

การซ่อมบำรุงรักษาเชิงคาดการณ์มอเตอร์ไฟฟ้าโดยใช้โมเดลการเรียนรู้เชิงลึก

PREDICTIVE MAINTENANCE FOR INDUCTION MOTORS USING DEEP LEARNING TECHNIQUES

นิติรัฐ สุภิช
ดร.ธนภัทร มังคะจิตร

บทคัดย่อ

มอเตอร์ไฟฟ้าเป็นอุปกรณ์สำคัญอย่างหนึ่งในโรงงานอุตสาหกรรมซึ่งทำให้กระบวนการผลิตทำงานได้อย่างต่อเนื่อง ในกรณีที่อุปกรณ์เสียหายก่อนกำหนดการเปลี่ยนย่อมทำให้เกิดความเสียหายต่อกระบวนการผลิต งานวิจัยก่อนหน้านี้ได้นำเสนอให้เห็นถึงต้นทุนของการบำรุงรักษาเชิงคาดการณ์ที่ต่ำกว่าการบำรุงเชิงป้องกัน รวมถึงการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกแบบ LSTM ในการทำนายช่วงเวลาบำรุงรักษาเชิงคาดการณ์ที่มีประสิทธิภาพ

งานวิจัยนี้จึงเสนอโปรแกรมผ่านเว็บสำหรับคาดการณ์อายุการใช้งานที่เหลืออยู่ของมอเตอร์ไฟฟ้าจากข้อมูลจากเซนเซอร์ด้วยเทคนิคการเรียนรู้เชิงลึก โดยให้ผู้ใช้งานส่งไฟล์ข้อมูลขึ้นมาในระบบโมเดลก็จะทำนายว่ามอเตอร์ไฟฟ้าจะเกิดปัญหาในช่วงเวลาที่กำหนดหรือไม่ ส่งผลให้ผู้ที่เกี่ยวข้องสามารถเตรียมแผนดำเนินการให้เหมาะสมกับแผนงานผลิตได้ การทดสอบกับข้อมูลจำลองพบว่าแบบจำลองให้ผลการทำนายที่แม่นยำสำหรับทำนายการเสียหายของอุปกรณ์ในช่วงเวลาระยะสั้น ในขณะที่ยังให้ความแม่นยำค่อนข้างต่ำสำหรับการคาดการณ์การเสียหายของอุปกรณ์ในระยะยาว ดังนั้นจึงควรนำผลจากการทำนายของแบบจำลองในลักษณะเชิงคาดการณ์มาวางแผนร่วมกับการบำรุงรักษาเชิงป้องกันซึ่งจะทำให้สามารถลดต้นทุนและรักษากระบวนการผลิตให้ทำงานได้อย่างต่อเนื่อง

คำสำคัญ : การซ่อมบำรุงเชิงคาดการณ์ การเรียนรู้เชิงลึก การคาดการณ์อายุการใช้งาน
มอเตอร์ไฟฟ้า

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.

Keywords: Predictive Maintenance, Deep Learning, RUL (Remain Useful Life), Electrical Motor

บทนำ

ในปัจจุบันมอเตอร์ไฟฟ้าถือเป็นอุปกรณ์ที่สำคัญในโรงงานอุตสาหกรรม ไม่ว่าจะเป็นในกระบวนการผลิต ส่วนอำนวยความสะดวก เพราะฉะนั้นเมื่อมอเตอร์เกิดปัญหาขึ้นมาจึงมีผลกระทบในหลายส่วนงานเป็นอย่างมาก การซ่อมบำรุงจึงถือเป็นการช่วยให้กระบวนการผลิตทำงานได้โดยที่มีการหยุดงานน้อยที่สุด รวมถึงการใช้มอเตอร์อย่างคุ้มค่าที่สุด

โดยทั่วไปการซ่อมบำรุงมอเตอร์ จะใช้วิธีกำหนดเป็นช่วงเวลาที่ซ่อมหรือเปลี่ยนมอเตอร์ทุกกี่เดือน ซึ่งวิธีนี้ในกรณีที่มอเตอร์เกิดปัญหาก่อนถึงช่วงเวลาซ่อมบำรุง ก็จะส่งผลในเรื่องกระบวนการผลิตที่ต้องหยุด , ระยะเวลาการสั่งซื้อมอเตอร์ตัวใหม่เข้ามา ทำให้เกิดการสูญเสียรายได้จากการผลิตที่ต้องหยุดไป

อย่างไรก็ตาม งานวิจัยก่อนหน้านี้ได้ทำการเปรียบเทียบต้นทุนที่เกิดขึ้นระหว่างการซ่อมบำรุงรักษาแบบเชิงป้องกันและการซ่อมบำรุงรักษาแบบเชิงคาดการณ์พบว่าต้นทุนจากการซ่อมบำรุงเชิงป้องกันมากกว่าแบบเชิงคาดการณ์ในทุกด้านไม่ว่าจะเป็นต้นทุนในการเก็บสินค้า ต้นทุนในการจัดซื้อ ต้นทุนที่เกิดจากการหยุดผลิต

งานวิจัยนี้จึงเสนอโปรแกรมผ่านเว็บสำหรับคาดการณ์อายุการใช้งานที่เหลืออยู่ของมอเตอร์ไฟฟ้าจากข้อมูลจากเซนเซอร์ด้วยเทคนิคการเรียนรู้เชิงลึก โดยให้ผู้ใช้งานส่งไฟล์ข้อมูลขึ้นมาในระบบ โมเดลก็จะทำนายว่ามอเตอร์ไฟฟ้าจะเกิดปัญหาในช่วงเวลาที่กำหนดหรือไม่ ส่งผลให้ผู้ที่เกี่ยวข้องสามารถเตรียมแผนดำเนินการให้เหมาะสมกับแผนงานผลิตได้

วัตถุประสงค์

เพื่อทำเครื่องมือประมาณความน่าจะเป็นอายุใช้งานที่เหลือในเวลาที่กำหนดของมอเตอร์ไฟฟ้า โดยทำการนำข้อมูลต่างๆที่ดึงมาจากเซนเซอร์ มาทำโมเดลด้วยเทคนิคการเรียนรู้เชิงลึก หลังจากนั้นนำข้อมูลของมอเตอร์ไฟฟ้าแต่ละชุดมาเข้าโมเดล เพื่อตรวจสอบอายุการใช้งานที่เหลือ

ขอบเขตของการวิจัย

ข้อมูลที่นำมาใช้งานเป็นข้อมูลจำลอง ที่ได้นำมาจาก Kaggle ซึ่งเป็นข้อมูลที่คล้ายกับข้อมูลที่ได้รับจากหน่วยงานจริง

ประโยชน์ที่คาดว่าจะได้รับ

1. ทำให้การคาดการณ์เวลาที่อุปกรณ์จะเกิดปัญหามีความแม่นยำมากขึ้น
2. ใช้อุปกรณ์ได้อย่างมีประสิทธิภาพตลอดอายุการใช้งาน
3. ลดต้นทุนในการเก็บสต็อกของอุปกรณ์

แนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง


การศึกษาวิจัยนี้ เป็นการนำเสนอเทคนิคการประมาณอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้า ด้วยการประยุกต์ใช้การเรียนรู้เชิงลึก (Deep Learning) โดยจำเป็นต้องศึกษาเอกสารและงานวิจัยที่เกี่ยวข้อง ดังต่อไปนี้

1. 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 ของข้อมูลที่มีขนาดยาวเพราะปฏิกิริยาการอัปเดตค่า weights ก็จะใช้วิธี Backpropagation Algorithm ซึ่งจะคำนวณ gradient ของ loss function เพื่อมาอัปเดตค่า weights ซึ่งการคำนวณจะเกิดมาจากช่วงเวลาก่อนหน้าด้วย ส่งผลให้เกิดค่า gradient ที่ลดลงไปตามจำนวน sequence หรือที่เรียกว่า gradient vanishing

โมเดล LSTM จึงแก้ปัญหา gradient vanishing โดยส่วน memory ของ LSTM สามารถกำหนดได้ว่าเมื่อที่ memory นี้จะทำการจำหรือลบทิ้งไปจาก gates ต่างๆที่ประกอบใน โมเดลซึ่งมีรายละเอียดดังนี้

1. Input Gate เป็นตัวบอกว่าจะอัปเดตค่าหรือไม่
2. Forget Gate ถ้ามีค่าเป็น 0 ก็จะลบ cell state ทิ้ง ถ้ามีค่าเป็น 1 ก็จะเก็บ cell state นั้นไว้
3. Output Gate เป็นตัวกำหนดว่าจะนำ hidden state ณ เวลา t ไปคำนวณกับ Input data ที่เข้ามาใหม่หรือไม่



ภาพที่ 1 โครงสร้างเลเยอร์ของโมเดล LSTM (Sirinart Tangruamsub - 2017)

งานวิจัยที่เกี่ยวข้อง

Khanh T.P. Nguyen, Kamal Medjaher (2019) งานวิจัยนี้ได้ทำการศึกษา Framework ในรูปแบบ Dynamic Predictive Maintenance นำเสนอต้นทุนที่แตกต่างกันสำหรับการซ่อมบำรุง เพื่อให้เห็นประโยชน์ของการนำการบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) ไปประยุกต์ใช้ในโรงงานซึ่งจากผลการทดลองแสดงให้เห็นว่าต้นทุนของการบำรุงรักษาเชิงป้องกัน (Preventive Maintenance) จะสูงกว่าการบำรุงรักษาเชิงคาดการณ์

Michal Markiewicz, Maciej Wielgosz, Mikolaj Bochenski, Waldemar Tabaczynski, Tomasz Konieczny, and Liliana Kowalczyk (2019) งานวิจัยนี้ได้ทำการศึกษา โมเดลที่นำมาใช้กับงาน Predictive Maintenance ที่เป็นรูปแบบ Time Series จากผลการทดลองที่ทำการเปรียบเทียบกันระหว่างโมเดลพบว่าโมเดล LSTM ให้ผล Accuracy และ F1-Score ที่ค่อนข้างดี เพราะ LSTM เหมาะกับข้อมูลที่เป็น Sequence แบบ Time Series หรือ NLP เนื่องจากแก้ปัญหา Gradient Vanishing

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 วันพบว่าช่วงของ Window Length ที่ต่างกันก็จะส่งผลให้ค่า Accuracy ของโมเดล แตกต่างกันด้วย และก็ไม่จำเป็นว่า Window Length ที่มากขึ้นจะให้ค่า Accuracy ที่มากขึ้นด้วยและยังเกี่ยวข้องกับจำนวนของข้อมูลด้วยคือ ถ้าข้อมูลจำนวนน้อยก็จะทำให้โมเดลใช้งานได้ไม่ดี ถ้าข้อมูลเยอะเกินไปก็จะทำให้ใช้เวลานานหรือแย่กว่านั้นคือประสิทธิภาพของโมเดลลดลงอีกด้วย

ระเบียบวิธีวิจัย

การศึกษาวิจัยนี้เป็นการนำเสนอเครื่องมือช่วยในการของประมาณอายุใช้งานของมอเตอร์ไฟฟ้าด้วยเทคนิคการเรียนรู้เชิงลึก (Deep learning) โดยมีแนวทางการวิจัยดังนี้

1.การนำเข้าข้อมูลจาก Sensor

โดยปกติข้อมูลที่จะใช้ Sensor ไปวัดค่าจากมอเตอร์ไฟฟ้า ซึ่งค่าที่วัดจะเป็นอุณหภูมิ แรงดัน ความดัน เป็นต้น หลังจากได้ค่าจาก Sensor มา ก็จะนำไปบันทึกข้อมูลลง Server ไว้ แต่เนื่องจากข้อมูลส่วนนี้ถือเป็นความลับจึงทำให้งานวิจัยนี้ใช้ข้อมูลจำลองที่มีรูปแบบใกล้เคียงกับข้อมูลจริงจาก Kaggle



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

ภาพที่ 2 ตัวอย่าง Sensor ที่ใช้วัด (ขวา) ตัวอย่างข้อมูลที่ได้จาก Sensor

2. การเตรียมข้อมูลสำหรับสอนระบบ

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

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 ผลที่ได้จากการหา RUL (Remain Useful Lifetime)

ต่อมาในขั้นตอนนี้จะทำการสร้าง Label จาก RUL ที่คำนวณได้จากข้อ 2 โดยวิธีสร้าง

Label นั้นจะนำเอาค่า RUL ที่ได้ดูว่าอยู่ในช่วงวันที่ต้องการทำนายหรือไม่ โดยจากตัวอย่างสมมติว่า ถ้าใช้ช่วงที่ต้องการทำนายที่ 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 4 ผลที่ได้จากการสร้าง Label ที่กำหนดช่วงเวลาทำนายที่ 4 วัน


หลังจากนั้นก็จะทำการ Normalization และแบ่งข้อมูล Train และ Test ตามอัตราส่วน 70:30 ก่อนเข้าสู่กระบวนการสร้างโมเดล

3. การสร้างโมเดลประมาณอายุใช้งานของมอเตอร์ไฟฟ้า

หลังจากเตรียมข้อมูลเรียบร้อยแล้วก็เริ่มเข้าสู่กระบวนการสร้างโมเดล ซึ่งมีรายละเอียดดังนี้

ขั้นตอนที่ 1 สร้าง Network ของโมเดล LSTM โดยมีรายละเอียด ดังนี้

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



ภาพที่ 5 แสดง Network ของ LSTM ที่ใช้ในงานวิจัย

ขั้นตอนที่ 2 การเทรนข้อมูล (Model Training)

ในขั้นตอนการเทรนโมเดล จะใช้ข้อมูลที่แบ่งไว้สำหรับการเทรนโดยใช้ Parameter ตามตารางที่ 2

ตารางที่ 2 ค่า Parameter ต่างๆ ของโมเดล LSTM

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

ขั้นตอนที่ 3 การทำ Web User Interface

การประมาณอายุใช้งานที่เหลือของมอเตอร์ไฟฟ้า จะใช้ผ่านโปรแกรมที่สร้างขึ้นมาในรูปแบบ Web User interface โดยโปรแกรมจะมีส่วนให้ทาง User อัปโหลดไฟล์ Data ผ่าน Web หลังอัปโหลดข้อมูลเรียบร้อย เมื่อกดยืนยันก็จะทำการเทรน โมเดล และแจ้งผลการประมาณออกมา
กว่ามีโอกาสมอเตอร์ไฟฟ้าจะเกิดปัญหาในระยะเวลาที่กำหนดไว้หรือไม่

ผลการวิจัย

1. ผลการวัดประสิทธิภาพของโมเดล

ข้อมูลที่ได้หลังจากการเตรียมข้อมูลและการทำ Label จะได้จำนวนข้อมูลอยู่ที่ 166,441 แถว โดยจะแบ่งข้อมูลสำหรับการสอนระบบ (Training Data) 70% จำนวน 116,500 แถว และสำหรับการทดสอบโมเดล (Test Data) 30% จำนวน 49,941 แถว จากการทดสอบโมเดลให้ผลการทดสอบโมเดลโดยวิธี Confusion Matrix ได้ค่าดังตารางที่ 3

ตารางที่ 3 ตารางแสดงผลการทดสอบประสิทธิภาพของโมเดล

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

2. ผลการวัดประสิทธิภาพของโมเดลเมื่อปรับเปลี่ยนค่า Parameter

หลังจากที่ได้ผลการศึกษาในชุดแรกแล้ว ทางผู้ศึกษาจึงได้ทำการทดลองปรับเปลี่ยน Parameter เพื่อดูผลเปรียบเทียบว่าให้ค่าที่แตกต่างกันอย่างไร โดยค่าที่ใช้เป็นดังตารางที่ 3

ตารางที่ 4 ค่า Parameter ต่างๆที่ปรับเปลี่ยนของโมเดล LSTM

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

ตารางที่ 5 ตารางแสดงผลการทดสอบประสิทธิภาพของโมเดลหลังปรับเปลี่ยน Parameter

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

สรุปและอภิปรายผลการวิจัย

งานวิจัยนี้ได้นำเสนอเกี่ยวกับการพัฒนาระบบเครื่องมือเพื่อช่วยในการประมาณอายุการใช้งานที่เหลือของมอเตอร์ไฟฟ้าเพื่อช่วยเพิ่มประสิทธิภาพในการซ่อมบำรุง ช่วยให้เกิดประโยชน์ในการทำงานทั้งในเรื่องการคาดการณ์ว่ามอเตอร์ไฟฟ้าจะมีปัญหาได้แม่นยำมากขึ้นอีกทั้งยังสามารถใช้มอเตอร์ไฟฟ้าได้อย่างมีประสิทธิภาพตลอดอายุการใช้งานรวมถึงการลดต้นทุนในการเก็บสินค้าคงคลัง โดยสามารถสรุปผลการวิจัยได้ดังนี้

สำหรับโมเดลการเรียนรู้เชิงลึกการเตรียมข้อมูลก่อนนำเข้าไประบบส่งผลต่อความแม่นยำของโมเดลเป็นอย่างมาก ไม่ว่าจะเป็นเรื่อง Data Missing Handling , การทำ Normalization รวมไปถึง

ถึงการปรับค่าพารามิเตอร์ของโมเดล LSTM ผลการทดลองให้ความแม่นยำของโมเดลให้ค่า Accuracy ที่ 97% ค่า Precision ที่ 91% ค่า Recall ที่ 99.7% ค่า F1-Score ที่ 95.4%

ข้อเสนอแนะ

1. โมเดลที่ได้จากงานวิจัยนี้ทำโดยใช้ข้อมูลจำลอง อาจให้ผลที่แตกต่างกับข้อมูลจริงที่อยู่บนงาน
2. งานวิจัยในกรณีที่เป็นข้อมูลจริงควรคำนึงถึงเรื่อง Imbalance Data ด้วยเพราะโดยปกติข้อมูลที่บอกว่ามอเตอร์ไฟฟ้ามีปัญหาจะเกิดขึ้นไม่เยอะ ซึ่งในงานวิจัยนี้อัตราส่วนข้อมูลที่บอกว่าสถานะปกติ : สถานะผิดปกติเท่า 205836 : 7 ซึ่งในอนาคตถ้ามีการนำวิธีการจัดการ Imbalance Data มาใช้รวมก่อนนำเข้าโมเดล อาจจะทำให้โมเดลแม่นยำมากขึ้น
3. อาจให้มีการ Interface กับระบบ ERP หรือระบบสั่งซื้อได้ในกรณีที่มอเตอร์เริ่มทำนายแล้วว่าจะมีปัญหาในเวลาที่กำหนด

บรรณานุกรม

- Ammar Azlan, Yuhanis Yusof and Mohamad Farhan Mohamad Mohsin. (2019). Determining the impact of window length on time series forecasting using deep learning. *International Journal of Advanced Computer Research*, 9(44), 2277-7970.
- Khanh T.P. Nguyen, Kamal Medjaher. (2019). A new dynamic predictive maintenance framework using deep learning for failure prognostics. *Elsevier*, 188, 251-262.
- Michal Markiewicz ,Maciej Wielgosz, Mikołaj Bochenski, Waldemar Tabaczynski, Tomasz Konieczny, and Liliana Kowalczyk. (2019). Predictive Maintenance of Induction Motors Using Ultra-Low Power Wireless Sensors and Compressed Recurrent Neural Networks. *IEEE Access*, 7, 178891-178902.