

**การซ่อมบำรุงรักษาเชิงคาดการณ์มอเตอร์ไฟฟ้า
โดยใช้โมเดลการเรียนรู้เชิงลึก**

นิติรัฐ สุกีชร

**สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมข้อมูลขนาดใหญ่
วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์
มหาวิทยาลัยธุรกิจบัณฑิต
ปีการศึกษา 2564**

**PREDICTIVE MAINTENANCE FOR INDUCTION MOTORS BY
USING DEEP LEARNING TECHNIQUES**

NITIRAT SUKEETHORN

**An Independent Study Submitted in Partial Fulfillment of the
Requirements for the Degree of Master of Big Data Engineering,
College of Innovative Technology and Engineering,
Dhurakij Pundit University
Academic Year 2021**




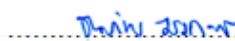
ใบรับรองงานสารนิพนธ์


วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิต
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต

หัวข้อสารนิพนธ์ การซ่อมบำรุงรักษาเชิงคาดการณ์มอเตอร์ไฟฟ้าโดยใช้โมเดลการเรียนรู้เชิงลึก
เสนอโดย นิตริฐ สุกีธร
สาขาวิชา วิศวกรรมข้อมูลขนาดใหญ่
อาจารย์ที่ปรึกษาสารนิพนธ์ ดร.ธนภัทร มังคะจิตร

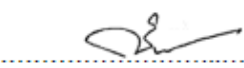
ได้พิจารณาเห็นชอบโดยคณะกรรมการสอบสารนิพนธ์แล้ว


.....ประธานกรรมการ
(ดร.สรรพฤทธิ์ มฤคทัต)


.....กรรมการและอาจารย์ที่ปรึกษา
(ดร.ธนภัทร มังคะจิตร)


.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ดวงใจ จิตคงชื่น)

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์รับรองแล้ว


.....
(ดร.ชัยพร เขมะภาคพันธ์)

คณบดีวิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์

วันที่ 14 เดือน ธันวาคม พ.ศ. 2564

หัวข้อสารนิพนธ์	การซ่อมบำรุงรักษาเชิงคาดการณ์มอเตอร์ไฟฟ้าโดยใช้โมเดลการเรียนรู้เชิงลึก
ชื่อผู้เขียน	นิติรัฐ สุกีธร
อาจารย์ที่ปรึกษา	ดร.ธนภัทร นังคะจิตร
สาขาวิชา	วิศวกรรมข้อมูลขนาดใหญ่
ปีการศึกษา	2564

บทคัดย่อ

มอเตอร์ไฟฟ้าเป็นอุปกรณ์สำคัญอย่างหนึ่งในโรงงานอุตสาหกรรมซึ่งทำให้กระบวนการผลิตทำงานได้อย่างต่อเนื่อง ในกรณีที่อุปกรณ์เสียหายก่อนกำหนดการเปลี่ยนซ่อมทำให้เกิดความเสียหายต่อกระบวนการผลิต งานวิจัยก่อนหน้านี้ได้นำเสนอให้เห็นถึงต้นทุนของการบำรุงรักษาเชิงคาดการณ์ที่ต่ำกว่าการบำรุงเชิงป้องกัน รวมถึงการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกแบบ LSTM ในการทำนายช่วงเวลาบำรุงรักษาเชิงคาดการณ์ที่มีประสิทธิภาพ

งานวิจัยนี้จึงเสนอโปรแกรมผ่านเว็บสำหรับคาดการณ์อายุการใช้งานที่เหลืออยู่ของมอเตอร์ไฟฟ้าจากข้อมูลจากเซนเซอร์ด้วยเทคนิคการเรียนรู้เชิงลึก โดยให้ผู้ใช้งานส่งไฟล์ข้อมูลขึ้นมาในระบบโมเดลก็จะทำนายว่ามอเตอร์ไฟฟ้าจะเกิดปัญหาในช่วงเวลาที่กำหนดหรือไม่ ส่งผลให้ผู้ที่เกี่ยวข้องสามารถเตรียมแผนดำเนินการให้เหมาะสมกับแผนงานผลิตได้ การทดสอบกับข้อมูลจำลองพบว่าแบบจำลองให้ผลการทำนายที่แม่นยำสำหรับทำนายการเสียหายของอุปกรณ์ในช่วงเวลาระยะสั้น ในขณะที่ยังให้ความแม่นยำค่อนข้างต่ำสำหรับการคาดการณ์การเสียหายของอุปกรณ์ในระยะยาว ดังนั้นจึงควรนำผลจากการทำนายของแบบจำลองในลักษณะเชิงคาดการณ์มาวางแผนร่วมการบำรุงรักษาเชิงป้องกันซึ่งจะทำให้สามารถลดต้นทุนและรักษากระบวนการผลิตให้ทำงานได้อย่างต่อเนื่องได้

Independent Study Title	PREDICTIVE MAINTENANCE FOR INDUCTION MOTORS BY USING DEEP LEARNING TECHNIQUES
Author	Nitirat Sukeethorn
Independent Study Advisor	Dr. Thanapat Kangkachit
Department	Big Data Engineering
Academic Year	2021

ABSTRACT

In most industrial plants, electric motors are the essential devices that serve the manufacturing process to run continuously. The losses in the process may arise in case of premature failures in the motors before the replacement schedule. The former research revealed that the cost for predictive maintenance was significantly lower than preventive maintenance. In addition, effectively predicting the replacement intervals can be performed using the LSTM deep learning technique.

Therefore, this work proposes a web-based system for predicting the remaining useful lifetime (RUL) of electric motors using the LSTM deep learning technique. Once users upload the sensor logs into our system, our model classifies whether the devices will malfunction or work flawlessly during a given period. As result, the appropriate action plans can be prepared. Experiments on a public dataset show that our model obtains high accuracy in a short period of RUL. Contrastingly for the dataset with a long period of RUL, less accuracy is produced. Thus, the combination of prediction results and preventive maintenance plans may reduce costs and sustain the manufacturing process.

กิตติกรรมประกาศ

สารนิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ โดยการให้ความช่วยเหลือของอาจารย์ที่ปรึกษา สารนิพนธ์ ดร.ชนภัทร ชังคะจิตร ที่ได้กรุณาให้คำแนะนำ ตรวจสอบ และแก้ไขข้อบกพร่องต่าง ๆ มาโดยตลอด เพื่อให้สารนิพนธ์ฉบับนี้สมบูรณ์ ผู้เขียนจึงขอกราบขอบพระคุณไว้ ณ โอกาสนี้

ขอขอบคุณเจ้าหน้าที่หลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมข้อมูล ขนาดใหญ่ทุกท่านสำหรับการช่วยเหลือและประสานงานเพื่อให้การดำเนินการทำวิจัยเป็นไปอย่างราบรื่น

ขอขอบคุณมิตรสหายทุกท่านที่ได้ให้คำปรึกษาและให้กำลังใจในเสมอมาตลอดจนมหาวิทยาลัยที่ ให้โอกาสในการศึกษาเรียนรู้ตามความสนใจของผู้วิจัย

ผู้เขียนขอกราบขอบพระคุณครอบครัวของผู้เขียน รวมถึงเจ้าหน้าที่บัณฑิตมหาวิทยาลัย ธุรกิจบัณฑิตทุกท่านที่ให้ความสะดวกด้านอำนวยความสะดวก และประสานงาน ในการทำสารนิพนธ์ ให้กับผู้เขียน ทำให้การจัดทำสารนิพนธ์ของผู้เขียนในครั้งนี้สำเร็จลุล่วงไปด้วยดี

หากมีสิ่งได้ที่ผู้วิจัยได้ทำผิดพลาดหรือบกพร่องประการใด ผู้วิจัยต้องกราบขออภัยเป็นอย่างสูงมา ณ โอกาสนี้ ผู้วิจัยหวังเป็นอย่างยิ่งว่าสารนิพนธ์ฉบับนี้ จะเป็นพื้นฐานในการต่อยอดองค์ความรู้ของผู้ที่สนใจศึกษาในงานด้านนี้ต่อไป

นิติรัฐ สุกีธร

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ฉ
บทคัดย่อภาษาอังกฤษ	ง
กิตติกรรมประกาศ	จ
สารบัญตาราง	ช
สารบัญภาพ	ฉ
บทที่	
1. บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตงานวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ	2
2. แนวคิด ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง.....	11
2.1 การเรียนรู้เชิงลึก (Deep Learning).....	11
2.2 Long Short-Term Memory (LSTM).....	12
2.3 ตัววัดประสิทธิภาพของโมเดล (Confusion Matrix).....	13
2.4 งานวิจัยที่เกี่ยวข้อง.....	16
3. ระเบียบวิธีวิจัย	21
3.1 การนำเข้าข้อมูลจาก Sensor.....	21
3.2 การเตรียมข้อมูลสำหรับสอนระบบ.....	22
3.3 การสร้างโมเดลประมาณอายุใช้งานของมอเตอร์ไฟฟ้า.....	24
3.4 การประมาณอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้าผ่าน Web UI.....	25
3.5 เครื่องมือที่ใช้ในงานวิจัย.....	26
4. ผลการดำเนินงานวิจัย.....	27
4.1 ผลการวัดประสิทธิภาพของโมเดล.....	27
4.2 ผลการวัดประสิทธิภาพของโมเดลเมื่อปรับเปลี่ยนค่า Parameter.....	28
4.3 ผลการวัดความพึงพอใจของผู้ใช้งาน.....	29

สารบัญ (ต่อ)

	หน้า
5. สรุปผลการทดลอง.....	31
5.1 สรุปผลการวิจัย.....	31
5.2 ข้อเสนอแนะ.....	32
บรรณานุกรม.....	33
ภาคผนวก.....	35
ประวัติผู้เขียน.....	37

สารบัญตาราง

ตารางที่	หน้า
2.1 เปรียบเทียบค่า Accuracy แต่ละ Window Length.....	18
3.1 ค่า Parameter ต่างๆ ของ โมเดล LSTM.....	25
4.1 ตารางแสดงผลการทดสอบประสิทธิภาพของโมเดล.....	27
4.2 ค่า Parameter ต่างๆที่ปรับเปลี่ยนของ โมเดล LSTM.....	28
4.3 ตารางแสดงผลการทดสอบประสิทธิภาพของโมเดลหลังปรับเปลี่ยน Parameter.....	28

สารบัญภาพ

ภาพที่	หน้า
2.1 ตัวอย่างโครงสร้างเลเยอร์ของแบบจำลองการเรียนรู้เชิงลึก.....	11
2.2 โครงสร้างเลเยอร์ของโมเดล RNN.....	12
2.3 โครงสร้างเลเยอร์ของโมเดล LSTM.....	13
2.4 Confusion Matrix แบบ Binary Classification.....	14
2.5 สมการคำนวณค่า Accuracy.....	15
2.6 สมการคำนวณค่า Precision.....	15
2.7 สมการคำนวณค่า Recall.....	15
2.8 สมการคำนวณค่า F1 Score.....	16
2.9 แผนผัง Dynamic Predictive Maintenance Process.....	16
2.10 แสดงการเปรียบเทียบต้นทุนของวิธีการซ่อมบำรุงแต่ละแบบ.....	17
2.11 ผลการเปรียบเทียบ Accuracy ของแต่ละโมเดล.....	17
2.12 ข้อมูลของ Node MCU ที่ใช้กับ Sensor.....	19
2.13 ข้อมูลของ Sensor ที่นำมาใช้.....	19
2.14 Flow ในการดำเนินงานวิจัย.....	19
2.15 ผลการเปรียบเทียบ Accuracy ของแต่ละโมเดลในงานวิจัย.....	20
3.1 (ซ้าย) ตัวอย่าง Sensor ที่ใช้วัด (ขวา) ตัวอย่างข้อมูลที่ได้จาก Sensor.....	21
3.2 ตัวอย่างข้อมูลจำลองที่นำมาใช้.....	22
3.3 ผลที่ได้จากการหา RUL (Remain Useful Lifetime).....	23
3.4 ผลที่ได้จากการสร้าง Label ที่กำหนดช่วงเวลาทำนายที่ 4 วัน.....	23
3.5 แสดง Network ของ LSTM ที่ใช้ในงานวิจัย.....	24
3.6 ตัวอย่างโปรแกรมรูปแบบ Web User Interface ในการนำไปใช้งาน.....	25
4.1 กราฟแสดงผลการวัดความพึงพอใจของผู้ทดลองใช้งาน.....	30

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ในปัจจุบันมอเตอร์ไฟฟ้าถือเป็นอุปกรณ์ที่สำคัญในโรงงานอุตสาหกรรม ไม่ว่าจะเป็นในกระบวนการผลิต ส่วนอำนวยความสะดวก เพราะฉะนั้นเมื่อมอเตอร์เกิดปัญหาขึ้นมาจึงมีผลกระทบในหลายส่วนงานเป็นอย่างมาก การซ่อมบำรุงจึงถือเป็นการช่วยให้กระบวนการผลิตทำงานได้โดยที่มีการหยุดงานน้อยที่สุด รวมถึงการใช้มอเตอร์อย่างคุ้มค่าที่สุด

โดยทั่วไปการซ่อมบำรุงมอเตอร์ จะใช้วิธีกำหนดเป็นช่วงเวลาว่าจะซ่อมหรือเปลี่ยนมอเตอร์ทุกกี่เดือน ซึ่งวิธีนี้ในกรณีที่มอเตอร์เกิดปัญหาก่อนถึงช่วงเวลาซ่อมบำรุง ก็จะส่งผลในเรื่องกระบวนการผลิตที่ต้องหยุด , ระยะเวลาการสั่งซื้อมอเตอร์ตัวใหม่เข้ามา ทำให้เกิดการสูญเสียรายได้จากการผลิตที่ต้องหยุดไป

อย่างไรก็ตาม งานวิจัยก่อนหน้านี้ได้ทำการเปรียบเทียบต้นทุนที่เกิดขึ้นระหว่างการซ่อมบำรุงรักษาแบบเชิงป้องกันและการซ่อมบำรุงรักษาแบบเชิงคาดการณ์พบว่าต้นทุนจากการซ่อมบำรุงเชิงป้องกันมากกว่าแบบเชิงคาดการณ์ในทุกด้าน ไม่ว่าจะเป็นต้นทุนในการเก็บสินค้า ต้นทุนในการจัดซื้อ ต้นทุนที่เกิดจากการหยุดผลิต

งานวิจัยนี้จึงเสนอโปรแกรมผ่านเว็บสำหรับคาดการณ์อายุการใช้งานที่เหลืออยู่ของมอเตอร์ไฟฟ้าจากข้อมูลจากเซนเซอร์ด้วยเทคนิคการเรียนรู้เชิงลึก โดยให้ผู้ใช้งานส่งไฟล์ข้อมูลขึ้นมาในระบบโมเดลก็จะทำนายว่ามอเตอร์ไฟฟ้าจะเกิดปัญหาในช่วงเวลาที่กำหนดหรือไม่ ส่งผลให้ผู้ที่เกี่ยวข้องสามารถเตรียมแผนดำเนินการให้เหมาะสมกับแผนงานผลิตได้

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อทำเครื่องมือประมาณความน่าจะเป็นอายุใช้งานที่เหลือในเวลาที่กำหนดของมอเตอร์ไฟฟ้า โดยทำการนำข้อมูลต่างๆที่ดึงมาจากเซนเซอร์ มาทำโมเดลด้วยเทคนิคการเรียนรู้เชิงลึก หลังจากนั้นนำข้อมูลของมอเตอร์ไฟฟ้าแต่ละชุดมาเข้าโมเดล เพื่อตรวจสอบอายุการใช้งานที่เหลือ

1.3 ขอบเขตงานวิจัย

- 1.3.1 เป็นข้อมูลจำลองจาก Kaggle ที่นำมาใช้งาน
- 1.3.2 ต้องใช้แบบรูปแบบของข้อมูลตามที่กำหนดไว้
- 1.3.3 ใช้โมเดล LSTM ในการ Training

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1.4.1 ทำให้การคาดการณ์เวลาที่อุปกรณ์จะเกิดปัญหามีความแม่นยำมากขึ้น
- 1.4.2 ใช้อุปกรณ์ได้อย่างมีประสิทธิภาพตลอดอายุการใช้งาน
- 1.4.3 ลดต้นทุนในการเก็บสต็อกของอุปกรณ์


บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การศึกษาวิจัยนี้ เป็นการนำเสนอเทคนิคการประมาณน้ำหนักของสุกร ด้วยการประยุกต์ใช้การเรียนรู้เชิงลึก (Deep Learning) โดยจำเป็นต้องศึกษาเอกสารและงานวิจัยที่เกี่ยวข้อง ดังรายการต่อไปนี้

2.1 การเรียนรู้เชิงลึก (Deep Learning)


การเรียนรู้เชิงลึกเป็นแขนงย่อยของการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งแต่ละงานแบ่งย่อยและกระจายไปยังแต่ละอัลกอริทึมของการเรียนรู้ของเครื่องที่ถูกจัดให้อยู่ในรูปแบบของลำดับชั้นที่ต่อเนื่องกัน โดยในแต่ละชั้น (Layer) ถูกสร้างขึ้นตามผลลัพธ์จากชั้นก่อนหน้า จากนั้นแต่ละชั้นประกอบกันเป็นโครงข่ายประสาทเทียม ซึ่งคล้ายกับวิธีการกระจายการแก้ปัญหาของเซลล์ประสาทในสมองมนุษย์ที่แต่ละเซลล์ประสาทเชื่อมต่อซึ่งกันและกัน รวมถึงมีการส่งข้อมูลระหว่างเซลล์ประสาท



ภาพที่ 2.1 ตัวอย่างโครงสร้างเลขอร์ของแบบจำลองการเรียนรู้เชิงลึก

2.2 Long Short-Term Memory (LSTM)

LSTM เป็นหนึ่งในโมเดลของ Recurrent neural network (RNN) ที่นิยมใช้งานกับข้อมูลที่มีลักษณะเป็นลำดับ (Sequence) เช่นงาน Text (Sequence of words) ซึ่ง RNN จะมี Memory ที่เก็บ Outputจากการคำนวณกลับไปใช้คำนวณใหม่ ซึ่งปัญหาของ RNN จะเกิดขึ้นในงานที่ Sequence ของข้อมูลที่มีขนาดยาวเพราะปฏิกิริยาอัตราค่า weights ก็จะใช้วิธี Backpropagation Algorithm ซึ่งจะคำนวณ gradient ของ loss function เพื่อมาอัตราค่า weights ซึ่งการคำนวณจะเกิดมาจากช่วงเวลาก่อนหน้าด้วย ส่งผลให้เกิดค่า gradient ที่ลดลงไปตามจำนวน sequence หรือที่เรียกว่า gradient vanishing




ภาพที่ 2.2 โครงสร้างเลเยอร์ของโมเดล RNN

ที่มา: Sirinart Tangruamsub - 2017

โมเดล LSTM จึงแก้ปัญหา gradient vanishing โดยส่วน memory ของ LSTM สามารถกำหนดได้ว่าเมื่อที่ memory นี้จะทำการจำหรือลบทิ้งไปจาก gates ต่างๆที่ประกอบในโมเดลซึ่งมีรายละเอียดดังนี้

- 2.2.1 Input Gate เป็นตัวบอกว่าจะอัตราค่าหรือไม่
- 2.2.2 Forget Gate ถ้ามีค่าเป็น 0 ก็จะลบ cell state ทิ้ง ถ้ามีค่าเป็น 1 ก็จะเก็บ cell state นั้นไว้
- 2.2.3 Output Gate เป็นตัวกำหนดว่าจะนำ hidden state ณ เวลา t ไปคำนวณกับ Input data ที่เข้ามาใหม่หรือไม่



ภาพที่ 2.3 โครงสร้างเลเยอร์ของโมเดล LSTM

ที่มา: Sirinart Tangruamsub - 2017

2.3 ตัววัดประสิทธิภาพของโมเดล (Confusion Matrix)

Confusion Matrix: เป็นเมตริกขนาด $N \times N$ ที่นำมาใช้ประเมินประสิทธิภาพของ Classification Model ซึ่ง N คือจำนวนคลาสที่ต้องการทำนาย โดยที่เมตริกจะเปรียบเทียบค่าจริงกับค่าที่โมเดลทำนายได้ อีกทั้งยังรู้ว่า Error ที่ทำนายเป็น Error ส่วนไหนสำหรับ Binary Classification เราจะได้เมตริกขนาด 2×2 ที่มี 4 ค่า ดังภาพ

		ACTUAL VALUES	
		POSITIVE	NEGATIVE
PREDICTED VALUES	POSITIVE	TP	FP
	NEGATIVE	FN	TN

ภาพที่ 2.4 Confusion Matrix แบบ Binary Classification

ที่มา: <https://www.analyticsvidhya.com/blog/2020/04/confusion-matrix-machine-learning>

ความหมายของค่าที่อยู่ใน Confusion Matrix

True Positive (TP) คือค่าที่บอกว่าโมเดลทำนายตรงกับข้อมูลที่เกิดขึ้นจริง ในคลาส Positive

True Negative (TN) คือค่าที่บอกว่าโมเดลทำนายตรงกับข้อมูลที่เกิดขึ้นจริง ในคลาส Negative

False Positive (FP) คือค่าที่บอกว่าโมเดลทำนายไม่ตรงกับข้อมูลที่เกิดขึ้นจริง โดยที่ข้อมูลจริงเป็นคลาส Negative แต่โมเดลทำนายเป็นคลาส Positive

False Negative (FN) คือค่าที่บอกว่าโมเดลทำนายไม่ตรงกับข้อมูลที่เกิดขึ้นจริง โดยที่ข้อมูลจริงเป็นคลาส Positive แต่โมเดลทำนายเป็นคลาส Negative

เราสามารถนำ Confusion Matrix มาคำนวณ การประเมินประสิทธิภาพของการทำนายด้วย Model ของเรา ในรูปแบบค่าต่างๆ ได้แก่

Accuracy เป็นการวัดความถูกต้องของโมเดล โดยพิจารณารวมทุกคลาส

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

ภาพที่ 2.5 สมการคำนวณค่า Accuracy

Precision เป็นการวัดค่าที่ทำนายคลาส Positive เทียบกับผลที่ทำนายทั้งหมดในคลาส Positive

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

ภาพที่ 2.6 สมการคำนวณค่า Precision

Recall เป็นการวัดค่าที่ทำนายคลาส Positive เทียบกับผลที่เกิดขึ้นจริงของคลาส Positive

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

ภาพที่ 2.7 สมการคำนวณค่า Recall


F1 Score เป็นค่าเฉลี่ยแบบ Harmonic Mean ระหว่าง Precision และ Recall

$$F1 - score = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}}$$

ภาพที่ 2.8 สมการคำนวณค่า F1 Score

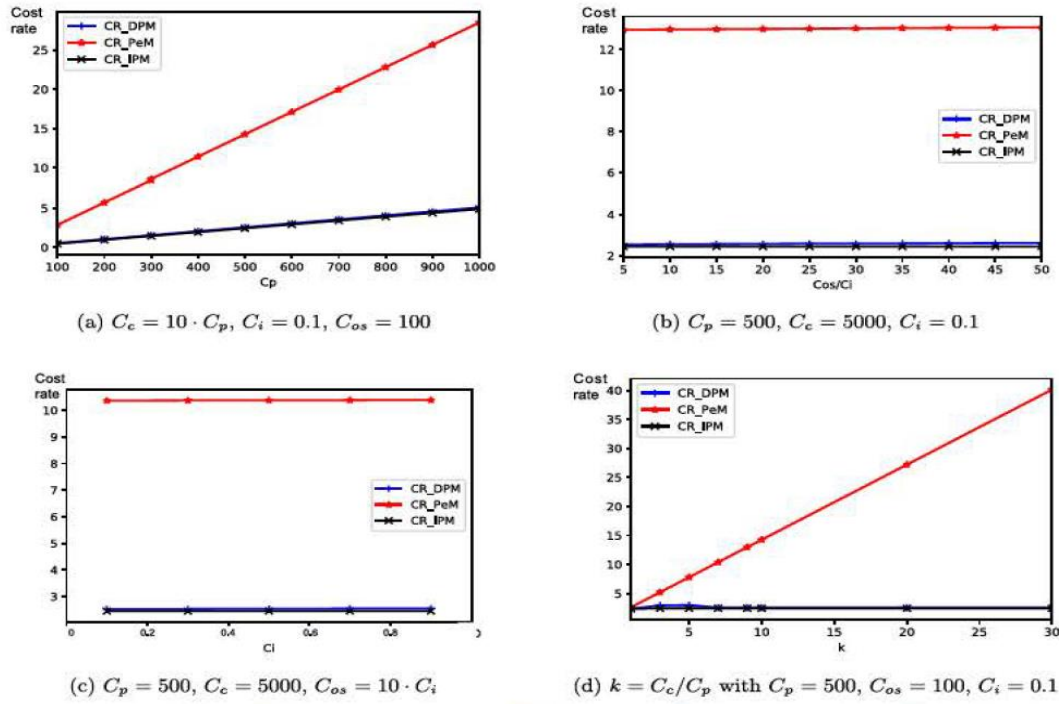
2.4 งานวิจัยที่เกี่ยวข้อง

2.4.1 Khanh T.P. Nguyen, Kamal Medjaher (2019) งานวิจัยนี้ได้ทำการศึกษา Framework ในรูปแบบ Dynamic Predictive Maintenance นำเสนอต้นทุนที่แตกต่างกันสำหรับการซ่อมบำรุง เพื่อให้เห็นประโยชน์ของการนำ Predictive Maintenance ไปประยุกต์ใช้ในโรงงาน



ภาพที่ 2.9 แผนผัง Dynamic Predictive Maintenance Process

ตามข้อมูลจากงานวิจัยนี้จะเห็นได้ว่าการทำ Predictive Maintenance จะทำให้อัตรา ต้นทุนเฉลี่ยมีค่าที่ค่อนข้างต่ำ ดังข้อมูลตามภาพที่ 3.10



ภาพที่ 2.10 แสดงการเปรียบเทียบต้นทุนของวิธีการซ่อมบำรุงแต่ละแบบ

2.4.2 Michal Markiewicz ,Maciej Wielgosz, Mikolaj Bochenski, Waldemar Tabaczynski, Tomasz Konieczny, and Liliana Kowalczyk (2019) งานวิจัยนี้ได้ทำการศึกษาโมเดลที่นำมาใช้กับงาน Predictive Maintenance ที่เป็นรูปแบบ Time Series

Algorithm	Accuracy	F1-score
RNN with 16 LSTMs, lookback of 32	91.97%	0.81
RNN with 16 LSTMs, lookback of 32, thq 8-bits	92.04%	0.81
Constant (always classify as OK)	78.80%	0.39
K-NN (K=5)	82.67%	0.31
OC-SVM (linear kernel)	67.62%	0.39
Isolation Forest	88.95%	0.77

ภาพที่ 2.11 ผลการเปรียบเทียบ Accuracy ของแต่ละโมเดล

จากผลการเปรียบเทียบจะเห็นได้ว่าโมเดล LSTM ให้ผล Accuracy และ F1-Score ที่ค่อนข้างดีเพราะ LSTM เหมาะกับข้อมูลที่เป็น Sequence แบบ Time Series หรือ NLP เนื่องจากแก้ปัญหา Gradient Vanishing

2.4.3 Ammar Azlan, Yuhanis Yusof and Mohamad Farhan Mohamad Mohsin (2019) งานวิจัยนี้ได้ทำการศึกษาว่าขนาดของ Window Length ส่งผลอย่างไรต่อการทำ Deep Learning แบบ Time series forecasting ซึ่งงานวิจัยนี้ได้แบ่งช่วง Window Length ออกมาเป็น 3 ช่วงคือ 25 วัน , 50 วัน และ 100 วัน โดยที่ผลการทดลองออกมามีรายละเอียดดังนี้

ตารางที่ 2.1 เปรียบเทียบค่า Accuracy แต่ละ Window Length

Window Length	Accuracy
25 Days	81.25%
50 Days	62.5%
100 Days	100%

จากตารางที่ 1 ก็จะพบว่าช่วงของ Window Length ที่ต่างกันก็จะส่งผลให้ค่า Accuracy ของโมเดลแตกต่างกันด้วย และก็ไม่จำเป็นว่า Window Length ที่มากขึ้นจะให้ค่า Accuracy ที่มากขึ้นด้วยและยังเกี่ยวข้องกับจำนวนของข้อมูลด้วยคือ ถ้าข้อมูลจำนวนน้อยก็จะทำให้โมเดลใช้งานได้ไม่ดี ถ้าข้อมูลเยอะเกินไปก็จะทำให้ใช้เวลานานหรือแย่กว่านั้นคือประสิทธิภาพของโมเดลลดลงอีกด้วย


2.4.4 Muhammad Syafrudin , Ganjar Alfian , Norma Latif Fitriyani and Jongtae Rhee (2018) งานวิจัยนี้ได้ทำการศึกษาถึงการนำ Sensor ไปติดตั้งจริงที่หน้างาน รวมการดึงข้อมูลออกมาเก็บเข้า Server การทำ Data Preparation และการทำโมเดลดังรายละเอียดตามภาพที่ 2.12

Specification	Information
RAM	1 GB
CPU	Quad Cortex A53 @ 1.2 GHz
GPU	400 MHz VideoCore IV
GPIO	40 pins
Storage	Micro-SD
Ethernet	10/100 Mbps
Wireless	Wireless LAN 802.11n/Bluetooth 4.0 Low Energy
USB	4 ports
Power consumption	5 V
Dimensions	85.60 × 56.5 mm

ภาพที่ 2.12 ข้อมูลของ Node MCU ที่ใช้กับ Sensor

Specification	Information
Gyroscope	Gyroscope sensor (accurate to $\pm 245/500/2000$ degrees per second)
Accelerometer	Accelerometer sensor (accurate to $\pm 2/4/8/16$ G-forces)
Magnetometer	Magnetic Sensor (accurate to $\pm 4/8/12/16$ gauss)
Barometric pressure	Pressure sensor (accurate to ± 0.1 hectopascal)
Temperature	Temperature sensor (accurate to ± 2 °C)
Humidity	Relative humidity sensor (accurate to $\pm 4.5\%$)
Display	8 × 8 LED display matrix
Input	Small 5 joystick button

ภาพที่ 2.13 ข้อมูลของ Sensor ที่นำมาใช้



ภาพที่ 2.14 Flow ในการดำเนินงานวิจัย

จากภาพที่ 14 จะเห็นได้ว่าเมื่อรับข้อมูลจาก Sensor ก็จะเข้าขั้นตอนการทำ Data Preprocessing เช่น Data Missing Handling , Feature Engineering หลังจากนั้นก็หา Outlier ด้วยวิธี DBSCAN แล้วเข้าสู่การเทรนโมเดลด้วยวิธี Random Forest Classification

Model	Precision (%)	Recall (%)	Accuracy (%)
Naïve Bayes (NB)	94.1	93.6	93.567
Logistics Regression (LR)	98	98	97.953
Multilayer Perceptron (MLP)	96.8	96.8	96.784
Random Forest (RF)	98.5	98.5	98.538
DBSCAN + NB	96.8	96.7	96.74
DBSCAN + LR	98.6	98.5	98.52
DBSCAN + MLP	98.8	98.8	98.81
Hybrid Prediction Model (DBSCAN + RF)	100	100	100

ภาพที่ 2.15 ผลการเปรียบเทียบ Accuracy ของแต่ละโมเดลในงานวิจัย

จากภาพที่ 15 จะเห็นได้ว่าการทำ DBSCAN กับ Random Forest ให้ผลที่ดีมาก ส่วนการจัดการ Outlier มีผลต่อการเทรนนิ่งโมเดล

บทที่ 3

วิธีดำเนินการวิจัย

การศึกษาวิจัยนี้เป็นการนำเสนอเครื่องมือช่วยในการของประมาณอายุใช้งานของมอเตอร์ไฟฟ้าด้วยเทคนิคการเรียนรู้เชิงลึก (Deep learning) โดยมีแนวทางการวิจัยดังนี้

3.1 การนำเข้าข้อมูลจาก Sensor

โดยปกติข้อมูลที่จะใช้ **Sensor** ไปวัดค่าจากมอเตอร์ไฟฟ้า ซึ่งค่าที่วัดจะเป็นอุณหภูมิ แรงสั่น ความดัน เป็นต้น หลังจากได้ค่าจาก **Sensor** มา ก็จะนำไปบันทึกข้อมูลลง **Server** ไว้ แต่เนื่องจากข้อมูลส่วนนี้ ถือเป็นความลับจึงทำให้งานวิจัยนี้ใช้ข้อมูลจำลองที่มีรูปแบบใกล้เคียงกับข้อมูลจริงจาก **Kaggle**



- 1 Vibration
- 2 Temperature
- 3 Relative humidity
- 4 Ambient pressure

ภาพที่ 3.1 (ซ้าย) ตัวอย่าง Sensor ที่ใช้วัด (ขวา) ตัวอย่างข้อมูลที่ได้จาก Sensor

ที่มา: <https://www.balluff.com/en/de/products/product-news-overview/product-news/condition-monitoring-sensor/>

timestamp	sensor_00	sensor_01	sensor_02	sensor_03	sensor_04	sensor_05	machine_status
04-01-18 0:00	2.465394	47.09201	53.2118	46.31076	634.375	76.45975	NORMAL
04-01-18 0:01	2.465394	47.09201	53.2118	46.31076	634.375	76.45975	NORMAL
04-01-18 0:02	2.444734	47.35243	53.2118	46.39757	638.8889	73.54598	NORMAL
04-01-18 0:03	2.460474	47.09201	53.1684	46.39756775	628.125	76.98898	NORMAL
04-01-18 0:04	2.445718	47.13541	53.2118	46.39756775	636.4583	76.58897	NORMAL
04-01-18 0:05	2.453588	47.09201	53.1684	46.39756775	637.6157	78.18568	NORMAL
04-01-18 0:06	2.455556	47.04861	53.16839981	46.39756775	633.3333	75.81614	NORMAL
04-01-18 0:07	2.449653	47.13541	53.16839981	46.39756775	630.6713	75.77331	NORMAL
04-01-18 0:08	2.463426	47.09201	53.16839981	46.39756775	631.9444	74.58916	NORMAL
04-01-18 0:09	2.445718	47.17882	53.1684	46.39756775	641.7823	74.57428	NORMAL
04-01-18 0:10	2.46441	47.48264	53.125	46.39756775	637.7314	76.05148	NORMAL
04-01-18 0:11	2.444734	47.91666	53.1684	46.39756775	635.6482	74.58654	NORMAL
04-01-18 0:12	2.460474	48.26389	53.125	46.39756775	630.0926	76.95988	NORMAL
04-01-18 0:13	2.448669	48.4375	53.1684	46.39756775	638.6574	75.6731	NORMAL
04-01-18 0:14	2.453588	48.56771	53.1684	46.39756775	632.4074	80.65949	NORMAL
04-01-18 0:15	2.455556	48.3941	53.125	46.39757	642.3611	78.13193	NORMAL
04-01-18 0:16	2.449653	48.3941	53.1684	46.31076	630.2084	77.89381	NORMAL

ภาพที่ 3.2 ตัวอย่างข้อมูลจำลองที่นำมาใช้

ที่มา: <https://www.kaggle.com/imtquentin/pump-sensor-predictive-maintenance-lstm-network/data>

3.2 การเตรียมข้อมูลสำหรับสอนระบบ

3.2.1 การจัดการ Missing Data

ในงานวิจัยนี้ ใช้การจัดการ Missing Data แบบ Listwise Deletion ซึ่งวิธีนี้ก็จะลบข้อมูลที่เป็น Missing Data ทั้งหมดออกไปที่ใช้วิธีนี้เนื่องจากข้อมูลจำลองเป็นข้อมูล Missing Data ที่หายไปทั้งแถวจึงไม่สามารถใช้วิธีอื่นได้ แต่ในกรณีที่มีข้อมูลจริงมีข้อมูลในรูปแบบอื่นอาจจะใช้วิธีอื่น เช่น Last observation carried forward (LOCF) คือการนำค่าก่อนที่จะเกิด Missing Data มาแทนค่าเป็นต้น

3.2.2 การแปลงข้อมูล Timestamp ให้เป็นรูปแบบ Datetime

หลังจากนั้นทำการหาค่า RUL จากการนับวันที่สถานะของมอเตอร์ไฟฟ้าเป็นปกติไปจนถึงวันที่สถานะของมอเตอร์ไฟฟ้ามีปัญหา เพื่อหาช่วงเวลาในการทำ Label ในส่วนถัดไป

3.2.3 คำนวณหาค่า RUL (Remain Useful Lifetime)

หลังจากนั้นทำการหาค่า RUL จากการนับวันที่สถานะของมอเตอร์ไฟฟ้าเป็นปกติไปจนถึงวันที่สถานะของมอเตอร์ไฟฟ้ามีปัญหา เพื่อหาช่วงเวลาในการทำ Label ในส่วนถัดไป


```

0      11 days 21:55:00
1      11 days 21:54:00
2      11 days 21:53:00
3      11 days 21:52:00
4      11 days 21:51:00
...
17151  0 days 00:04:00
17152  0 days 00:03:00
17153  0 days 00:02:00
17154  0 days 00:01:00
17155  0 days 00:00:00
Name: timestamp, Length: 17156, dtype: timedelta64[ns]

```

ภาพที่ 3.3 ผลที่ได้จากการหา RUL (Remain Useful Lifetime)

3.2.4 ทำการสร้าง Label

ต่อมาในขั้นตอนนี้จะทำการสร้าง Label จาก RUL ที่คำนวณได้จากข้อ 3.2.2 โดยวิธีสร้าง Label นั้นจะนำเอาค่า RUL ที่ได้ดูว่าอยู่ในช่วงวันที่ต้องการทำนายหรือไม่ โดยจากตัวอย่างสมมติว่าถ้าใช้ช่วงที่ต้องการทำนายที่ 4 วัน ถ้า RUL อยู่ในช่วง 4 วันดังนั้นจะสร้าง Label เท่ากับ 1

sensor_46	sensor_47	sensor_48	sensor_49	sensor_51	machine_rul	label1
37.90509	37.32639	175.3472	71.46991	243.0556	NORMAL 4 days 00:11:00	0
38.19444	37.32639	177.9514	72.62731	245.081	NORMAL 4 days 00:10:00	0
38.77315	37.32639	176.794	74.07407	247.6852	NORMAL 4 days 00:09:00	0
38.77315	37.32639	175.0579	74.36343	250.2894	NORMAL 4 days 00:08:00	0
38.77315	36.74768	171.875	75.52084	253.4722	NORMAL 4 days 00:07:00	0
38.77315	36.45833	170.7176	76.38889	256.6551	NORMAL 4 days 00:06:00	0
38.77315	36.45833	171.0069	76.67824	259.2592	NORMAL 4 days 00:05:00	0
38.77315	36.45833	173.9005	76.67824	261.5741	NORMAL 4 days 00:04:00	0
38.19444	36.45833	177.0833	76.67824	263.8889	NORMAL 4 days 00:03:00	0
38.19444	36.45833	179.3981	77.25694	265.3356	NORMAL 4 days 00:02:00	0
38.19444	36.45833	182.8704	78.125	267.6505	NORMAL 4 days 00:01:00	0
37.90509	36.16898	185.4745	77.83565	269.6759	NORMAL 4 days 00:00:00	1
37.90509	36.16898	187.2106	76.96759	273.1481	NORMAL 3 days 23:59:00	1

ภาพที่ 3.4 ผลที่ได้จากการสร้าง Label ที่กำหนดช่วงเวลาทำนายที่ 4 วัน

3.2.5 ทำการ Normalization

ในโมเดลการเรียนรู้เชิงลึก ขนาดความต่างของข้อมูลมีผลต่อการเทรนนิ่งโมเดล ดังนั้นเราจึงต้องทำการ Normalize Feature ก่อนเข้าเทรนนิ่ง โดยใช้การ Min-Max Scaler ทำในส่วน Feature ที่เป็น Sensor ทั้งหมด

3.2.6 ทำการแบ่งข้อมูล Train-Test

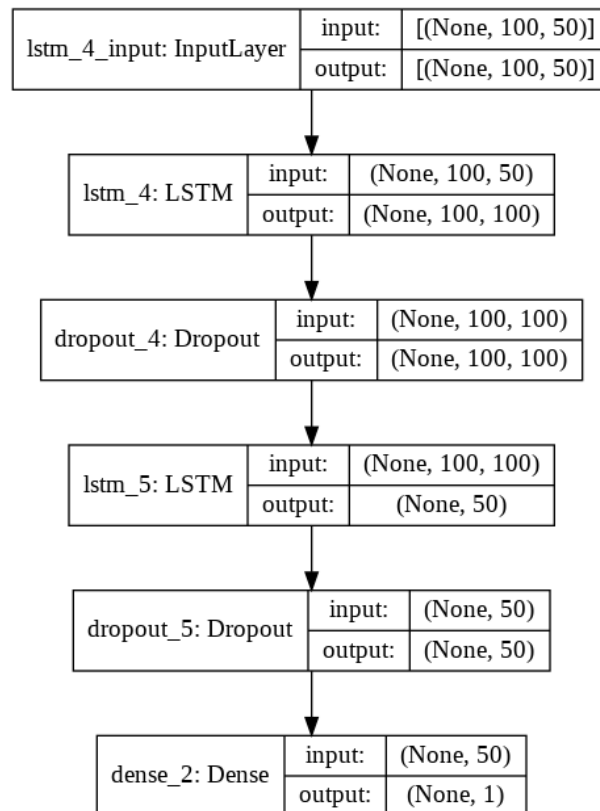
ทำการแบ่งข้อมูล Train-Test ที่อัตราส่วน 70:30

3.3 การสร้างโมเดลประมาณอายุใช้งานของมอเตอร์ไฟฟ้า

หลังจากเตรียมข้อมูลเรียบร้อยแล้วก็เริ่มเข้าสู่กระบวนการสร้าง โมเดล ซึ่งมีรายละเอียดดังนี้

3.3.1 สร้าง Network ของโมเดล LSTM

Layer แรกจะใช้ LSTM ที่ 100 unit ตามจำนวนของ Input Sequence ตามด้วย LSTM ที่มี Layer 50 Unit และใช้ Dropout ในแต่ละ LSTM Layer เพื่อควบคุมเรื่อง Overfitting และส่วนสุดท้ายที่เป็น Dense ก็จะใช้ Sigmoid เพื่อสอดคล้องกับการแยกประเภทข้อมูล Binary Classification



ภาพที่ 3.5 แสดง Network ของ LSTM ที่ใช้ในงานวิจัย

3.3.1 การเทรนข้อมูล (Model Training)

ในขั้นตอนการเทรนโมเดล เราจะนำข้อมูลที่แบ่งไว้สำหรับการเทรนโดยใช้ Parameter ตามตารางที่ 3.1

ตารางที่ 3.1 ค่า Parameter ต่างๆ ของโมเดล LSTM

Parameter	Value
Epochs	10
Batch Size	200
Validation Split	0.1
Verbose	1
Loss	Binary Crossentropy
Optimizer	Adam

3.4 การประมาณอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้าผ่าน Web UI

ในการนำโมเดลที่ได้จากข้อ 3.3 ไปใช้ประมาณอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้า จะใช้ผ่านโปรแกรมที่สร้างขึ้นในรูปแบบ Web User interface โดยโปรแกรมจะมีส่วนให้ทาง User อัปโหลดไฟล์ Data ผ่าน Web หลังอัปโหลดข้อมูลเรียบร้อยแล้ว เมื่อกดยืนยันก็จะทำการเทรนโมเดล และแจ้งผลการประมาณออกมากกว่ามีโอกาสมอเตอร์ไฟฟ้าจะเกิดปัญหาในระยะเวลาที่กำหนดไว้หรือไม่

Predictive Maintenance

Please input dates that need to predict:

No file chosen

ภาพที่ 3.6 ตัวอย่างโปรแกรมรูปแบบ Web User Interface ในการนำไปใช้งาน

3.5 เครื่องมือที่ใช้ในงานวิจัย

3.5.1 ภาษาไพธอน (Python)

Python เป็นภาษาคอมพิวเตอร์ภาษาหนึ่งที่นิยมใช้ และเหมาะสำหรับการทำ Data Science มาก เนื่องจากมี Package ของชุดคำสั่งที่สามารถเลือกให้เหมาะกับงานอยู่มากมาย และภาษายังเข้าใจง่าย เหมาะกับมือใหม่

3.5.2 Jupyter Notebook

เป็นเครื่องมือ opensource ที่ใช้ในการสร้าง Reproducible Document ซึ่งก็คือเอกสารที่มีคำอธิบายและ code ที่สามารถ execute ได้ เพื่อทำการทดลองซ้ำและสามารถดูผลการทดลองได้ ทั้ง กับข้อมูลชุดเดิมหรือข้อมูลชุดใหม่ได้ โดย Jupyter สามารถเขียน source code เป็น block สั้นๆ และ เขียนอธิบายแต่ละส่วนด้วย markdown ได้ ซึ่ง Jupyter ได้สร้างระบบ kernel ที่ให้นักพัฒนาเขียน configuration เพื่อใช้งานกับภาษาหรือระบบได้หลากหลาย

บทที่ 4

ผลการดำเนินงานวิจัย

จากการพัฒนาโมเดลสำหรับการประมาณอายุการใช้งานที่เหลือของมอเตอร์ไฟฟ้าเพื่อวางแผนในการซ่อมบำรุงอย่างมีประสิทธิภาพ โดยนำเอาการเรียนรู้เชิงลึกโมเดล LSTM หลังจากนั้นมาประยุกต์ทำในรูปแบบ **Web User Interface** เพื่อความสะดวกในการใช้งาน ผลการศึกษามีรายละเอียดดังนี้

4.1 ผลการวัดประสิทธิภาพของโมเดล

ข้อมูลที่ได้หลังจากการเตรียมข้อมูลและการทำ Label เราจะได้จำนวนข้อมูลอยู่ที่ 166,441 แถว โดยจะแบ่งข้อมูลสำหรับการสอนระบบ (Training Data) 70% จำนวน 116,500 แถว และสำหรับการทดสอบโมเดล (Test Data) 30% จำนวน 49,941 แถว

จากการทดสอบโมเดลให้ผลการทดสอบโมเดลโดยวิธี Confusion Matrix ได้ค่าดังตารางที่ 4.1

ตารางที่ 4.1 ตารางแสดงผลการทดสอบประสิทธิภาพของโมเดล

Indicator	Value
Accuracy	93.9%
Precision	89.9%
Recall	62.5%
F1-Score	73.7%

จากค่า Parameter ในตารางที่ 1 เราจะได้ผลทดสอบ Confusion Matrix ที่
Accuracy = 93.9% , Precision = 89.9% , Recall = 62.5% และ F1-Score = 73.7%

4.2 ผลการวัดประสิทธิภาพของโมเดลเมื่อปรับเปลี่ยนค่า Parameter

หลังจากที่ได้ผลการศึกษาในชุดแรกแล้ว ทางผู้ศึกษาจึงได้ทำการทดลองปรับเปลี่ยน Parameter เพื่อดูผลเปรียบเทียบว่าให้ค่าที่แตกต่างกันอย่างไร โดยค่าที่ใช้เป็นดังตารางที่ 4.2

ตารางที่ 4.2 ค่า Parameter ต่างๆที่ปรับเปลี่ยนของ โมเดล LSTM

Parameter	Value
Epochs	20
Batch Size	400
Validation Split	0.2
Verbose	1
Loss	Binary Crossentropy
Optimizer	Adam

ตารางที่ 4.3 ตารางแสดงผลการทดสอบประสิทธิภาพของโมเดลหลังปรับเปลี่ยน Parameter

Indicator	Value
Accuracy	97.0%
Precision	91.0%
Recall	99.7%
F1-Score	95.4%

4.3 ผลการวัดความพึงพอใจของผู้ใช้งาน

การวัดผลความพึงพอใจของผู้ใช้งาน ทำการวัดผลจากทีมงานซ่อมบำรุง โดยทำการวัดผลด้วยคำถามจำนวน 5 ข้อและข้อเสนอแนะอีก 1 ข้อ ซึ่งมีรายละเอียดดังนี้

4.3.1 คำถาม (Questionnaire) วัดความพึงพอใจ


1. โดยรวมแล้ว ท่านชอบโปรแกรมการประมาณอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้านี้หรือไม่
2. โปรแกรมการประมาณอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้านี้ ตรงกับความต้องการในการทำงานของท่านหรือไม่
3. โปรแกรมนี้ทำให้การซ่อมบำรุงมีประสิทธิภาพมากขึ้นกว่าวิธีการเดิมของท่านหรือไม่
4. โปรแกรมนี้มีขั้นตอนการใช้งานที่สะดวกและง่ายหรือไม่
5. ท่านคิดว่า ท่านจะแนะนำให้ทีมงานที่ทำงานเดียวกันกับท่านต่อหรือไม่

4.3.2 กลุ่มเป้าหมาย (Target group) ทั้งหมด 5 คนเป็น ทีมงานซ่อมบำรุง โรงงานอุตสาหกรรม จำนวน 5 ท่าน

4.3.3 สรุปความคิดเห็นและข้อเสนอแนะสำหรับผลิตภัณฑ์ ทีมงานซ่อมบำรุง โรงงานอุตสาหกรรม จำนวน 5 ท่าน

4.3.4 ผลประเมินความพอใจ

จากผลการสำรวจความพึงพอใจของผู้ได้ทดลองใช้งาน พบว่าโดยรวมแล้ว ผู้ใช้ชอบระบบนี้มากที่สุด 20% ชอบมาก 80% และระบบนี้เป็นโปรแกรมที่ตรงกับความต้องการของผู้ใช้งานมากที่สุด 40% ตรงความต้องการมาก 60% นอกจากนี้ผู้ทำงานยังให้คะแนนเรื่องระบบนี้ทำให้การซ่อมบำรุงมีประสิทธิภาพขึ้นหรือไม่ เห็นด้วยมาก 60% ปานกลาง 40% ส่วนมุมมองต่อการใช้งานของระบบ พบว่าระบบมีการใช้งานที่ง่ายมากที่สุด 20% ใช้งานง่ายปานกลาง 20% ในข้อสุดท้ายสำหรับการแนะนำให้กับผู้อื่นพบว่า ผู้ใช้งานจะแนะนำต่อแน่นอน(มากที่สุด) 20% จะแนะนำต่อ(มาก) 80% โดยคะแนนในภาพรวมแสดงดังภาพที่ 4.1



ภาพที่ 4.1 กราฟแสดงผลการวัดความพึงพอใจของผู้ทดลองใช้งาน

บทที่ 5

สรุปผล อภิปรายผลและข้อเสนอแนะ

งานวิจัยนี้ ได้นำเสนอเกี่ยวกับการพัฒนาระบบเครื่องมือเพื่อช่วยในการประมาณอายุการใช้งานที่เหลือของมอเตอร์ไฟฟ้าเพื่อช่วยเพิ่มประสิทธิภาพในการซ่อมบำรุง และช่วยให้เกิดประโยชน์ในการทำงาน ทั้งในเรื่องการคาดการณ์ว่ามอเตอร์ไฟฟ้าจะมีปัญหาได้แม่นยำมากขึ้น ใช้มอเตอร์ไฟฟ้าได้อย่างมีประสิทธิภาพตลอดอายุการใช้งาน ลดต้นทุนในการเก็บสินค้าคงคลัง โดยสามารถสรุปผลการวิจัยได้ดังนี้

5.1 สรุปผลการศึกษา

5.1.1 การพัฒนาเครื่องมือในประมาณอายุการใช้งานที่เหลือของมอเตอร์ไฟฟ้าประกอบด้วยขั้นตอนดังนี้

1. ทำการเตรียมข้อมูลก่อนเข้าสู่กระบวนการเทรนนิ่งโมเดล ซึ่งการเตรียมข้อมูลเราทำได้ทำ Missing Data Handling , Data Conversion
2. ทำ Feature Engineering โดยการทำให้ Label ขึ้นมา, ทำ Normalization Feature ที่เป็น Sensor โดยวิธี Min-Max Scaler
3. ทำการเตรียม Network LSTM และทำการปรับ Parameter ของโมเดล LSTM
4. ทำการ Training Model และ Test กับข้อมูลเพื่อทดสอบการทำนายผลออกมา

5.1.2 ผลการทดลอง

จากผลการทดลองโมเดลให้ค่า Accuracy = 97% ค่า Precision = 91% ค่า Recall = 99.7% และค่า F-1 Score = 95.4%

5.2 ข้อเสนอแนะ

5.2.1 โมเดลที่ได้จากงานวิจัยนี้ทำโดยใช้ข้อมูลจำลอง อาจให้ผลที่แตกต่างกับข้อมูลจริงที่อยู่หน้างาน

5.2.2 งานวิจัยในกรณีที่เป็นข้อมูลจริงควรคำนึงถึงเรื่อง Imbalance Data ด้วยเพราะโดยปกติข้อมูลที่บอกวามอเตอร์ไฟฟ้ามีปัญหาจะเกิดขึ้นไม่เยอะ ซึ่งในงานวิจัยนี้อัตราส่วนข้อมูลที่บอกวามสถานะปกติ : สถานะผิดปกติเท่า 205836 : 7 ซึ่งในอนาคตถ้ามีการนำวิธีการจัดการ Imbalance Data มาใช้ร่วมก่อนนำเข้าโมเดล อาจจะทำให้โมเดลแม่นยำมากขึ้น

5.2.3 อาจให้มีการ Interface กับระบบ ERP หรือระบบสั่งซื้อได้ในกรณีที่มอเตอร์เริ่มทำนายแล้วว่าจะมีปัญหาในเวลาที่กำหนด

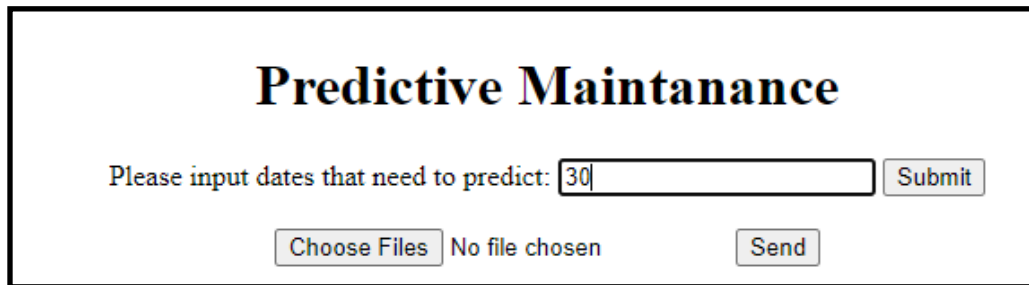
บรรณานุกรม

บรรณานุกรม

- Divish Rengasamy , Mina Jafari , Benjamin Rothwell , Xin Chen andGrazziela P. Figueredo (2020): Deep Learning with Dynamically Weighted Loss Function for Sensor-Based Prognostics and Health Management [MDPI]
- Gustavo Scalabrini Sampaio , Arnaldo Rabello de Aguiar Vallim Filho ,Leilton Santos da Silva and Leandro Augusto da Silva (2018): Prediction of Motor Failure Time Using An Artificial Neural Network [MDPI]
- Shang-Yi Chuang , Nilima Sahoo , Hung-Wei Lin and Yeong-Hwa Chang (2019) :Predictive Maintenance with Sensor Data Analytics on a Raspberry Pi-Based Experimental Platform [MDPI]
- Xanthi Bampoula , Georgios Siaterlis , Nikolaos Nikolakis and Kosmas Alexopoulos (2021) : A Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders
- Yassine Bouabdallaoui , Zoubeir Lafhaj , Pascal Yim , Laure Ducoulombier and Belkacem Bennadji (2021) : Predictive Maintenance in Building Facilities: A Machine Learning-Based Approach

ภาคผนวก

ตัวอย่างแอปพลิเคชันที่นำมาใช้งานในการทำนายอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้า

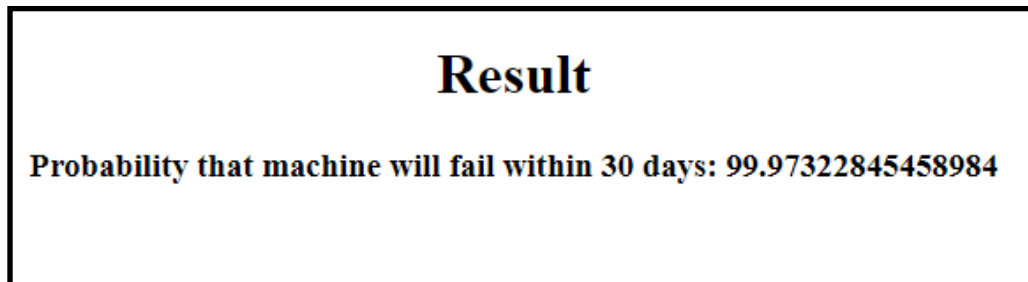


Predictive Maintenance

Please input dates that need to predict:

No file chosen

ภาพที่ 1 ตัวอย่างแอปพลิเคชันที่รันบน Web UI



Result

Probability that machine will fail within 30 days: 99.97322845458984

ภาพที่ 2 ผลลัพธ์ที่ได้จากการรันข้อมูลตัวอย่าง

ประวัติผู้เขียน

ชื่อ-นามสกุล	นิติรัฐ สุกีธร
ประวัติการศึกษา	วิศวกรรมศาสตรบัณฑิต คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ปีการศึกษา 25
ตำแหน่งและสถานที่ทำงาน	หน่วยงาน อุตสาหกรรมดิจิทัล บริษัทซีเมนส์ (ประเทศไทย) จำกัด ตั้งแต่ปี พ.ศ.2564 - ปัจจุบัน