) ได้ แบ่งเป็น Class 0, 1 และ 2 เพื่อใช้แจ้งเตือนผู้ใช้งาน นำค่าจากเซนเซอร์ทุกๆ Cycle ไปเรียนรู้ด้วย Deep Learning และทำ Classification โดยผลลัพธ์ที่ได้มีความแม่นยำ 80.5%

คำสำคัญ: total organic carbon analyzer, failure prediction, deep learning

ABSTRACT

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 80.5%.

Keywords: total organic carbon analyzer, failure prediction, deep learning

1. บทนำ

ในโรงงานอุตสาหกรรมปิโตรเคมีประกอบไปด้วยอุปกรณ์วัดค่าต่างๆมากมาย เพื่อให้กระบวนการผลิตสามารถดำเนินการผลิตได้อย่างต่อเนื่อง ปลอดภัย และตรงตามความต้องการของตลาด เมื่ออุปกรณ์วัดค่าเหล่านี้เสียหาย ทางโรงงานจะต้องจัดหาทีมงานเพื่อเข้าไปซ่อมแซมอุปกรณ์ให้เร็วที่สุด เพื่อให้กระบวนการผลิตสามารถผลิตต่อโดยไม่ต้องหยุดการผลิตเป็นเวลานาน เพราะการหยุดผลิตนั้นหมายถึงการเสียโอกาสในการทำกำไรไปอย่างมหาศาล ในทางอุดมคตินั้นโรงงานอุตสาหกรรมคาดหวังให้อุปกรณ์วัดค่าเหล่านี้สามารถทำงานได้ตลอดเวลา แต่ในความเป็นจริงเมื่อใช้งานอุปกรณ์วัดค่าเหล่านี้ต่อเนื่องเป็นเวลานาน ก็มีโอกาสพังเสียหายได้เป็นเรื่องปกติ ดังนั้นทุกโรงงานจึงต้องมีผู้ที่ทำหน้าที่ซ่อมแซมอุปกรณ์วัดค่าเหล่านี้เรียกว่า วิศวกรซ่อมบำรุง หรือ Maintenance Engineer นั่นเอง

หน้าที่ของวิศวกรซ่อมบำรุงหลักๆ คือ การซ่อมอุปกรณ์ให้กลับมาใช้งานได้ใหม่ให้เร็วที่สุด แต่ ณ ปัจจุบันรูปแบบของการซ่อมแซมอุปกรณ์จะมีการแบ่งประเภทออกไป ทำให้วิศวกรซ่อมบำรุงมีลักษณะของงานซ่อมที่หลากหลายขึ้น ดังต่อไปนี้

1. Corrective Maintenance คือการซ่อมอุปกรณ์ที่พังเสียหายไปแล้ว ให้กลับมาใช้งานได้ดังเดิม เนื่องจากเป็นงานที่ฉุกเฉินทำให้มีระยะเวลาปฏิบัติงานที่จำกัด ถ้าหากซ่อมอุปกรณ์เสร็จช้าก็จะมีระยะเวลาในการผลิตไปมากเท่านั้น

2. Preventive Maintenance คือการซ่อมอุปกรณ์เพื่อป้องกันความเสียหายที่จะเกิดขึ้นในอนาคต การซ่อมในลักษณะนี้จะอ้างอิงจากสถิติความเสียหายของอุปกรณ์วัดค่า จากนั้นทำการวิเคราะห์และประเมินต้นตอของปัญหา เมื่อทราบต้นตอของปัญหาที่เป็นสาเหตุให้เป็นอุปกรณ์วัดค่าพังเสียหายบ่อยๆ ทางทีมซ่อมบำรุงจะสร้างระบบขึ้นมาเพื่อตรวจสอบและซ่อมแซมต้นตอของปัญหาก่อนที่จะเกิดการพัง

3. Predictive Maintenance คือ การซ่อมเครื่องจักรก่อนที่จะพังเสียหายโดยมีการประมาณการไว้ล่วงหน้าว่าอุปกรณ์วัดค่าดังกล่าวจะมีการพังเสียหายในช่วงใด การซ่อมในลักษณะนี้จะเป็นการนำประวัติของอุปกรณ์วัดค่ามาดูย้อนหลัง เพื่อหารูปแบบของการพังเสียหายของอุปกรณ์ว่ามีสัญญาณใดสามารถเป็นตัวบ่งบอกระยะเวลาก่อนที่อุปกรณ์วัดค่าจะพังเสียหายได้หรือไม่

ในงานวิจัยนี้จะกล่าวถึงกระบวนการผลิตที่เกี่ยวข้องสองกระบวนการผลิต คือ กระบวนการผลิตโซดาไฟ และกระบวนการผลิตอีพ็อกซีเรซิน โดยจุดเริ่มต้นจะเริ่มจากการผลิตโซดาไฟจากน้ำเกลือก่อน จุดที่สำคัญในกระบวนการนี้คือ Membrane ถ้าหาก Membrane อุดตัน กระบวนการผลิตโซดาไฟจะไม่สามารถแยกประจุทางไฟฟ้าได้ ทำให้ผลิตภัณฑ์โซดาไฟในตอนที่ขายไม่เกิดขึ้น การป้องกันไม่ให้ Membrane อุดตันทำได้โดยการสังเกตค่า Total Organic Carbon (TOC) ไม่ให้มากเกินไปที่กำหนด การตรวจวัดค่า TOC โดยเครื่อง Total Organic Carbon Analyzer ถ้าหากค่าเกินที่กำหนด น้ำเกลือรีไซเคิลทั้งหมดจะถูกกำจัดทิ้งหรือนำไปบำบัดเพิ่มเติม ดังนั้นเครื่อง Total Organic Carbon Analyzer เป็นเครื่องมือที่มีความสำคัญอย่างมากต่อกระบวนการผลิตโซดาไฟ

ดังนั้นถ้าสามารถประเมินเวลาพังเสียหายของอุปกรณ์ล่วงหน้าได้ ก็จะสามารถวางแผนรับมือได้อย่างทันเวลา และกระทบต่อกระบวนการผลิตทั้งสองน้อยที่สุด

2. เอกสารและงานวิจัยที่เกี่ยวข้อง

ในปัจจุบันเริ่มมีการใช้ Machine Learning ในโรงงานอุตสาหกรรมเป็นจำนวนมาก โดยจุดเริ่มต้นของงานวิจัยนี้มาจากจุดประสงค์ที่ต้องการจะให้ผู้ปฏิบัติงานสามารถนำค่าของเซนเซอร์ภายในเครื่องจักรมาบ่งบอกให้ได้ว่าเครื่องจักรนั้นทำงานได้ปกติหรือเสียอยู่ ถ้าหากเป็นการแบ่งแยกคลาสเพียงสองคลาสนั้นสามารถใช้เทคนิค Support Vector Machine มาใช้ได้ทันที แต่จะไม่เพียงพอสำหรับการทำ Prediction ล่วงหน้า

อ้างอิงจาก [1] ที่เป็นการแบ่งความเป็นไปได้เพียง 2 กรณีเท่านั้น คือสำเร็จและไม่สำเร็จ วัดค่าความแม่นยำได้จาก Accuracy แต่ในงานซ่อมบำรุงนั้นการที่การทราบสถานะเพียง 2 สถานะไม่สามารถก่อให้เกิดประโยชน์ใดๆ เนื่องจากถ้าเราทำนายได้ว่าอุปกรณ์เสียหายจริง แต่ไม่ได้ป้องกันอะไรล่วงหน้า ก็ไม่ต่างอะไรกับปัจจุบัน

ดังนั้นสิ่งที่ช่วยในงานซ่อมบำรุงได้คือการทราบเวลาที่วันอุปกรณ์ถึงจะเสีย แตกต่างจากงานวิจัยนี้ที่จะมีการทำ Prediction ถึง 3 Class ด้วยกันซึ่งทั้ง 3 Class นั้นแบ่งตามระยะเวลาที่เครื่องสามารถทำงานได้ ทำให้มี Class ที่แตกต่างออกไปจาก [1] จำนวน 1 Class นั่นก็คือ Need maintenance ที่ช่วยให้สามารถเตรียมความพร้อมสำหรับงานซ่อมก่อนที่จะเสียได้

อ้างอิงจาก [2] พบว่ามีการนำ Autoregressive Integrated Moving Average (ARIMA) มาประยุกต์เพื่อนำมาใช้ในงานที่ต้องการทำนายระยะเวลาที่เหลือของเครื่องจักรเป็นตัวเลขได้ทันทีที่เราเรียกระยะเวลาที่เหลือว่า Remaining Useful Lifetime (RUL) แตกต่างจากงานวิจัยนี้ที่จะนำแนวคิดเกี่ยวกับ RUL มาใช้ในการจำแนก Class เป็นช่วงเวลาแตกต่างกับ [2] ที่จะ Predict เป็นตัวเลขของระยะเวลาที่เครื่องจักรทำงานได้ งานวิจัยนี้จะ Predict เป็นช่วงเวลาแทนเนื่องจากในงานซ่อมไม่มีความจำเป็นที่จะต้องทราบตัวเลขเพียงตัวเลขเดียว จุดประสงค์คือถ้าทราบช่วงเวลาที่เหลือที่เครื่องจักรสามารถทำงานได้ก็เพียงพอแล้วสำหรับงานซ่อม

อ้างอิงจาก [3] มีการนำ Remaining Useful Lifetime มาเข้า Model Artificial Neural Network เพื่อทำนายผลลัพธ์ โดยมี Layer เพียง 2 Layers เท่านั้น แตกต่างจากงานวิจัยนี้ที่จะใช้ Deep Learning ในการเรียนรู้ที่มี Layer ถึง 4 Layers ด้วยกัน เพื่อเพิ่ม Accuracy ของการทำ Prediction ให้มากขึ้น

และสุดท้ายอ้างอิงจาก [6] พบว่ามีการนำ Data จากเครื่องจักรหลายๆตัวเพื่อมาหา Remaining Useful Lifetime โดย Data ที่ได้นั้นต้องนำมาทำ Data preprocessing ก่อนที่จะไปเข้า Deep Learning ได้ เพราะต้องคำนวณ Remaining Useful Lifetime ออกมาเอง โดยใช้ค่า Maximum cycle ที่เครื่องจักรสามารถทำงานได้นำมาหักลบกับ Cycle นั้นๆ จะได้ผลลัพธ์เป็น RUL นั้นเอง แตกต่างจากงานวิจัยนี้ที่ไม่ต้องทำ Data preprocessing หา Failure ที่เป็น Root cause เนื่องจากงานวิจัยนี้จะนับ Alarm ทุกตัวใน Data log ทุกครั้งที่มีการหยุดเครื่องจักรเป็น Root cause ทั้งหมดและใช้ Deep learning แทน Artificial neural network แต่จากงานวิจัย [6] ทำให้มีการนำแนวคิดงานวิจัยมาต่อยอด เพื่อคำนวณหา RUL ที่เป็น Multicategory นั้นเอง

3. วิธีการวิจัย

3.1 การเก็บรวบรวมข้อมูล

ข้อมูลที่จะใช้ในงานวิจัยนี้เป็นข้อมูลที่ได้มีการเก็บรวบรวมเป็นระยะเวลา 6 เดือน โดยแหล่งข้อมูลที่มาได้จากตัวเครื่อง Total Organic Carbon Analyzer โดยแต่ละ Cycle ของตัวเครื่องดังกล่าวใช้เวลาประมาณ 15 นาที จากจำนวนเครื่องทั้งหมด 4 เครื่องทำให้มีปริมาณข้อมูลมากเพียงพอที่จะนำมาทำ RUL Prediction ของอุปกรณ์ตัวดังกล่าวได้ ข้อมูลต่างๆภายในเครื่องที่เก็บได้ 1 Cycle มีรายละเอียดดังนี้

3.1.1 Date: วันที่ที่ค่าถูกบันทึก

3.1.2 Time: เวลาที่ค่าถูกบันทึก

3.1.3 TICmgu: ค่าของ Total Inorganic Carbon ในสารก่อน Calibrate

3.1.4 TICmgc: ค่าของ Total Inorganic Carbon ในสารหลัง Calibrate

3.1.5 CO2p: ค่าปริมาณของคาร์บอนไดออกไซด์ก่อนที่เครื่องจะทำงาน

3.1.6 TOCmgu: ค่าของ Total Organic Carbon ในสารก่อน Calibrate

3.1.7 TOCmgc: ค่าของ Total Organic Carbon ในสารหลัง Calibrate

3.1.8 CO2p.1: ค่าปริมาณของคาร์บอนไดออกไซด์หลังจากที่เครื่องทำงาน

3.1.9 DegC: ค่าอุณหภูมิ ณ ขณะที่เครื่องทำการเก็บค่า

3.1.10 Atm: ค่าความดันบรรยากาศของเครื่อง ณ ขณะที่วัด

3.1.11 Sample: ปริมาณ Sample ในระบบ

3.1.12 Sample pump operation mode: บอกลักษณะของ Sample pump

3.1.13 Sample pump number of pulse: จำนวนครั้งที่ Sample pump ทำงาน

3.1.14 Sample pump time for operation (ms): เวลาทั้งหมดที่ Sample pump ทำงาน

3.1.15 Sample pump time for last pulse (ms): เวลาที่ใช้ก่อนที่ Sample pump จะถึงการทำงาน
ครั้งสุดท้าย

3.1.16 Sample pump error counter: บอกรายงานครั้งที่ Sample pump ไม่ทำงาน

3.1.17 Acid pump operation mode: บอกรายงานของ Acid pump

3.1.18 Acid pump number of pulse: จำนวนครั้งที่ Acid pump ทำงาน

3.1.19 Acid pump time for operation (ms): เวลาทั้งหมดที่ Acid pump ทำงาน

3.1.20 Acid pump time for last pulse (ms): เวลาที่ใช้ก่อนที่ Acid pump จะถึงการทำงานครั้งสุดท้าย

3.1.21 Acid pump error counter: บอกรายงานครั้งที่ Acid pump ไม่ทำงาน

3.1.22 Base pump operation mode: บอกรายงานของ Base pump

3.1.23 Base pump number of pulse: จำนวนครั้งที่ Base pump ทำงาน

3.1.24 Base pump time for operation (ms): เวลาทั้งหมดที่ Base pump ทำงาน

3.1.25 Base pump time for last pulse (ms): เวลาที่ใช้ก่อนที่ Base pump จะถึงการทำงานครั้งสุดท้าย

3.1.26 Base pump error counter: บอกรายงานครั้งที่ Base pump ไม่ทำงาน

3.2 การจัดเตรียมข้อมูล

3.2.1 เปลี่ยนชื่อของเซนเซอร์ตั้งแต่หัวข้อ 3.1.8 จนถึง 3.1.26 ให้เป็น S1 ถึง S18 เพื่อให้ง่ายต่อการเขียนโปรแกรม

3.2.2 ข้อมูลที่ได้จะมีการเรียงกันตามวันเวลาที่บันทึกอยู่แล้ว และภายในข้อมูลที่ได้เก็บมาจากเครื่องจะมีการแจ้งเตือน Alarm ของเครื่องแทรกไว้ตลอดเวลาที่เครื่องเกิดปัญหา ดังนั้นทำการเปลี่ยนจากวันและเวลาให้เป็น Operation และ Cycle โดยให้ Cycle แรกตั้งแต่เริ่มเก็บเป็น Operation 1 Cycle ที่ 1 หลังจากนั้นจะเก็บข้อมูลเป็นจำนวน Cycle ง่ายๆ จนกระทั่งเจอ Alarm หยุดการทำงานของเครื่องอีกครั้งจะถือว่าเป็น Cycle สุดท้ายก่อนที่จะเริ่ม Operation ใหม่เป็น Operation ที่ 2 Cycle ที่ 1

ตารางที่ 1 ข้อมูล Raw data ที่ได้จากเครื่องวัด Total Organic Carbon analyzer

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 2 ข้อมูลของ Data หลังจากเปลี่ยน Date และ Time เป็น Operation และ Cycle

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

3.2.3 ทำการคำนวณหาค่า Remaining Useful Lifetime จาก Operation และ Cycle โดย คำนวณจากสูตรที่ (1)

$$RUL = Max\ cycle\ ของ\ Operation - cycle\ ของ\ Operation \quad (1)$$

โดย RUL นี้จะเป็นตัวบ่งบอกว่าใน Operation นั้นๆ ยังสามารถทำงานได้อีกกี่ Cycle ก่อนที่อุปกรณ์จะเกิดการ Breakdown

3.2.4 กำหนด Class ให้กับ RUL ในแต่ละช่วง

ตารางที่ 3 การจัดหมวดหมู่แต่ละช่วงเวลา


ช่วงของ RUL	Class	ความหมาย
ตั้งแต่ 1920 ขึ้นไป	0	Healthy
1344-1919	1	Need Maintenance
ตั้งแต่ 1343 ลงมา	2	Break down

โดย Healthy = เครื่องสามารถทำงานได้ตามปกติ

Need Maintenance = เครื่องผิดปกติเตรียมอะไหล่สำรองให้พร้อมและเข้าไปตรวจสอบ

Break down = เตรียมแจ้งทีมกระบวนการผลิตเพื่อจัดเตรียมแผนป้องกันเวลาที่เครื่องเสียหาย

3.2.5 หา Correlation ของ Attribute ภายในเครื่องที่เกี่ยวข้องกับ RUL จาก Correlation Matrix



รูปที่ 1 Correlation Matrix ของ Input และ Output

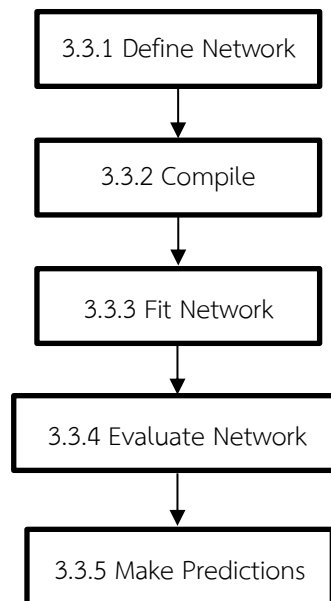
3.2.6 จาก Correlation Matrix เลือก Attribute มาทำ Deep Learning เพื่อทำนาย RUL คือ TICmgu, TICmgu, TOCmgu, TOCmgu, CO2p.1, S1, S2, S6, S7, S11, S12, S16 และ S17 ทั้งหมด 13 parameters

3.2.7 แบ่ง Data ออกเป็น 2 ชุด โดย Training Data 80% และ Testing Data 20%

ตารางที่ 4 จำนวนของ Output ที่ใช้ในการ Training และ Testing Model

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

3.3 Prediction model construction



รูปที่ 2 Process ขั้นตอนการทำ Deep learning

3.3.1 Define Network: กำหนดให้ Model มีทั้งหมด 3 Layers โดย Layer ที่ 1: มี Hidden node ทั้งหมด 15 nodes และมี Reactivation เป็น Relu Layer ที่ 2: มี Hidden node ทั้งหมด 15 nodes และมี Reactivation เป็น Relu Layer ที่ 3: มี Hidden node ทั้งหมด 15 nodes และมี Reactivation เป็น Relu Layer ที่ 4: มี Output node ทั้งหมด 3 nodes และมี Reactivation เป็น Softmax

3.3.2 Compile Network: Optimizer ที่ใช้เป็น Adam เนื่องจากในขณะที่ทำการ Training ข้อมูลทางตัวของ Model จะต้องมีการปรับ Tuning Learning rate ให้ดียิ่งขึ้นด้วย และ Loss กำหนดให้เป็น sparse_categorical_crossentropy เนื่องจาก Output ในการวิจัยครั้งนี้เป็น Multiclass Classification

3.3.3 Fit Network: นำค่าของ Attribute ทั้งหมดที่กล่าวในหัวข้อ 3.2.7 เป็น Training Input ภายใน Model โดยมี Training Output เป็น Categorical และทำการ Training Model ให้เรียบร้อย

3.3.4 Evaluate Network: ดู Accuracy และ Loss ของ Model ที่ผ่านการ Training มาแล้ว


3.3.5 Make prediction: นำ Testing Input และ Testing Output ที่ได้เตรียมไว้มา Test กับ Model ที่ Training สำเร็จแล้ว เพื่อดูประสิทธิภาพของ Model ที่สร้างขึ้น

4. ผลการวิจัย

ผลการทดลองหลังจากที่ได้มีการทดสอบ Testing Input และ Testing Output เข้าไปภายใน Model ที่ได้สร้างขึ้นได้ผลลัพธ์ตามตารางด้านล่าง โดยกำหนดให้ Epoch=300, batch size=100 และ Dropout=0.2

ตารางที่ 5 ผลลัพธ์การ Predict ด้วย Model ที่ผ่านการ Train โดยมี Input เป็น Test data

	Healthy	Need maintenance	Breakdown
Healthy	1626	114	100
Need maintenance	229	2203	103
Breakdown	292	176	348



รูปที่ 3 Confusion matrix

จะเห็นได้ว่าผลลัพธ์จากการ Predict ด้วย Model ที่ผ่านการ Training มาแล้วเทียบกับผลลัพธ์ของ Test data ที่ทราบค่าอยู่แล้วมีค่าดังนี้

Healthy ทายถูกทั้งหมด 1626 จาก 1840 คิดเป็น Accuracy 88.37%

Need maintenance ทายถูกทั้งหมด 2203 จาก 2535 คิดเป็น Accuracy 86.9%

Breakdown ทายถูกทั้งหมด 348 จาก 816 คิดเป็น Accuracy 42.64%

Classification Report:

	precision	recall	f1-score	support
Healthy	0.76	0.88	0.82	1840
Need maintenance	0.88	0.87	0.88	2535
Breakdown	0.63	0.43	0.51	816
accuracy			0.80	5191
macro avg	0.76	0.73	0.73	5191
weighted avg	0.80	0.80	0.80	5191

รูปที่ 4 Classification Report

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

5. อภิปรายผลและข้อเสนอแนะการวิจัย

จากผลการวิจัยพบว่าเมื่อนำ Model ดังกล่าวไปใช้ในการ Predict งานจริงๆ จะสามารถ Predict เครื่องจักรได้ที่ช่วงการทำงานเหลือ 14 วันขึ้นไปได้ดีที่ 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 โดยแผนการพัฒนาต่อไปคือจะให้ Output Categories มากกว่า 3 Categories ทำให้การแจ้งเตือนแต่ละครั้งเป็นการบอกได้เจาะจงมากยิ่งขึ้น เช่นใช้ งานได้อีกกี่วัน ใช้งานได้อีกกี่สัปดาห์ ใช้งานได้อีกกี่เดือน ถ้าหากสามารถทำ RUL Prediction ได้ตามที่ได้กล่าวมา กระบวนการผลิตก็จะมีประสิทธิภาพยิ่งขึ้น และไม่มียานซ่อมแซมแบบ Corrective maintenance อีกเลยก็เป็นได้

คำขอบคุณ

ขอขอบคุณ ศ.ดร. ประภาส จงสถิตย์วัฒนา สำหรับคำแนะนำในงานวิจัยตั้งแต่การเลือกหัวข้องานวิจัย รูปแบบงานวิจัย รวมไปถึงการแนะนำแหล่งอ้างอิงข้อมูลต่างๆ เพื่อให้งานวิจัยนี้เสร็จสมบูรณ์ และขอบคุณคุณสุรียา สำหรับคำแนะนำและข้อมูลต่างๆ สุดท้ายนี้ขอขอบคุณครอบครัว รวมไปถึงคุณณัฐวดีที่คอยให้กำลังใจตลอดเวลา

6. เอกสารอ้างอิง

- [1] Pootisirakorn, M., & Chongstitvatana, P. (2019) Failure Prediction in Open-hole Wireline Logging of Oil and Gas Drilling using Support vector machine, Int. Computer Science and Engineering Conf.
- [2] Kanawaday, A., & Sane, A. (2017) Machine Learning for Predictive Maintenance of Industrial Machines using IoT Sensor Data. IEEE Int. Conf. on Software Engineering and Service Science.
- [3] Mahamad, A. K., Saon, S., & Hiyama, T. (2010) Predicting remaining useful life of rotating machinery based artificial neural network. Computer & Mathematics with Applications 60:4, pp.1078-1087.
- [4] Yeh, C.H., Lin, M.H., Lin, C.H., Yu, C.H. & Chen, M.J. (2019) Machine Learning for Long Cycle Maintenance Prediction of Wind Turbine. Sensors, 19(7):1671.
- [5] Saxena, A., Goebel, K., Simon, D., & Eklund, N. (2008) Damage Propagation Modeling for Aircraft Engine Run to Failure Simulation. Int. Conf. on Prognostics and Health Management. pp.1-9.
- [6] Elasha, F., Shanbr, S., Li, X., & Mba, D. (2019) Prognosis of a Wind Turbine Gearbox Bearing Using Supervised Machine Learning. Sensors, 19(14):3092.
- [7] Sampaio, G.S., Rabello de Aguiar Vallim Filho, A., Santos da Silva, L., & Augusto da Silva L. (2019) Prediction of Motor Failure Time using An Artificial Neural Network. Sensors, 19(19):4342.
- [8] Kimera, D., & Nangolo, F.N. (2020) Predictive maintenance for ballast pumps on ship repair years via machine learning. Transportation Engineering. vol. 2. 100020.