

การพยากรณ์ความเสียหายสเต็ปเปอร์มอเตอร์โดยใช้อัลกอริทึมการเรียนรู้ของเครื่อง
Stepper Motor Damage Prediction Using Machine Learning Algorithms

นพฤทธิ์ ศรีวิชัย* อนูปงศ์ สว่างนาค รุจิพันธุ์ โกษารัตน์ และ ปิยพล ยืนยงสถาวร
Nopparit Sriwichai*, Anupong Sawangnak, Rujipan Kosarat and Piyaphol
Yuenyongsathaworn

สาขาวิชาวิศวกรรมซอฟต์แวร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา
Bachelor of Engineering Program in Software Engineering, Faculty of Engineering, Rajamangala
University of Technology Lanna, Thailand
Email: nopparit_sr66@live.rmutl.ac.th

Received : February 15, 2025

Revised : May 15, 2025

Accepted : May 22, 2025

บทคัดย่อ

งานวิจัยนี้นำเสนอวิธีการพยากรณ์ความเสียหายของสเต็ปเปอร์มอเตอร์ในระบบอัตโนมัติสมัยใหม่ โดยเก็บข้อมูลจากเซนเซอร์ 5 ประเภท ได้แก่ กระแสไฟฟ้า แรงดันไฟฟ้า แรงบิด อุณหภูมิ และการสั่นสะเทือน พร้อมบันทึกข้อมูลวันที่ เวลา และค่าความผิดพลาดในการเคลื่อนที่ เป็นระยะเวลา 3 เดือน การวิจัยนี้เปรียบเทียบประสิทธิภาพของอัลกอริทึมการเรียนรู้ของเครื่อง 3 แบบ ได้แก่ เกรเดียนท์บูสต์ทรี (Gradient Boosted Trees) ดีปเลิร์นนิง (Deep Learning) และเอ็กซ์ตรีมเกรเดียนท์บูสต์ติง (Extreme Gradient Boosting) ผลการวิจัยพบว่า เกรเดียนท์บูสต์ทรีมีประสิทธิภาพสูงสุด สามารถอธิบายความแปรปรวนของข้อมูลได้ร้อยละ 91.17 และสามารถพยากรณ์โอกาสเกิดความเสียหายร้อยละ 90 ภายในระยะเวลา 5-6 เดือน การวิเคราะห์ความสำคัญของตัวแปรพบว่า ปัจจัยด้านเวลาและการสั่นสะเทือนมีผลต่อการเสื่อมสภาพของมอเตอร์มากที่สุด คิดเป็นร้อยละ 55.32 และ 28.35 ตามลำดับ ผลการวิจัยนี้สามารถนำไปประยุกต์ใช้ในการวางแผนบำรุงรักษาเชิงคาดการณ์ เพื่อลดการหยุดชะงักของสายการผลิตและเพิ่มประสิทธิภาพการผลิตโดยรวม

คำสำคัญ: สเต็ปเปอร์มอเตอร์ การพยากรณ์ความเสียหาย การเรียนรู้ของเครื่อง เกรเดียนท์บูสต์ทรี การบำรุงรักษาเชิงคาดการณ์

ABSTRACT

This study presents a method for predicting stepper motor failures in modern automation systems by collecting data from five types of sensors: current, voltage, torque, temperature, and vibration, along with timestamp records and motion error measurements over a three-month period. The study compares the performance of three machine learning algorithms: Gradient Boosted Trees, Deep Learning, and Extreme Gradient Boosting. The results indicate that Gradient Boosted Trees achieves the highest accuracy at 91.17% and can predict a 90% probability of failure within 5 to 6 months. Feature importance analysis reveals that temporal factors and vibration have the most significant impact on motor degradation, accounting for 55.32% and 28.35%, respectively. These findings can be applied to predictive maintenance planning to minimize unplanned production line downtime and enhance overall production efficiency.

Keywords: Stepper Motor, Failure Prediction, Machine Learning, Gradient Boosted Trees, Predictive Maintenance

บทนำ

ในยุคอุตสาหกรรม 4.0 ที่มีการใช้เทคโนโลยีการผลิตขั้นสูงและระบบอัตโนมัติ สเต็ปเปอร์มอเตอร์ถือเป็นหัวใจสำคัญในการขับเคลื่อน และควบคุมการทำงานของเครื่องจักรในอุตสาหกรรมหลากหลายประเภท ไม่ว่าจะเป็นเครื่องพิมพ์ 3 มิติ เครื่องจักร CNC หรือแขนกลอุตสาหกรรม (Rojko, 2017) การศึกษาที่ผ่านมาพบว่า การประยุกต์ใช้ปัญญาประดิษฐ์ และการเรียนรู้ของเครื่องในกระบวนการผลิตสมัยใหม่สามารถเพิ่มประสิทธิภาพการผลิตได้ถึงร้อยละ 25 (Wang et al., 2018) รวมถึงการบูรณาการระบบ IoT และเซนเซอร์เข้ากับการผลิตสมัยใหม่ช่วยเพิ่มประสิทธิภาพการเฝ้าระวัง และควบคุมคุณภาพได้อย่างมีนัยสำคัญ (Chen et al., 2017)

ด้วยคุณสมบัติที่โดดเด่นในการควบคุมตำแหน่งอย่างแม่นยำ และความสามารถในการทำงานแบบต่อเนื่อง ทำให้สเต็มเปเปอร์มอเตอร์เป็นอุปกรณ์ที่มีความสำคัญอย่างยิ่งต่อกระบวนการผลิตสมัยใหม่ โดยเฉพาะอย่างยิ่งในอุตสาหกรรมที่ต้องการความแม่นยำสูง เช่น อุตสาหกรรมอิเล็กทรอนิกส์ และการผลิตชิ้นส่วนยานยนต์ อย่างไรก็ตาม การเสียหายของสเต็มเปเปอร์มอเตอร์ก่อให้เกิดผลกระทบที่รุนแรงต่อภาคอุตสาหกรรม จากการศึกษาพบว่า การหยุดชะงักของสายการผลิตที่เกิดจากความเสียหายของสเต็มเปเปอร์มอเตอร์สร้างความสูญเสียทางเศรษฐกิจกว่าร้อยละ 15 - 20 ของต้นทุนการผลิตโดยรวม (Liu et al., 2019)

การบำรุงรักษาแบบดั้งเดิมที่อาศัยการตรวจสอบตามระยะเวลา หรือการซ่อมแซมเมื่อเกิดความเสียหายไม่สามารถตอบสนองต่อความท้าทายในยุคอุตสาหกรรม 4.0 ได้อย่างมีประสิทธิภาพ (Carvalho et al., 2019) นอกจากนี้ยังพบว่า การบำรุงรักษาแบบดั้งเดิมมักส่งผลให้เกิดต้นทุนที่สูงเกินความจำเป็น และไม่สามารถป้องกันการหยุดชะงักของการผลิตได้อย่างมีประสิทธิภาพ ด้วยเหตุนี้ การพัฒนาระบบการบำรุงรักษาเชิงพยากรณ์จึงได้รับความสนใจเพิ่มขึ้น โดยการศึกษาที่ผ่านมาพบว่า วิธีการแบบ data-driven สามารถช่วยลดต้นทุนการซ่อมบำรุงได้อย่างมีประสิทธิภาพ (Liu et al., 2019) งานวิจัยนี้จึงมุ่งเน้นการพัฒนาระบบพยากรณ์ความเสียหายของสเต็มเปเปอร์มอเตอร์ โดยประยุกต์ใช้เทคนิค Gradient Boosted Trees (Susto et al., 2014) ร่วมกับการปรับแต่งพารามิเตอร์อย่างเหมาะสม (Yang & Shami, 2020)

จากการทบทวนวรรณกรรมที่เกี่ยวข้อง การใช้เทคนิค Machine Learning ในการพยากรณ์ความเสียหายของอุปกรณ์อุตสาหกรรม สามารถเพิ่มประสิทธิภาพการบำรุงรักษาได้อย่างมีนัยสำคัญ (Lei et al., 2016) โดยเฉพาะการใช้ข้อมูลจากเซนเซอร์หลากหลายประเภทร่วมกับการวิเคราะห์แบบ real-time ซึ่งสอดคล้องกับงานวิจัยก่อนหน้า (Carvalho et al., 2019) ที่เสนอว่าการบูรณาการระหว่าง IoT และ AI จะเป็นกุญแจสำคัญในการยกระดับการบำรุงรักษาเชิงพยากรณ์ นอกจากนี้ การนำเทคโนโลยี Cloud Computing มาใช้ในการประมวลผล และจัดเก็บข้อมูลขนาดใหญ่ยังช่วยเพิ่มความยืดหยุ่นและประสิทธิภาพของระบบ ซึ่งจะส่งผลให้องค์กรสามารถตอบสนองต่อความต้องการที่เปลี่ยนแปลงได้อย่างรวดเร็ว เพิ่มประสิทธิภาพการผลิตโดยรวม และเสริมสร้างขีดความสามารถในการแข่งขันขององค์กรในระยะยาว

วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนา และเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ความเสียหายของสเต็มเปเปอร์มอเตอร์

2. เพื่อวิเคราะห์ความสำคัญของปัจจัยต่าง ๆ ที่ส่งผลต่อการเสียหายของสตีปเปอร์มอเตอร์
3. เพื่อพัฒนาแนวทางการบำรุงรักษาเชิงคาดการณ์ โดยใช้ผลการพยากรณ์จากแบบจำลอง

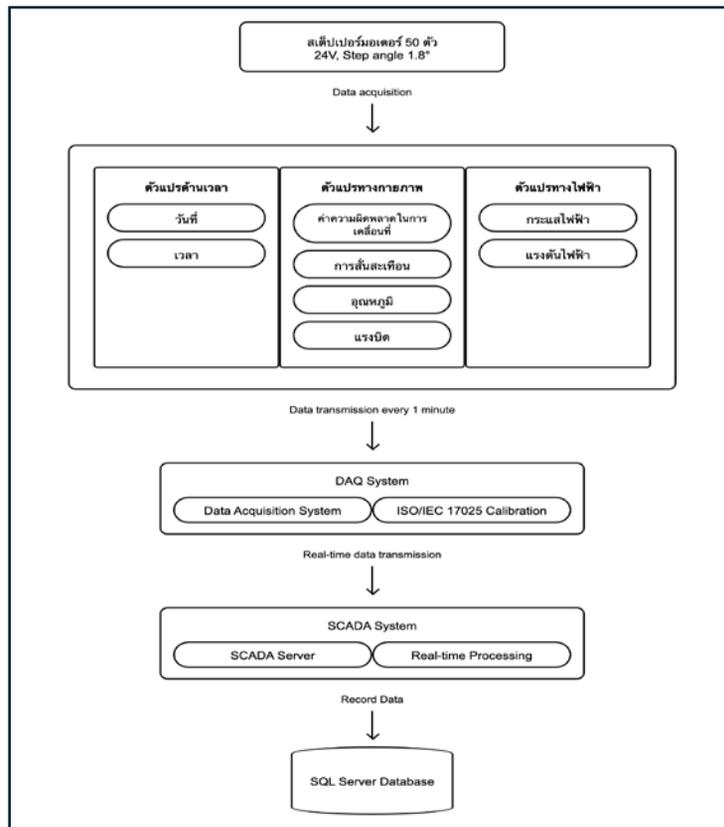
สมมติฐานในการวิจัย

1. เทคนิคการเรียนรู้ของเครื่องสามารถพยากรณ์ความเสียหายของสตีปเปอร์มอเตอร์ได้ด้วย ความแม่นยำสูงกว่าร้อยละ 90
2. ระยะเวลาการใช้งาน และค่าพารามิเตอร์ทางกายภาพ (แรงบิด อุณหภูมิ การสั่นสะเทือน) มีผลต่อการเสื่อมสภาพของสตีปเปอร์มอเตอร์อย่างมีนัยสำคัญ
3. แบบจำลอง Gradient Boosted Trees มีประสิทธิภาพในการพยากรณ์สูงกว่าแบบจำลอง การเรียนรู้ของเครื่องประเภทอื่น

วิธีดำเนินงานวิจัย

การวิจัยนี้เป็นการวิจัยเชิงปริมาณแบบทดลอง (Quantitative Experimental Research) โดยมีระยะเวลาดำเนินการ 3 เดือน เพื่อพัฒนาระบบพยากรณ์ความเสียหายของสตีปเปอร์มอเตอร์ การดำเนินงานแบ่งเป็นหลายขั้นตอนดังนี้

1. การเก็บรวบรวมข้อมูล ระบบการเก็บข้อมูลประกอบด้วยเซนเซอร์และค่าที่อ่านได้จาก สตีปเปอร์มอเตอร์ (Step angle 1.8° , 24V) จำนวน 50 ตัว จากสายการผลิตอัตโนมัติ ทำการบันทึก ข้อมูลอัตโนมัติทุก 1 นาที ในช่วงวันที่ 6 มกราคม ถึง 10 มีนาคม โดยมีข้อมูลจำนวน 200,000 ข้อมูล โดยตัวแปรที่เก็บข้อมูลแบ่งเป็น 3 กลุ่มหลัก ซึ่งประกอบด้วยตัวแปร 5 ประเภทตามบทความได้แก่ 1) ตัวแปรด้านเวลา (วันที่ เวลา และชั่วโมงการทำงาน) 2) ตัวแปรทางไฟฟ้า (กระแสไฟฟ้าและ แรงดันไฟฟ้า) และ 3) ตัวแปรทางกายภาพ ซึ่งประกอบด้วย 3 ประเภทย่อย ได้แก่ อุณหภูมิ การสั่นสะเทือน และแรงบิด รวมทั้งค่าความผิดพลาดในการเคลื่อนที่ซึ่งเป็นตัวแปรเป้าหมายในการพยากรณ์ ในการเก็บข้อมูลใช้ระบบ Data Acquisition (DAQ) แบบอัตโนมัติ โดยเซนเซอร์ทั้งหมด ได้รับการสอบเทียบตามมาตรฐาน ISO/IEC 17025 และเชื่อมต่อกับระบบ SCADA เพื่อบันทึกข้อมูลลง ฐานข้อมูล SQL Server แบบ real-time



ภาพประกอบ 1 แผนผัง Block Diagram แสดงกระบวนการเก็บข้อมูลจากสเต็ปเปอร์มอเตอร์

จากภาพประกอบ 1 แสดงแผนผัง Block Diagram ของระบบการเก็บข้อมูลสเต็ปเปอร์มอเตอร์ ขนาด 24V ที่มี Step angle 1.8° โดยระบบถูกออกแบบให้เก็บข้อมูลแบบอัตโนมัติผ่านเซนเซอร์ 3 กลุ่มหลัก ได้แก่ ข้อมูลด้านเวลา (วันที่และเวลา) ข้อมูลทางกายภาพ (ความผิดพลาดในการเคลื่อนที่ แรงบิด อุณหภูมิ และการสั่นสะเทือน) และข้อมูลทางไฟฟ้า (กระแสไฟฟ้าและแรงดันไฟฟ้า) โดยทำการบันทึกข้อมูลทุก 1 นาที

ข้อมูลจากเซนเซอร์จะถูกส่งผ่านระบบ DAQ (Data Acquisition System) ที่ได้รับการสอบเทียบตามมาตรฐาน ISO/IEC 17025 เพื่อรับประกันความแม่นยำของการวัด จากนั้นข้อมูลจะถูกส่งแบบ Real-time ไปยังระบบ SCADA ที่ประกอบด้วย SCADA Server และระบบประมวลผล

แบบ Real-time Processing เพื่อตรวจสอบและประมวลผลข้อมูลเบื้องต้น ก่อนที่จะบันทึกลงในฐานข้อมูล SQL Server สำหรับการนำไปวิเคราะห์ และพยากรณ์ความเสียหายในขั้นต่อไป

ระบบนี้ได้รับการออกแบบให้มีความน่าเชื่อถือสูงผ่านการควบคุมคุณภาพในทุกขั้นตอน ตั้งแต่การเลือกใช้เซนเซอร์ที่มีความแม่นยำ การสอบเทียบตามมาตรฐานสากล การส่งข้อมูลแบบ Real-time และการประมวลผลข้อมูลก่อนจัดเก็บ ทำให้ได้ข้อมูลที่มีคุณภาพเหมาะสมสำหรับการพัฒนาแบบจำลองการพยากรณ์ความเสียหายของสเต็ปเปอร์มอเตอร์

การนิยามความเสียหายและการเสื่อมสภาพ ในการวิจัยนี้ ความเสียหายหรือการเสื่อมสภาพของสเต็ปเปอร์มอเตอร์ถูกนิยามโดยใช้ค่า Step Error เป็นตัวบ่งชี้หลัก โดยกำหนดให้ค่า Step Error ที่มากกว่า 0.25 steps ติดต่อกันเป็นเวลาอย่างน้อย 30 นาที ถือเป็นกาเกิดความเสียหายในระดับที่ต้องวางแผนซ่อมบำรุง ค่าขีดจำกัดนี้กำหนดขึ้นจากคู่มือผู้ผลิต และการวิเคราะห์ค่าความผิดพลาดในการเคลื่อนที่ของสเต็ปเปอร์มอเตอร์ในสภาวะปกติ ค่าความเสียหายนี้จะถูกแทนด้วยค่าต่อเนื่อง (0-1) ที่แสดงถึงระดับความเสื่อมสภาพตามสมการที่ 4 โดย 0 หมายถึงสภาพปกติ และ 1 หมายถึงเสื่อมสภาพสมบูรณ์ที่ต้องการการเปลี่ยนทดแทน ทั้งนี้ เมื่อค่า $D(t)$ เกิน 0.7 จะถือว่าเข้าสู่ช่วงเสี่ยงที่ต้องวางแผนบำรุงรักษา และเมื่อมากกว่า 0.9 จะถือว่าต้องดำเนินการซ่อมบำรุงโดยเร่งด่วน

2. การเตรียมข้อมูล ขั้นตอนการเตรียมข้อมูลเริ่มจากการทำความสะอาดข้อมูล (Data Cleaning) โดยตรวจสอบและกำจัดค่าผิดปกติ (Outliers detection using IQR method and Z-score) จัดการค่าที่ขาดหาย (Missing values imputation using mean/median for numerical data and mode for categorical data) และตรวจสอบความถูกต้องของรูปแบบข้อมูล (Data format validation and type conversion) จากนั้นทำการแปลงข้อมูลด้วยการปรับมาตราส่วน (Min-Max scaling and Standard scaling) แปลงรูปแบบวันที่และเวลา และสร้างคุณลักษณะใหม่ (Feature engineering including time-based features and interaction terms) สุดท้ายแบ่งข้อมูลเป็นชุดฝึกฝน (Training set) ร้อยละ 80 และชุดทดสอบร้อยละ 20 ตามแนวทางของ (Liu et al., 2019)

3. แบบจำลองทางคณิตศาสตร์ การพัฒนาแบบจำลองใช้สมการทางคณิตศาสตร์ทั้งหมด 4 สมการหลักตามแนวทางของ (Susto et al., 2014) เพื่อสร้างแบบจำลองสำหรับการเรียนรู้ของเครื่อง (Machine Learning) โดยเฉพาะอัลกอริทึม Gradient Boosted Trees ที่ใช้ในการพยากรณ์ความเสียหายของสเต็ปเปอร์มอเตอร์ แบบจำลองนี้ได้รับการพัฒนาและปรับปรุงจากการศึกษาก่อน

หน้าของ (Yang & Shami, 2020) ซึ่งแสดงให้เห็นถึงประสิทธิภาพในการทำนายความเสียหายของอุปกรณ์อุตสาหกรรมได้อย่างแม่นยำ สมการเหล่านี้มีความสำคัญในการอธิบายกระบวนการเรียนรู้และการปรับปรุงความแม่นยำของแบบจำลอง

การพัฒนาแบบจำลองนี้ยังได้คำนึงถึงปัจจัยสำคัญต่าง ๆ ที่ส่งผลต่อประสิทธิภาพการทำนาย เช่น คุณลักษณะของข้อมูล (Feature Engineering) การจัดการกับข้อมูลที่ไม่สมดุล (Imbalanced Data) โดยใช้เทคนิค Synthetic Minority Over-sampling Technique (SMOTE) เพื่อสร้างข้อมูลเพิ่มเติมสำหรับกรณีที่มีความเสียหายสูง ซึ่งมีจำนวนตัวอย่างน้อยกว่า ร่วมกับการใช้ class weight ให้มีน้ำหนักมากกว่าสำหรับข้อมูลที่พบน้อย และการเลือกพารามิเตอร์ที่เหมาะสม (Hyperparameter Optimization) ซึ่งมีผลโดยตรงต่อความแม่นยำในการพยากรณ์ นอกจากนี้ ยังได้มีการทดสอบประสิทธิภาพของแบบจำลองด้วยชุดข้อมูลที่หลากหลายเพื่อยืนยันความน่าเชื่อถือ และความคงทนของแบบจำลอง ประกอบด้วย

3.1 สมการการทำนาย (Prediction Equation) ใช้ในการรวมผลการทำนายจาก Decision Trees หลายต้นเพื่อให้ได้ผลลัพธ์สุดท้าย

$$F(x) = \sum_{i=1}^M \gamma_i h_{i(x)} \quad (1)$$

โดยที่

$F(x)$ คือ ค่าการทำนายสุดท้าย

M คือ จำนวน trees ทั้งหมด

γ_i คือ learning rate

$h_{i(x)}$ คือ decision tree ที่ i

จากสมการที่ (1) แสดงการรวมกันเชิงเส้นของฟังก์ชันพื้นฐานหลายตัว (Ensemble Method) ซึ่งอยู่ในรูปแบบของ Gradient Boosting Model (GBM) หรือ Additive Model ที่ใช้ Decision Trees เป็นตัวเรียนรู้ย่อย (Base Learners) โดยรวมผลการทำนายจาก Decision Trees ทั้งหมด M ต้น แต่ละต้นมีค่า learning rate (γ_i) กำกับ

3.2 สมการ Loss Function ใช้วัดค่าความผิดพลาดของการทำนายเพื่อปรับปรุงประสิทธิภาพของแบบจำลอง

$$L(y, F(x)) = \sum_{i=1}^n (y_i - F(x_i))^2 \quad (2)$$

โดยที่

y_i คือ ค่าจริง

$F(x_i)$ คือ ค่าทำนาย

N คือ จำนวนตัวอย่างทั้งหมด

จากสมการที่ (2) เป็นฟังก์ชันวัดค่าความผิดพลาดของการทำนาย โดยใช้วิธี Mean Squared Error (MSE) ซึ่งคำนวณจากผลรวมของความแตกต่างกำลังสองระหว่างค่าจริงกับค่าทำนาย ยิ่งค่า Loss น้อย แสดงว่าแบบจำลองมีความแม่นยำในการทำนายสูง

3.3 สมการการปรับปรุงโมเดล - อธิบายวิธีการเพิ่มและปรับปรุง Decision Trees ใหม่เข้าไปในแบบจำลอง

$$F_{m(x)} = F_{(m-1)(x)} + \gamma_m h_{m(x)} \quad (3)$$

โดยที่

$F_{m(x)}$ คือ โมเดลที่ iteration ที่ m

$F_{(m-1)(x)}$ คือ โมเดลก่อนหน้า

γ_m คือ learning rate ที่ iteration ที่ m

$h_{m(x)}$ คือ tree ใหม่ที่สร้างขึ้น

จากสมการที่ (3) แสดงกระบวนการเรียนรู้แบบ boosting ที่มีการสร้างและเพิ่ม decision tree ใหม่เข้าไปในแบบจำลองทีละต้น โดยแต่ละต้นจะเรียนรู้จากความผิดพลาดของต้นก่อนหน้า และมีการควบคุมอัตราการเรียนรู้ด้วย learning rate

3.4 สมการการคำนวณความเสียหาย ใช้คำนวณค่าความเสียหายที่เกิดขึ้นตามเวลาโดยพิจารณาปัจจัยต่าง ๆ

$$D(t) = D_0 + \alpha \sum_{i=1}^t w_i x_i \quad (4)$$

โดยที่

$D(t)$ คือ ค่าความเสียหายที่เวลา t

D_0 คือ ค่าความเสียหายเริ่มต้น

α คือ อัตราการเสื่อมสภาพ

w_i คือ น้ำหนักของตัวแปรที่ i

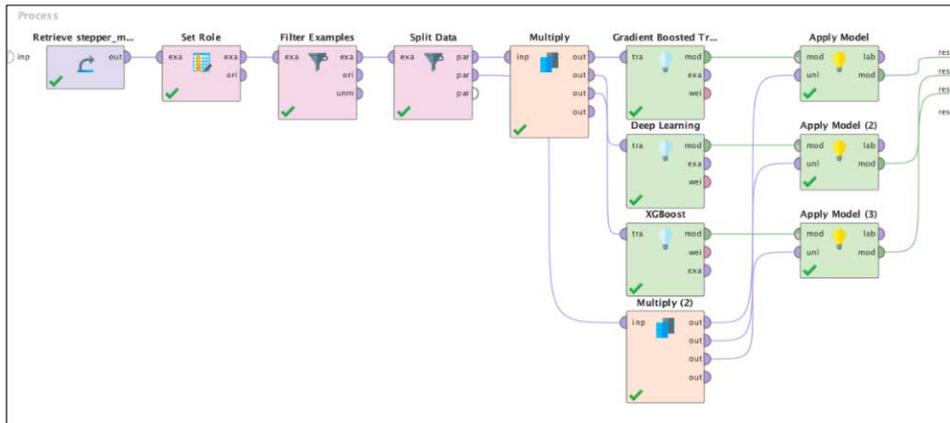
x_i คือ ค่าของตัวแปรที่ i

จากสมการที่ (4) ใช้ในการคำนวณค่าความเสียหายที่เกิดขึ้นตามเวลา โดยพิจารณาจากค่าความเสียหายเริ่มต้นและผลกระทบสะสมจากตัวแปรต่าง ๆ ที่มีน้ำหนักความสำคัญแตกต่างกัน คูณด้วยอัตราการเสื่อมสภาพ ทำให้สามารถติดตามการเสื่อมสภาพของอุปกรณ์ตามการใช้งานจริง

สมการทั้ง 4 สมการนี้ทำงานร่วมกันในการสร้างแบบจำลองที่สามารถทำนายความเสียหายของสเต็มเปอร์มอเตอร์ได้อย่างแม่นยำ โดยมีการปรับปรุงและเรียนรู้จากข้อมูลอย่างต่อเนื่อง

4. การพัฒนาและประเมินแบบจำลอง

ในการวิจัยนี้ ตัวแปรเป้าหมาย (Target Variable) ที่ใช้ในการพยากรณ์คือค่าความเสียหาย $D(t)$ ซึ่งเป็นค่าต่อเนื่อง (Continuous Value) ในช่วง 0 ถึง 1 ที่แสดงระดับความเสื่อมสภาพของสเต็มเปอร์มอเตอร์ ดังนั้น การศึกษานี้จึงใช้เทคนิคการวิเคราะห์การถดถอย (Regression Analysis) ไม่ใช่การจำแนกประเภท (Classification) การวิจัยนี้ใช้ซอฟต์แวร์ Rapid Miner ในการพัฒนาและเปรียบเทียบประสิทธิภาพอัลกอริทึม 3 แบบ คือ 1) Gradient Boosted Trees 2) Deep Learning และ 3) XGBoost โดยมีขั้นตอนการดำเนินงานดังภาพประกอบ 2



ภาพประกอบ 2 แผนผังกระบวนการพัฒนาแบบจำลองใน Rapid Miner

จากภาพประกอบ 2 แสดงแผนผังกระบวนการพัฒนาแบบจำลองใน Rapid Miner แสดงการทำงานของ Ensemble Learning โดยมีขั้นตอนการทำงานดังนี้

1. การตั้งค่าข้อมูล (Set Role) - กำหนดบทบาทของตัวแปรต้นและตัวแปรตาม
2. การกรองข้อมูล (Filter Examples) - คัดกรองข้อมูลตามเงื่อนไขที่กำหนด
3. การแบ่งข้อมูล (Split Data) - แบ่งข้อมูลเป็นชุดฝึกฝน 80% และชุดทดสอบ 20%
4. การสร้างแบบจำลอง 3 ประเภทผ่าน Multiply ได้แก่

4.1 Gradient Boosted Trees (GBT) เป็นเทคนิคการเรียนรู้แบบ ensemble ที่สร้างแบบจำลองจากต้นไม้ตัดสินใจหลายต้นต่อเนื่องกัน โดยแต่ละต้นจะเรียนรู้จากข้อผิดพลาดของต้นก่อนหน้า

4.2 Deep Learning เป็นการเรียนรู้เชิงลึกที่ใช้โครงข่ายประสาทเทียมแบบ Multi-Layer Perceptron (MLP) โดยในงานวิจัยนี้ได้ออกแบบโครงข่ายที่มี 3 ชั้นซ่อน (hidden layers) ประกอบด้วยโหนดจำนวน 64, 32 และ 16 โหนดตามลำดับ ใช้ฟังก์ชันกระตุ้น (activation function) แบบ ReLU ในชั้นซ่อน และฟังก์ชัน Sigmoid ในชั้นเอาต์พุต พร้อมใช้อัตราการเรียนรู้ (learning rate) เท่ากับ 0.01 และค่า dropout เท่ากับ 0.2 เพื่อป้องกัน overfitting โครงข่ายนี้สามารถเรียนรู้รูปแบบที่ซับซ้อนได้ดี

4.3 XGBoost เป็นอัลกอริทึมที่พัฒนาต่อยอดจาก GBT ที่เพิ่มประสิทธิภาพด้านความเร็วและความแม่นยำ

5. การประยุกต์ใช้แบบจำลอง (Apply Model) - นำแบบจำลองไปทดสอบกับชุดข้อมูลทดสอบ

การประเมินประสิทธิภาพของแบบจำลองใช้เกณฑ์การวัด 4 ค่า ได้แก่

1. R^2 (Coefficient of Determination) วัดความสามารถในการอธิบายความแปรปรวนของข้อมูล มีค่าระหว่าง 0-1 โดยค่าที่ใกล้ 1 แสดงถึงประสิทธิภาพที่ดีกว่า

2. RMSE (Root Mean Square Error) วัดค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง ค่ายิ่งน้อยยิ่งดี แสดงถึงความแม่นยำในการทำนายที่สูงกว่า

3. MAE (Mean Absolute Error) วัดค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย ค่ายิ่งน้อยยิ่งดี บ่งชี้ถึงความแม่นยำในการทำนาย

4. MSE (Mean Square Error) วัดค่าความคลาดเคลื่อนกำลังสองเฉลี่ย ค่ายิ่งน้อยยิ่งดี แสดงถึงประสิทธิภาพการทำนายที่ดีกว่า

การพัฒนาแบบจำลองใช้เทคนิค 5-fold Cross-validation และการปรับ Hyperparameters โดยใช้วิธี Grid Search ตามแนวทางของ (Carvalho et al., 2019) โดยสำหรับ Gradient Boosted Trees ได้ทดลองปรับค่า learning rate (0.01, 0.05, 0.1), maximum depth (3, 5, 7) และจำนวน estimators (100, 200, 300) สำหรับ Deep Learning ได้ปรับจำนวนชั้นซ่อน (2, 3, 4), จำนวนโหนด (16-128) และอัตราการเรียนรู้ (0.001, 0.01, 0.1) สำหรับ XGBoost ได้ปรับค่า alpha (0, 0.5, 1), lambda (1, 2, 5) และ max_depth (3, 5, 7)

ผลการวิจัย

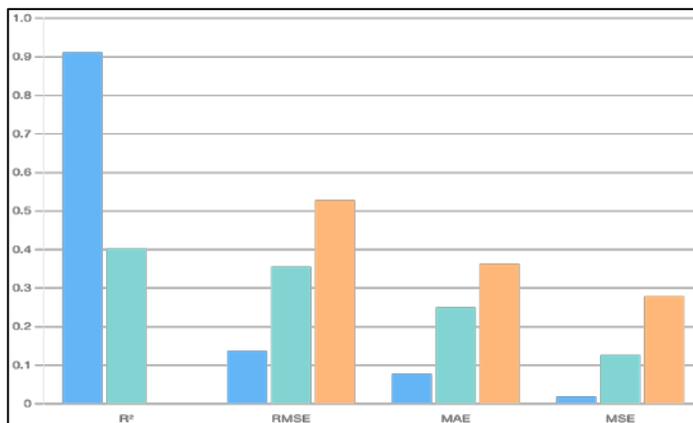
การวิเคราะห์ข้อมูลในงานวิจัยนี้ใช้ซอฟต์แวร์ RapidMiner Studio ซึ่งเป็นเครื่องมือที่มีประสิทธิภาพสำหรับการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง โดยมีผลการวิเคราะห์ดังนี้

1. การเปรียบเทียบประสิทธิภาพของแบบจำลอง

การวิจัยได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่อง 3 ประเภท ได้แก่ Gradient Boosted Trees, Deep Learning และ XGBoost โดยใช้เกณฑ์การประเมิน 4 ด้าน คือ R^2 , RMSE, MAE และ MSE ดังแสดงในตารางที่ 1 และภาพประกอบ 3

ตารางที่ 1 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง

Model	R ²	RMSE	MAE	MSE
Gradient Boosted Trees	0.9117 (91.17%)	0.1365	0.0772	0.0186
Deep Learning	0.4026 (40.26%)	0.3551	0.2494	0.1261
XGBoost	0.000 (0%)	0.528	0.363	0.279



ภาพประกอบ 3 กราฟแท่งแสดงการเปรียบเทียบประสิทธิภาพของแบบจำลองทั้งสามประเภท

จากตารางที่ 1 และภาพประกอบ 3 แสดงให้เห็นว่าการเปรียบเทียบประสิทธิภาพของโมเดล Gradient Boosted Trees, Deep Learning, และ XGBoost โดยใช้มาตรวัดประสิทธิภาพ 4 ตัวชี้วัด ได้แก่ R² (Coefficient of Determination), RMSE (Root Mean Squared Error), MAE (Mean Absolute Error) และ MSE (Mean Squared Error) ผลการวิเคราะห์พบว่า Gradient Boosted Trees ให้ผลลัพธ์ที่ดีที่สุดในทุกมาตรวัด โดยมีค่า R² สูงถึง 0.9117 (91.17%) แสดงให้เห็นว่าโมเดลสามารถอธิบายความแปรปรวนของข้อมูลได้ดี ในขณะที่ Deep Learning และ XGBoost ให้ค่า R² ที่ต่ำกว่ามาก โดยเฉพาะ XGBoost ซึ่งมีค่า R² เท่ากับ 0.000 (0%) แสดงว่าโมเดลไม่สามารถเรียนรู้ความสัมพันธ์ของข้อมูลได้เลย

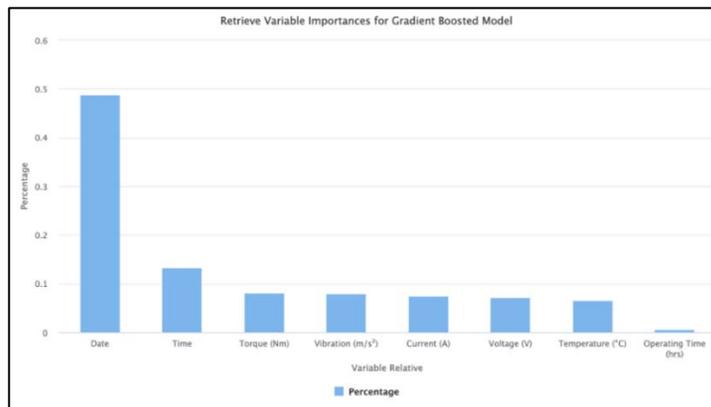
เมื่อพิจารณาค่าความคลาดเคลื่อนจากภาพประกอบ 3 พบว่า Gradient Boosted Trees มีค่า RMSE, MAE และ MSE ต่ำที่สุด (RMSE = 0.1365, MAE = 0.0772, MSE = 0.0186) ซึ่งสะท้อนให้เห็น

ถึงความแม่นยำในการทำนายที่สูงกว่า ในขณะที่ Deep Learning มีค่าความคลาดเคลื่อนปานกลาง (RMSE = 0.3551, MAE = 0.2494, MSE = 0.1261) และ XGBoost มีค่าความคลาดเคลื่อนสูงที่สุด (RMSE = 0.5280, MAE = 0.3630, MSE = 0.2790) ซึ่งบ่งชี้ถึงความแม่นยำในการทำนายที่ต่ำกว่าอย่างมีนัยสำคัญ

จากผลลัพธ์ที่แสดงในตารางที่ 1 สามารถสรุปได้ว่า Gradient Boosted Trees เป็นโมเดลที่เหมาะสมที่สุดสำหรับการพยากรณ์ความเสียหายของสแต็ปเปอร์มอเตอร์ในกรณีนี้ ทั้งในแง่ของความสามารถในการอธิบายความแปรปรวนของข้อมูล และความแม่นยำในการทำนาย สำหรับ Deep Learning อาจต้องมีการปรับปรุงด้วยการเพิ่มจำนวนข้อมูลฝึกฝน หรือปรับแต่งสถาปัตยกรรมของโครงข่าย ส่วน XGBoost อาจไม่เหมาะสมกับลักษณะของข้อมูลในการศึกษานี้ หรืออาจต้องมีการปรับแต่งพารามิเตอร์เพิ่มเติมเพื่อให้ได้ประสิทธิภาพที่ดีขึ้น

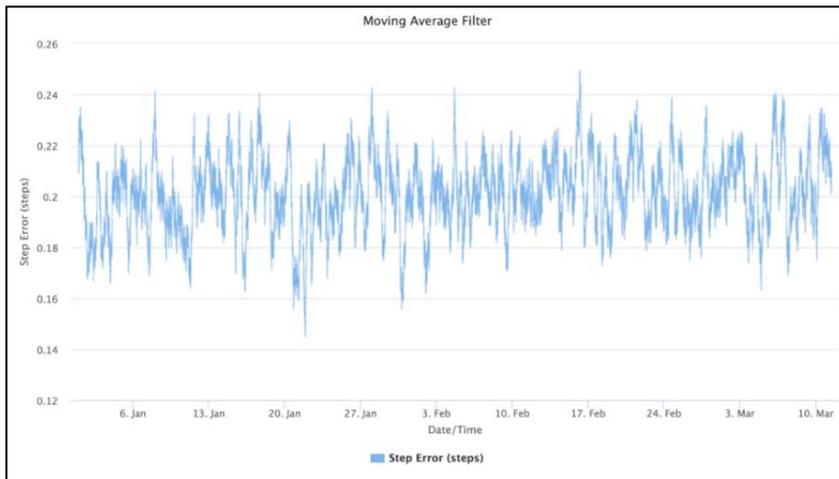
2. การวิเคราะห์ภาพและแผนภูมิ

ในการวิเคราะห์ความสำคัญของตัวแปร ที่ส่งผลต่อการพยากรณ์ความเสียหายของสแต็ปเปอร์มอเตอร์ ผู้วิจัยได้ใช้เทคนิค Variable Importance Analysis จากแบบจำลอง Gradient Boosted Trees เพื่อระบุว่าตัวแปรใดมีอิทธิพลต่อความแม่นยำในการพยากรณ์มากที่สุด โดยผลการวิเคราะห์แสดงในรูปแบบกราฟแท่งดังภาพประกอบ 4



ภาพประกอบ 4 แสดงความสำคัญของตัวแปรแต่ละตัวที่ส่งผลต่อการพยากรณ์ โดยแสดงในรูปแบบกราฟแท่งเรียงลำดับจากมากไปน้อย

จากภาพประกอบ 4 แสดงความสำคัญของตัวแปรในแบบจำลอง Gradient Boosted Trees โดยพบว่าตัวแปร Date มีความสำคัญสูงสุด (ประมาณ 0.5 หรือ 50%) รองลงมาคือ Time, Torque และตัวแปรอื่น ๆ ตามลำดับ แสดงให้เห็นว่าปัจจัยด้านเวลา มีผลต่อการพยากรณ์มากที่สุด



ภาพประกอบ 5 แสดงกราฟแนวโน้มการเสื่อมสภาพตามเวลาของสเต็ปเปอร์มอเตอร์ ซึ่งแสดงความสัมพันธ์ระหว่างเวลาและการเสื่อมสภาพ

จากภาพประกอบ 5 แสดงกราฟ Moving Average Filter ของค่า Step Error ตามช่วงเวลา ตั้งแต่ 6 มกราคม ถึง 10 มีนาคม พบว่า มีการแกว่งตัวของค่าความผิดพลาดระหว่าง 0.12 ถึง 0.26 steps ซึ่งแสดงถึงพฤติกรรมของการเสื่อมสภาพของสเต็ปเปอร์มอเตอร์ตามเวลา

3. การวิเคราะห์ความสำคัญของตัวแปร

จากการวิเคราะห์ความสำคัญของตัวแปรทั้งหมด พบว่า ปัจจัยด้านเวลาส่งผลกระทบต่อ การเสื่อมสภาพของสเต็ปเปอร์มอเตอร์มากที่สุด โดยตัวแปร Date มีความสำคัญสูงสุดที่ 44.67% และ Time ที่ 10.65% รวมเป็น 55.32% รองลงมาคือปัจจัยทางกายภาพ ได้แก่ Torque (11.28%), Vibration (9.13%) และ Temperature (7.94%) รวมเป็น 28.35% และปัจจัยทางไฟฟ้า ได้แก่ Current (7.65%), Voltage (7.42%) และ Operating Time (1.20%) รวมเป็น 16.27% ตามลำดับ

อภิปรายผลการวิจัย

1. ประสิทธิภาพของแบบจำลอง

1.1 แบบจำลอง GBT มีประสิทธิภาพสูงสุด ($R^2 = 0.9117$, $RMSE = 0.1365$) เนื่องจากสามารถจับรูปแบบความสัมพันธ์ที่ซับซ้อนของข้อมูลได้ดี จากการเปรียบเทียบกับงานวิจัยของ (Liu et al., 2019) ที่ใช้เทคนิค Deep Learning พบว่า GBT ให้ผลลัพธ์ที่แม่นยำกว่า เนื่องจากข้อมูลมีความไม่เป็นเชิงเส้นสูง การที่แบบจำลอง GBT มีประสิทธิภาพสูงสอดคล้องกับงานวิจัยของ (Susto et al., 2014) ที่พบว่าเทคนิค Ensemble Learning มีความเหมาะสมกับการพยากรณ์การเสียหายของอุปกรณ์อุตสาหกรรม เนื่องจากสามารถเรียนรู้รูปแบบที่ซับซ้อน และทนต่อสัญญาณรบกวนได้ดี

1.2 Deep Learning มีประสิทธิภาพปานกลาง ($R^2 = 0.4026$) สอดคล้องกับงานวิจัยของ (Carvalho et al., 2019) ที่พบว่า การใช้ Deep Learning กับชุดข้อมูลขนาดเล็กอาจไม่เหมาะสม เนื่องจาก Deep Learning ต้องการข้อมูลจำนวนมากในการเรียนรู้และปรับปรุงโมเดล นอกจากนี้ ยังพบปัญหา overfitting เมื่อใช้กับข้อมูลที่มีจำนวนน้อย ทำให้ความสามารถในการทำนายกับข้อมูลใหม่ลดลง

1.3 XGBoost ให้ผลลัพธ์ที่แม่นยำน้อยที่สุด โดยมีค่า $R^2 = 0$ แม้จะมีการปรับแต่งพารามิเตอร์แล้ว ซึ่งสาเหตุหลักมาจากลักษณะความไม่เป็นเชิงเส้นของข้อมูล และความซับซ้อนของความสัมพันธ์ระหว่างตัวแปร นอกจากนี้ XGBoost อาจเกิดปัญหา overfitting กับชุดข้อมูลฝึกฝน และไม่สามารถสรุปรูปแบบที่เหมาะสมสำหรับชุดทดสอบได้ การทดลองปรับค่า regularization parameters และลดความซับซ้อนของโมเดลก็ไม่สามารถแก้ไขปัญหานี้ได้

2. ปัจจัยที่ส่งผลต่อความเสียหาย

2.1 ปัจจัยด้านเวลา (Date และ Time) รวมกันมีผลมากถึงร้อยละ 55.32 แสดงให้เห็นว่าระยะเวลาการใช้งานเป็นปัจจัยหลักที่ส่งผลต่อการเสื่อมสภาพของสแต็ปเปอร์มอเตอร์ สอดคล้องกับทฤษฎีการเสื่อมสภาพของอุปกรณ์ (Wear-out Theory) ที่ระบุว่าการใช้งานต่อเนื่องเป็นระยะเวลานานจะส่งผลให้เกิดการเสื่อมสภาพของชิ้นส่วนและประสิทธิภาพลดลง

2.2 ปัจจัยทางกายภาพ (Torque, Vibration, Temperature) รวมกันมีผลร้อยละ 28.35 โดยแรงบิด (Torque) มีอิทธิพลสูงสุดในกลุ่มนี้ ซึ่งสอดคล้องกับงานวิจัยของ (Liu et al., 2019) ที่พบว่าปัจจัยทางกายภาพมีความสัมพันธ์โดยตรงกับการเสื่อมสภาพของมอเตอร์ โดยเฉพาะในกรณีที่มีการใช้งานที่แรงบิดสูงหรือมีการสั่นสะเทือนมาก

2.3 ปัจจัยทางไฟฟ้า (Current, Voltage) รวมกันมีผลร้อยละ 15.07 ซึ่งแม้จะมีผลน้อยที่สุด แต่ก็ยังเป็นปัจจัยสำคัญที่ต้องเฝ้าระวัง เนื่องจากความผิดปกติของกระแสไฟฟ้าและแรงดันไฟฟ้าสามารถส่งผลกระทบต่อการทำงานของมอเตอร์ได้ สอดคล้องกับผลการศึกษาของ (Carvalho et al., 2019) ที่พบว่าความผันผวนของปัจจัยทางไฟฟ้าเป็นสาเหตุสำคัญของการเสียหายแบบเฉียบพลัน

การวิเคราะห์ปัจจัยทั้งสามกลุ่มนี้ช่วยให้เข้าใจถึงความสำคัญของแต่ละปัจจัยที่ส่งผลต่อการเสื่อมสภาพของสเต็ปเปอร์มอเตอร์ ซึ่งเป็นประโยชน์อย่างยิ่งในการวางแผนการบำรุงรักษาเชิงป้องกัน และการพัฒนาระบบเฝ้าระวังที่มีประสิทธิภาพ

ข้อเสนอแนะเพื่อนำผลการวิจัยไปใช้

1. การพัฒนาระบบการพยากรณ์อัจฉริยะ จากผลการวิจัยที่พบว่าแบบจำลอง GBT มีประสิทธิภาพสูงในการพยากรณ์ความเสียหาย ควรนำไปพัฒนาต่อยอดเป็นระบบการพยากรณ์อัจฉริยะแบบบูรณาการ โดยผสมผสานเทคโนโลยี IoT เข้ากับการเรียนรู้ของเครื่องเพื่อสร้างระบบพยากรณ์แบบ real-time นอกจากนี้ควรพัฒนาความสามารถในการวิเคราะห์แบบ Multi-parameter โดยใช้ข้อมูลจากหลายพารามิเตอร์พร้อมกัน โดยเฉพาะตัวแปรที่มีความสำคัญสูง เช่น วันที่ เวลา และ แรงบิด รวมถึงการพัฒนาระบบให้สามารถเรียนรู้และปรับปรุงประสิทธิภาพการพยากรณ์ได้อย่างต่อเนื่องและอัตโนมัติ

2. การประยุกต์ใช้ในภาคอุตสาหกรรม ผลการวิจัยนี้สามารถนำไปประยุกต์ใช้ในภาคอุตสาหกรรมได้หลายรูปแบบ โดยเริ่มจากการขยายระบบสู่สายการผลิต ด้วยการนำแบบจำลอง GBT ที่ให้ค่าความแม่นยำสูงถึงร้อยละ 91.1 ไปใช้กับมอเตอร์ทั้งสายการผลิต ควบคู่กับการพัฒนาระบบ Digital Twin เพื่อจำลองและวิเคราะห์พฤติกรรมของมอเตอร์ในสภาวะต่าง ๆ ซึ่งจะช่วยให้การวางแผนบำรุงรักษาเชิงพยากรณ์มีประสิทธิภาพมากขึ้น สามารถคาดการณ์และป้องกันความเสียหายได้ล่วงหน้า

3. การพัฒนาแพลตฟอร์มและการรักษาความปลอดภัย เพื่อให้การนำผลวิจัยไปใช้เกิดประสิทธิภาพสูงสุด ควรพัฒนาแพลตฟอร์มกลางที่สามารถติดตาม และควบคุมการทำงานของมอเตอร์ทั้งระบบแบบรวมศูนย์ โดยคำนึงถึงความปลอดภัยของข้อมูลตามมาตรฐาน ISO 27001 และพัฒนาระบบให้สามารถเชื่อมต่อและทำงานร่วมกับระบบ MES และ ERP ที่มีอยู่เดิมได้อย่างมีประสิทธิภาพ

ซึ่งจะช่วยให้การบริหารจัดการและการตัดสินใจในการบำรุงรักษามีความแม่นยำ และครอบคลุมมากยิ่งขึ้น

เอกสารอ้างอิง

- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, *137*, 106024.
- Chen, B., Wan, J., Shu, L., Li, P., Mukherjee, M., & Yin, B. (2017). Smart factory of industry 4.0: Key technologies, application case, and challenges. *Ieee Access*, *6*, 6505-6519.
- Lei, Y., Jia, F., Lin, J., Xing, S., & Ding, S. X. (2016). An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data. *IEEE Transactions on*, *63*(5), 3137-3147.
- Liu, Y., Zhou, H., Tsung, F., & Zhang, S. (2019). Real-time quality monitoring and diagnosis for manufacturing process profiles based on deep belief networks. *Computers & Industrial Engineering*, *136*, 494-503.
- Rojko, A. (2017). Industry 4.0 concept: Background and overview. *International Journal of Interactive Mobile Technologies*, *11*(5), 77-90.
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A. (2014). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, *11*(3), 812-820.
- Wang, J., Ma, Y., Zhang, L., Gao, R. X., & Wu, D. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of manufacturing systems*, *48*, 144-156.
- Yang, L., & Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, *415*, 295-316.
- Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*, *13*(3), 2213-2227.

