

การพัฒนาระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับ  
อุตสาหกรรมไฟฟ้าจราจร

Development of an Explainable AI-Based Predictive Maintenance Decision Support System for the  
Traffic Electrical Industry

ผู้วิจัย: นาย ยศพร ภัคศิขณ

นักศึกษาระดับปริญญาเอก

สาขาวิชาเทคโนโลยีดิจิทัลมีเดีย คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ

#### บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์ (Explainable Artificial Intelligence-based Predictive Maintenance Decision Support System: XAI-PdM DSS) สำหรับอุตสาหกรรมไฟฟ้าจราจร ซึ่งเป็นอุตสาหกรรมที่พึ่งพาเครื่องจักรเฉพาะทางและมีความเสี่ยงต่อการเสื่อมสภาพและการหยุดทำงานโดยไม่คาดคิด งานวิจัยมุ่งแก้ไขข้อจำกัดของการซ่อมบำรุงแบบดั้งเดิมและระบบปัญญาประดิษฐ์แบบกล่องดำที่ขาดความโปร่งใสในการตัดสินใจ โดยใช้แนวทางการวิจัยเชิงพัฒนา (Design and Development Research: DDR) ผ่านการสังเคราะห์วรรณกรรมด้านการซ่อมบำรุงเชิงพยากรณ์ ระบบสนับสนุนการตัดสินใจ ปัญญาประดิษฐ์แบบอธิบายได้ และเทคนิคการตัดสินใจหลายเกณฑ์

ระบบที่พัฒนาขึ้นบูรณาการแบบจำลองปัญญาประดิษฐ์สำหรับการพยากรณ์ความเสี่ยงของเครื่องจักร ร่วมกับเทคนิคอธิบายผลลัพธ์ ได้แก่ SHAP และ LIME เพื่อเพิ่มความโปร่งใสและความน่าเชื่อถือของการพยากรณ์ ผสานกับเทคนิคการตัดสินใจหลายเกณฑ์ในการจัดลำดับความสำคัญของงานซ่อมบำรุง และนำเสนอผลลัพธ์ผ่านแดชบอร์ดเพื่อสนับสนุนการตัดสินใจเชิงระบบ ผลการประเมินความเหมาะสมของระบบโดยผู้เชี่ยวชาญ 15 คน พบว่ามีความเหมาะสมในระดับมากที่สุด ( $\bar{X} = 4.58$ , S.D. = 0.49) แสดงให้เห็นว่าระบบที่พัฒนาขึ้นมีศักยภาพในการสนับสนุนการตัดสินใจซ่อมบำรุงอย่างมีประสิทธิภาพ โปร่งใส และสามารถประยุกต์ใช้ได้จริงในบริบทอุตสาหกรรมไฟฟ้าจราจร อันจะช่วยลด Downtime เพิ่มความน่าเชื่อถือของเครื่องจักร และยกระดับการซ่อมบำรุงสู่ระบบอุตสาหกรรมอัจฉริยะอย่างยั่งยืน

**คำสำคัญ** ระบบสนับสนุนการตัดสินใจ การซ่อมบำรุงเชิงพยากรณ์ ปัญญาประดิษฐ์แบบอธิบายได้ อุตสาหกรรมไฟฟ้าจราจร อายุการใช้งานคงเหลือของเครื่องจักร

## 1.1 บทนำ (Introduction)

อุตสาหกรรมไฟฟ้าจากรางเป็นภาคการผลิตที่มีบทบาทสำคัญต่อโครงสร้างพื้นฐานของระบบคมนาคม ความปลอดภัย สาธารณะ และการพัฒนาเมืองอัจฉริยะ โดยกระบวนการผลิตในอุตสาหกรรมนี้พึ่งพาเครื่องจักรเฉพาะทางที่มีความซับซ้อนสูง เช่น เครื่องตัดเหล็ก เครื่องปั๊ม และเครื่องม้วน ซึ่งมีผลโดยตรงต่อคุณภาพของชิ้นงาน ความปลอดภัยในการปฏิบัติงาน และความต่อเนื่องของสายการผลิต ความล้มเหลวของเครื่องจักรแม้เพียงครั้งเดียวสามารถก่อให้เกิดผลกระทบแบบลูกโซ่ ทั้งด้าน ต้นทุนการผลิตที่เพิ่มสูงขึ้น ระยะเวลาการส่งมอบที่ล่าช้า และความน่าเชื่อถือขององค์กรในระยะยาว งานวิจัยหลายฉบับ ชี้ให้เห็นว่าการซ่อมบำรุงแบบดั้งเดิมที่อาศัยรอบเวลา (Time-based Maintenance) ไม่สามารถสะท้อนสภาพการใช้งานจริง ของเครื่องจักรที่มีภาระงานแตกต่างกันและมีรูปแบบการเสื่อมสภาพที่ซับซ้อนได้อย่างเหมาะสม ส่งผลให้เกิดการหยุดทำงาน โดยไม่คาดคิด (Unplanned Downtime) และการใช้ทรัพยากรด้านการซ่อมบำรุงอย่างไม่มีประสิทธิภาพ [1]–[3]

เพื่อแก้ไขข้อจำกัดดังกล่าว แนวคิดการซ่อมบำรุงเชิงพยากรณ์ (Predictive Maintenance: PdM) ได้รับการพัฒนา และประยุกต์ใช้อย่างกว้างขวางในอุตสาหกรรมสมัยใหม่ โดยอาศัยเทคนิค Machine Learning และ Deep Learning ร่วมกับ ข้อมูลจากเซนเซอร์และเทคโนโลยี Internet of Things (IoT) เพื่อวิเคราะห์สภาพเครื่องจักร ตรวจสอบความผิดปกติ และ พยากรณ์อายุการใช้งานคงเหลือของอุปกรณ์ (Remaining Useful Life: RUL) งานวิจัยเชิงประจักษ์จำนวนมากรายงานว่า PdM สามารถลด Downtime เพิ่มประสิทธิภาพการใช้ทรัพยากร และสนับสนุนการวางแผนการผลิตเชิงรุกได้อย่างมีนัยสำคัญ [4]– [8] นอกจากนี้ การบูรณาการแนวคิด Digital Twin เข้ากับระบบ PdM ยังช่วยเพิ่มความแม่นยำในการพยากรณ์และขยาย ศักยภาพของการตัดสินใจเชิงอัจฉริยะภายใต้บริบทของอุตสาหกรรม 4.0 ซึ่งเน้นการเชื่อมโยงข้อมูลแบบเรียลไทม์และการ วิเคราะห์ขั้นสูง [9]–[11] อย่างไรก็ตาม แม้ระบบ PdM ที่ขับเคลื่อนด้วยปัญญาประดิษฐ์จะมีความก้าวหน้าอย่างต่อเนื่อง แต่ งานวิจัยจำนวนมากได้สะท้อนข้อจำกัดเชิงโครงสร้างที่สำคัญ กล่าวคือ โมเดลส่วนใหญ่ยังคงทำงานในลักษณะปัญญาประดิษฐ์ แบบกล่องดำ (Black-box AI) ซึ่งให้ความสำคัญกับความแม่นยำของการพยากรณ์มากกว่าความสามารถในการอธิบายเหตุผล ของผลลัพธ์ ส่งผลให้ผู้ใช้งานในภาคอุตสาหกรรมไม่สามารถตรวจสอบความสมเหตุสมผลของผลการพยากรณ์ หรือเชื่อมโยง ผลลัพธ์เหล่านั้นกับบริบทการตัดสินใจด้านการซ่อมบำรุงได้อย่างชัดเจน [12]–[16] แม้จะมีความพยายามพัฒนาโมเดลที่ สามารถตีความได้ เช่น Decision Tree-based Models และแนวคิด Interpretable Machine Learning แต่แนวทางดังกล่าว มักมุ่งเน้นการอธิบายผลในระดับโมเดลเป็นรายตัว และยังขาดกลไกในการผสมผสานข้อมูลหลายมิติที่เกี่ยวข้องกับการตัดสินใจเชิง ปฏิบัติในระดับองค์กร [17]–[20] ในช่วงทศวรรษที่ผ่านมา แนวคิด Explainable Artificial Intelligence (XAI) ได้รับความ สนใจเพิ่มขึ้นอย่างมากในฐานะกลไกสำคัญในการเพิ่มความโปร่งใส ความเข้าใจ และความเชื่อมั่นต่อระบบปัญญาประดิษฐ์ XAI มุ่งอธิบายเหตุผลเบื้องหลังการตัดสินใจของโมเดล AI ช่วยให้ผู้เชี่ยวชาญสามารถตรวจสอบและตีความผลลัพธ์ได้อย่างเป็นระบบ ควบคู่ไปกับงานวิจัยด้านการตัดสินใจเชิงหลายเกณฑ์ (Multi-Criteria Decision Making: MCDM) ซึ่งนำเสนอวิธีการจัดการ ความซับซ้อนของการตัดสินใจโดยพิจารณาปัจจัยหลายด้านพร้อมกัน ทั้งด้านเทคนิค เศรษฐกิจ และการปฏิบัติงาน รวมถึงการใช้ แดชบอร์ดเพื่อสนับสนุนการรับรู้สถานการณ์และการตัดสินใจในระดับปฏิบัติการ งานวิจัยแสดงให้เห็นว่าแนวทางเหล่านี้ สามารถเพิ่มความโปร่งใส ความน่าเชื่อถือ และการยอมรับของผู้ใช้ในระบบอัจฉริยะได้อย่างมีนัยสำคัญ [21]–[24]

อย่างไรก็ตาม งานวิจัยส่วนใหญ่มักศึกษา PdM, XAI และ MCDM แบบแยกส่วน และยังไม่ปรากฏกรอบแนวคิดเชิงระบบที่ บูรณาการองค์ประกอบเหล่านี้เข้าด้วยกันอย่างเป็นเอกภาพ โดยเฉพาะในบริบทของอุตสาหกรรมไฟฟ้าจากรางซึ่งมีลักษณะการ ทำงานและข้อจำกัดเฉพาะทาง ช่องว่างดังกล่าวสะท้อนความจำเป็นในการพัฒนาระบบสนับสนุนการตัดสินใจที่สามารถ

เชื่อมโยงผลการพยากรณ์เชิงเทคนิคเข้ากับกระบวนการตัดสินใจของมนุษย์อย่างโปร่งใส ตรวจสอบได้ และสอดคล้องกับการใช้งานจริงในภาคอุตสาหกรรม ในระดับนโยบาย การพัฒนาอุตสาหกรรมสู่ Industry 4.0 และ Smart Industry มุ่งเน้นการใช้เทคโนโลยีดิจิทัล ปัญญาประดิษฐ์ และระบบอัตโนมัติเพื่อเพิ่มประสิทธิภาพ ความยืดหยุ่น และความยั่งยืนของภาคการผลิต แนวทางดังกล่าวสอดคล้องกับทิศทางการพัฒนา Thailand 4.0 ที่มุ่งยกระดับอุตสาหกรรมไทยสู่เศรษฐกิจฐานนวัตกรรม การพัฒนาระบบซ่อมบำรุงอัจฉริยะที่ผสาน PdM และ XAI จึงไม่เพียงตอบโจทย์เชิงเทคนิคขององค์กรอุตสาหกรรมเท่านั้น แต่ยังสอดคล้องกับนโยบายการพัฒนาอุตสาหกรรมดิจิทัลในระดับประเทศ

จากบริบทและช่องว่างทางวิชาการดังกล่าว งานวิจัยเรื่อง การพัฒนาระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร จึงมีเป้าหมายเพื่อพัฒนาระบบสนับสนุนการตัดสินใจที่บูรณาการ Predictive Maintenance, Explainable Artificial Intelligence, Multi-Criteria Decision Making และการนำเสนอข้อมูลผ่านแดชบอร์ดเข้าไว้ด้วยกันอย่างเป็นระบบ กรอบแนวคิดดังกล่าวมุ่งเชื่อมโยงผลการวิเคราะห์ของปัญญาประดิษฐ์เข้ากับกระบวนการตัดสินใจของผู้ใช้งานอย่างมีเหตุผล โปร่งใส และตรวจสอบได้ เพื่อสนับสนุนการวางแผนซ่อมบำรุงเชิงรุก ลด Downtime เพิ่มความน่าเชื่อถือของเครื่องจักร และยกระดับกระบวนการซ่อมบำรุงสู่ระบบอุตสาหกรรมอัจฉริยะที่มีมนุษย์เป็นศูนย์กลางอย่างยั่งยืน [25] งานวิจัยนี้คาดว่าจะมีคุณค่าทั้งในเชิงวิชาการและเชิงปฏิบัติ ในเชิงวิชาการ ระบบที่พัฒนาขึ้นช่วยขยายองค์ความรู้ด้านระบบสนับสนุนการตัดสินใจและปัญญาประดิษฐ์แบบอธิบายได้ โดยเสนอแนวทางการบูรณาการเทคโนโลยีหลายด้านเข้าด้วยกันอย่างเป็นระบบ ในเชิงปฏิบัติ กรอบแนวคิดดังกล่าวสามารถใช้เป็นแนวทางในการออกแบบและพัฒนาระบบซ่อมบำรุงอัจฉริยะที่โปร่งใส เชื่อถือได้ และเหมาะสมต่อการประยุกต์ใช้จริงในอุตสาหกรรมไฟฟ้าจราจร รวมทั้งสามารถต่อยอดสู่การประยุกต์ใช้ในอุตสาหกรรมเฉพาะทางอื่น ๆ ในอนาคต

### 1.2 วัตถุประสงค์งานวิจัย

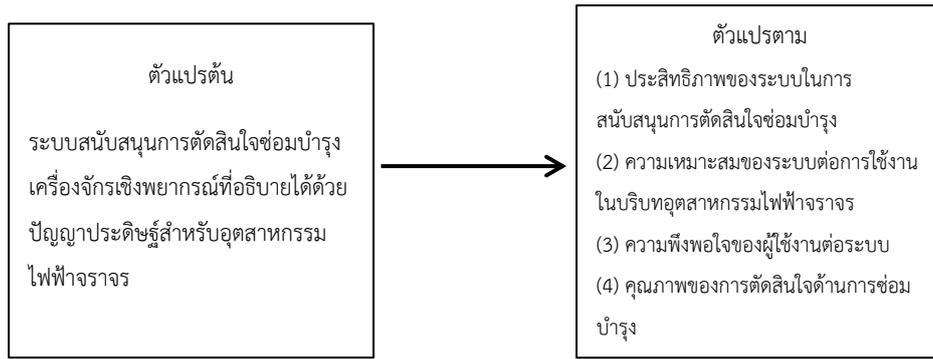
1.2.1 เพื่อพัฒนาระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร

1.2.2. เพื่อออกแบบและพัฒนาระบบต้นแบบของระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจรให้สามารถใช้งานได้จริง

1.2.3. เพื่อประเมินประสิทธิภาพและความเหมาะสมของระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร

### 1.3 ขอบเขตของการวิจัย

การวิจัยเรื่อง ระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร มีขอบเขตของการวิจัยดังต่อไปนี้



ภาพที่ 1 กรอบแนวคิดงานวิจัย

### 1.3.1 ตัวแปรต้น (Independent Variable)

ตัวแปรต้นของการวิจัย คือ ระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร ซึ่งเป็นระบบที่พัฒนาขึ้นโดยบูรณาการเทคโนโลยีปัญญาประดิษฐ์และระบบสนับสนุนการตัดสินใจ ประกอบด้วยองค์ประกอบสำคัญ ได้แก่ (1) ระบบพยากรณ์สภาพและอายุการใช้งานคงเหลือของเครื่องจักร (Predictive Maintenance Model) (2) กลไกอธิบายผลการพยากรณ์ด้วย Explainable Artificial Intelligence (XAI) เพื่อเพิ่มความโปร่งใสและความเข้าใจของผู้ใช้งาน และ (3) โมดูลการตัดสินใจเชิงหลายเกณฑ์และแดชบอร์ดสำหรับสนับสนุนการวางแผนซ่อมบำรุง

### 1.3.2 ตัวแปรตาม (Dependent Variables)

ตัวแปรตามของการวิจัย ได้แก่ ผลลัพธ์ที่เกิดจากการใช้ระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ ประกอบด้วย

- (1) ประสิทธิภาพของระบบในการสนับสนุนการตัดสินใจซ่อมบำรุง
  - (2) ความเหมาะสมของระบบต่อการใช้งานในบริบทอุตสาหกรรมไฟฟ้าจราจร
  - (3) ความพึงพอใจของผู้ใช้งานต่อระบบ
- และ (4) คุณภาพของการตัดสินใจด้านการซ่อมบำรุง

### 1.3.3 ประชากรและกลุ่มตัวอย่าง

ประชากรของการวิจัยนี้ คือ บุคลากรที่เกี่ยวข้องกับงานซ่อมบำรุงและการบริหารจัดการเครื่องจักรในอุตสาหกรรมไฟฟ้าจราจร ได้แก่ วิศวกรซ่อมบำรุง ช่างเทคนิค ผู้ควบคุมเครื่องจักร และผู้บริหารงานด้านการผลิต ซึ่งเป็นกลุ่มผู้ใช้งานระบบสนับสนุนการตัดสินใจซ่อมบำรุงโดยตรง

กลุ่มตัวอย่างของการวิจัย คือ ผู้เชี่ยวชาญและผู้ปฏิบัติงานในอุตสาหกรรมไฟฟ้าจราจร จำนวน 15 คน ซึ่งได้มาจากการสุ่มแบบเจาะจง (Purposive Sampling) เพื่อใช้ในการประเมินประสิทธิภาพและความเหมาะสมของระบบที่พัฒนาขึ้น

## 1.4 ประโยชน์ของการวิจัย

1.4.1 ได้กรอบแนวคิดของระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร ซึ่งสามารถใช้เป็นแนวทางในการพัฒนางานวิจัยและการออกแบบระบบซ่อมบำรุงอัจฉริยะในอุตสาหกรรมเฉพาะทางในอนาคต

1.4.2 ได้ระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์ ซึ่งช่วยสนับสนุนการวางแผนซ่อมบำรุง ลดการหยุดทำงานของเครื่องจักร เพิ่มความน่าเชื่อถือของกระบวนการผลิต และยกระดับประสิทธิภาพการดำเนินงานในอุตสาหกรรมไฟฟ้าจราจร

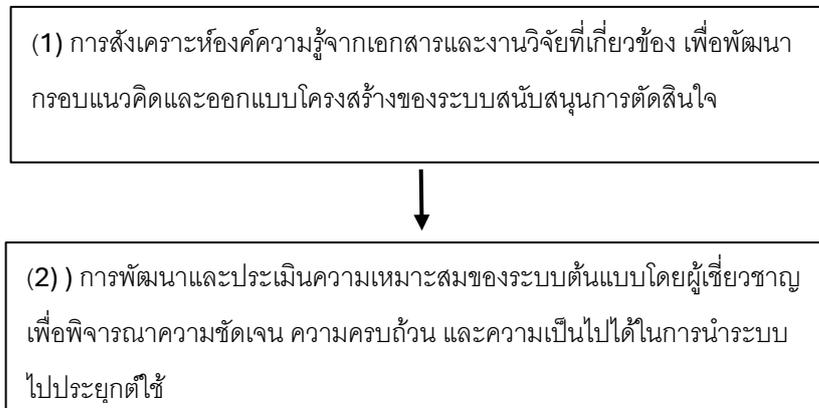
1.4.3 ได้ผลการประเมินประสิทธิภาพและความเหมาะสมของระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ ซึ่งสามารถใช้เป็นข้อมูลสนับสนุนการนำเทคโนโลยีปัญญาประดิษฐ์และระบบสนับสนุนการตัดสินใจไปประยุกต์ใช้ในการพัฒนาระบบซ่อมบำรุงในภาคอุตสาหกรรม

### 1.5. กรอบแนวคิดและผลการวิจัย

#### 1.5.1. การออกแบบงานวิจัย (Research Design)

การวิจัยเรื่อง “การพัฒนาระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร” ใช้ระเบียบวิธีวิจัยเชิงพัฒนา (Design and Development Research: DDR) โดยมีวัตถุประสงค์เพื่อพัฒนาและออกแบบระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับการประยุกต์ใช้ในบริบทอุตสาหกรรมไฟฟ้าจราจร

การดำเนินการวิจัยแบ่งออกเป็น 2 ระยะหลัก ได้แก่ (1) การสังเคราะห์องค์ความรู้จากเอกสารและงานวิจัยที่เกี่ยวข้อง เพื่อพัฒนารอบแนวคิดและออกแบบโครงสร้างของระบบสนับสนุนการตัดสินใจ และ (2) การพัฒนาและประเมินความเหมาะสมของระบบต้นแบบโดยผู้เชี่ยวชาญ เพื่อพิจารณาความชัดเจน ความครบถ้วน และความเป็นไปได้ในการนำระบบไปประยุกต์ใช้จริงในภาคอุตสาหกรรม



ภาพที่ 1 การออกแบบงานวิจัย

#### 1.5.2 ขั้นตอนที่ 1 การสังเคราะห์วรรณกรรมและการพัฒนารอบแนวคิด (ตามแนวทาง IPOF)

เป็นการสังเคราะห์องค์ความรู้จากงานวิจัยที่เกี่ยวข้องกับระบบสนับสนุนการตัดสินใจ (Decision Support Systems DSS) การซ่อมบำรุงเชิงพยากรณ์ (Predictive Maintenance: PdM) การพยากรณ์อายุการใช้งานคงเหลือของเครื่องจักร (Remaining Useful Life: RUL) ปัญญาประดิษฐ์แบบอธิบายได้ (Explainable AI: XAI) และเทคนิคการตัดสินใจหลายเกณฑ์ (Multi-Criteria Decision Making: MCDM) โดยคัดเลือกงานวิจัยที่ตีพิมพ์ในช่วง 5-10 ปีที่ผ่านมา ทั้งในระดับนานาชาติและระดับประเทศ หัวข้อดังนี้

1.5.2.1 ระบบสนับสนุนการตัดสินใจ (Decision Support System DSS)

ระบบสนับสนุนการตัดสินใจ (Decision Support System DSS) ถูกพัฒนาขึ้นเพื่อรองรับการตัดสินใจในบริบทที่มีความซับซ้อน มีข้อมูลหลายมิติ และมีความไม่แน่นอนสูง งานวิจัยในกลุ่มนี้ชี้ให้เห็นว่า DSS มีบทบาทสำคัญในการจัดโครงสร้างข้อมูลและแปลงองค์ความรู้ให้เป็นข้อมูลเชิงลึกที่สามารถนำไปใช้ตัดสินใจได้อย่างเป็นระบบ โดยเฉพาะเมื่อผสานแนวทางการตัดสินใจเชิงหลายเกณฑ์ (Multi-Criteria Decision Making: MCDM) ซึ่งช่วยให้การพิจารณาปัจจัยด้านเทคนิค เศรษฐกิจ และการปฏิบัติงานเป็นไปอย่างมีเหตุผลและตรวจสอบได้ [26]–[29] งานวิจัยด้าน MCDM ได้พัฒนาเทคนิคหลากหลายเพื่อจัดการความไม่แน่นอนของข้อมูลและความคิดเห็นผู้เชี่ยวชาญ เช่น Fuzzy Logic, AHP, TOPSIS และ MARCOS ซึ่งช่วยเพิ่มความโปร่งใสและความสอดคล้องของผลการตัดสินใจในระบบ DSS โดยเฉพาะในบริบทอุตสาหกรรมที่มีตัวแปรจำนวนมาก [30]–[35] นอกจากนี้ การบูรณาการกลไกการให้เหตุผลเชิงกฎ (Rule-Based Reasoning) และการให้เหตุผลเชิงกรณี (Case-Based Reasoning: CBR) ยังช่วยเสริมความสามารถในการอธิบายและตรวจสอบย้อนกลับของกระบวนการตัดสินใจ ซึ่งเป็นคุณลักษณะสำคัญของ DSS ที่ต้องการความน่าเชื่อถือสูง [36]–[40]

ตารางที่ 1 Synthesis of Decision Support Systems workflow

Component	Content (สรุปสาระสำคัญ)	Ref.
Decision Support System (DSS) Foundation	งานวิจัยกลุ่มนี้ชี้ให้เห็นว่า DSS เป็นกรอบเชิงระบบที่ช่วยจัดโครงสร้างข้อมูลและองค์ความรู้เพื่อสนับสนุนการตัดสินใจในสถานการณ์ที่มีความซับซ้อน โดยเน้นการรวมข้อมูลหลายมิติและการวิเคราะห์อย่างเป็นเหตุเป็นผล	[26]– [27]
Multi-Criteria Decision Making (MCDM)	MCDM ถูกใช้เป็นกลไกหลักของ DSS เพื่อจัดการการตัดสินใจที่ต้องพิจารณาปัจจัยหลายด้านพร้อมกัน เช่น ด้านเทคนิค เศรษฐกิจ และการดำเนินงาน ช่วยให้การตัดสินใจมีโครงสร้างและสามารถตรวจสอบได้	[28]– [29]
Fuzzy-based Decision Models	การประยุกต์ใช้ Fuzzy Logic ช่วยจัดการความไม่แน่นอน ความคลุมเครือของข้อมูล และความคิดเห็นผู้เชี่ยวชาญ ทำให้ DSS สามารถสะท้อนสภาพแวดล้อมจริงของอุตสาหกรรมที่ข้อมูลไม่สมบูรณ์ได้อย่างเหมาะสม	[30]– [31]
AHP-based Decision Support	เทคนิค Analytic Hierarchy Process (AHP) ถูกใช้เพื่อจัดลำดับความสำคัญของเกณฑ์และทางเลือกในการตัดสินใจ ช่วยลดอคติและเพิ่มความสอดคล้องของกระบวนการตัดสินใจในระบบ DSS	[32]– [33]
TOPSIS / MARCOS Techniques	เทคนิค TOPSIS และ MARCOS ถูกนำมาใช้เพื่อประเมินและจัดอันดับทางเลือกโดยอิงระยะห่างจากทางเลือกที่เหมาะสมที่สุด ช่วยเพิ่มความโปร่งใสและความสมเหตุสมผลของผลลัพธ์การตัดสินใจ	[34]– [35]
Rule-Based Reasoning	การให้เหตุผลเชิงกฎช่วยให้ DSS สามารถอธิบายเหตุผลของการตัดสินใจได้อย่างชัดเจน โดยอิงตรรกะที่กำหนดไว้ล่วงหน้า เหมาะสำหรับระบบที่ต้องการความโปร่งใสและการตรวจสอบย้อนกลับ	[36]– [37]
Case-Based Reasoning (CBR)	CBR สนับสนุนการตัดสินใจโดยอาศัยกรณีศึกษาในอดีตมาเปรียบเทียบกับสถานการณ์ปัจจุบัน ช่วยให้ DSS มีความยืดหยุ่นและสามารถเรียนรู้จากประสบการณ์จริง	[38]– [39]
Knowledge-based DSS Limitation	แม้ DSS ที่อิงกฎและกรณีศึกษาจะมีความอธิบายได้สูง แต่งานวิจัยสะท้อนว่ายังมีข้อจำกัดในการรองรับข้อมูลขนาดใหญ่และข้อมูลแบบเรียลไทม์จากเซนเซอร์ ซึ่งจำเป็นต้องการประยุกต์ใช้ในระบบซ่อมบำรุงเชิงพยากรณ์	[40]

จากการสังเคราะห์งานวิจัยพบว่า ระบบสนับสนุนการตัดสินใจ (Decision Support System: DSS) มีบทบาทสำคัญในการจัดโครงสร้างข้อมูลและองค์ความรู้เพื่อสนับสนุนการตัดสินใจในบริบทที่มีความซับซ้อน โดยอาศัยการบูรณาการข้อมูลหลายมิติร่วมกับกระบวนการตัดสินใจหลายเกณฑ์ ทำให้การตัดสินใจมีความเป็นระบบ โปร่งใส และสามารถตรวจสอบได้

อย่างไรก็ตาม งานวิจัยสะท้อนว่า DSS ที่อิงกฎและความรู้เป็นหลักยังมีข้อจำกัดในการรองรับข้อมูลขนาดใหญ่และข้อมูลแบบเรียลไทม์จากสภาพแวดล้อมจริง ส่งผลให้เกิดความจำเป็นในการพัฒนา DSS รูปแบบใหม่ที่บูรณาการเทคโนโลยีปัญญาประดิษฐ์และกลไกการอธิบายผลลัพธ์ เพื่อเพิ่มประสิทธิภาพ ความน่าเชื่อถือ และความเหมาะสมต่อการใช้งานในบริบทอุตสาหกรรมสมัยใหม่

1.5.2.2 การซ่อมบำรุงเชิงพยากรณ์ (Predictive Maintenance)

การซ่อมบำรุงเชิงพยากรณ์ (Predictive Maintenance: PdM) เป็นแนวทางที่มุ่งใช้ข้อมูลจากเซนเซอร์และระบบอัตโนมัติในการประเมินสภาพเครื่องจักรและพยากรณ์ความผิดปกติก่อนเกิดความล้มเหลวจริง งานวิจัยในช่วงที่ผ่านมาแสดงให้เห็นว่า PdM สามารถลด Downtime เพิ่มประสิทธิภาพการใช้ทรัพยากร และสนับสนุนการวางแผนการซ่อมบำรุงได้อย่างมีนัยสำคัญ โดยเฉพาะเมื่อผสานเทคนิค Machine Learning และ AI เข้ากับกระบวนการวิเคราะห์ข้อมูล [41]–[44]

อย่างไรก็ตาม งานวิจัยจำนวนมากในกลุ่ม PdM ยังคงมุ่งเน้นที่การเพิ่มความแม่นยำของการพยากรณ์เป็นหลัก ขณะที่การนำผลการพยากรณ์ไปใช้สนับสนุนการตัดสินใจเชิงปฏิบัติยังคงมีข้อจำกัด งานวิจัยบางส่วนเริ่มชี้ให้เห็นถึงความจำเป็นในการบูรณาการ PdM เข้ากับระบบระดับองค์กรและกระบวนการตัดสินใจ เพื่อให้ผลการพยากรณ์สามารถนำไปใช้ได้จริงในบริบทอุตสาหกรรม [45]–[48]

การทบทวนในส่วนนี้สะท้อนว่า PdM มีศักยภาพสูงในด้านการพยากรณ์ แต่ยังขาดกรอบการตัดสินใจเชิงระบบที่สามารถเชื่อมโยงผลการพยากรณ์กับการดำเนินงานจริงได้อย่างเป็นรูปธรรม

ตารางที่ 2. Synthesis of Predictive Maintenance workflow

Component	Content (สรุปสาระสำคัญ)	Ref.
Predictive Maintenance (PdM) Concept	งานวิจัยกลุ่มนี้ชี้ให้เห็นว่า PdM เป็นแนวทางการซ่อมบำรุงที่อาศัยข้อมูลจากเซนเซอร์และระบบอัตโนมัติในการประเมินสภาพเครื่องจักรล่วงหน้า เพื่อป้องกันความล้มเหลวก่อนเกิดขึ้นจริง และลดการหยุดชะงักของกระบวนการผลิต	[41]– [42]
AI-Driven PdM Models	การประยุกต์ใช้ Machine Learning และ AI ใน PdM ช่วยเพิ่มความแม่นยำในการตรวจจับความผิดปกติและการพยากรณ์แนวโน้มความเสียหายของเครื่องจักร โดยเฉพาะในสภาพแวดล้อมอุตสาหกรรมที่มีข้อมูลจำนวนมากและซับซ้อน	[43]– [44]
PdM Performance & Benefits	งานวิจัยรายงานว่า PdM สามารถลด Downtime ลดต้นทุนการซ่อมบำรุง และเพิ่มประสิทธิภาพการใช้ทรัพยากรของเครื่องจักรได้อย่างมีนัยสำคัญ เมื่อเทียบกับการซ่อมบำรุงแบบดั้งเดิม	[41]– [44]
PdM Limitation (Prediction-centric)	แม้ PdM จะมีความแม่นยำสูง แต่งานวิจัยสะท้อนว่าการพัฒนา PdM ส่วนใหญ่มุ่งเน้นที่ผลการพยากรณ์เป็นหลัก โดยยังขาดการเชื่อมโยงผลลัพธ์เข้ากับกระบวนการตัดสินใจเชิงปฏิบัติในระดับองค์กร	[45]– [46]
PdM Integration with Enterprise Systems	งานวิจัยบางส่วนเริ่มเสนอการบูรณาการ PdM เข้ากับระบบระดับองค์กร เช่น DSS และระบบวางแผน เพื่อให้ผลการพยากรณ์สามารถนำไปใช้สนับสนุนการตัดสินใจด้านการซ่อมบำรุงได้อย่างเป็นรูปธรรม	[47]– [48]
Need for Decision-Oriented PdM	จากการสังเคราะห์ พบว่า PdM ยังขาดกรอบการตัดสินใจเชิงระบบที่สามารถเชื่อมโยงข้อมูลการพยากรณ์กับการดำเนินงานจริง ซึ่งเป็นจุดตั้งต้นสำคัญของการพัฒนา PdM ที่ผสาน DSS และ XAI	[45]– [48]

จากการสังเคราะห์งานวิจัยพบว่า Predictive Maintenance (PdM) เป็นแนวทางการซ่อมบำรุงที่อาศัยข้อมูลจาก เซนเซอร์ ระบบอัตโนมัติ และแบบจำลองเชิงปัญญาประดิษฐ์ เพื่อประเมินสภาพเครื่องจักรล่วงหน้าและลดความเสี่ยงของความ ชัดข้องก่อนเกิดเหตุจริง โดยการประยุกต์ใช้ Machine Learning และ AI ช่วยเพิ่มความแม่นยำในการตรวจจับความผิดปกติ และการคาดการณ์แนวโน้มความเสียหาย ส่งผลให้สามารถลด Downtime ลดต้นทุนการซ่อมบำรุง และเพิ่มประสิทธิภาพการ ใช้ทรัพยากรของเครื่องจักรเมื่อเทียบกับการซ่อมบำรุงแบบดั้งเดิม

อย่างไรก็ตาม งานวิจัยส่วนใหญ่ยังมุ่งเน้น PdM ในเชิงการพยากรณ์เป็นหลัก โดยขาดการเชื่อมโยงผลการคาดการณ์เข้ากับ กระบวนการตัดสินใจเชิงปฏิบัติในระดับองค์กร แม้จะเริ่มมีแนวโน้มการบูรณาการ PdM เข้ากับระบบระดับองค์กร เช่น ระบบ สนับสนุนการตัดสินใจ แต่ยังคงขาดการตัดสินใจเชิงระบบที่เชื่อมโยงข้อมูลพยากรณ์กับการดำเนินงานจริงอย่างครบถ้วน สะท้อนถึงความจำเป็นในการพัฒนา PdM ที่มีลักษณะมุ่งเน้นการตัดสินใจ โดยบูรณาการ DSS และกลไกการอธิบายผลลัพธ์ เพื่อรองรับการใช้งานในบริบทอุตสาหกรรมสมัยใหม่อย่างมีประสิทธิภาพ

1.5.2.3 ปัญญาประดิษฐ์แบบอธิบายได้ (Explainable Artificial Intelligence XAI)

ข้อจำกัดสำคัญของ PdM ที่ขับเคลื่อนด้วย AI คือการพึ่งพาโมเดลแบบกล่องดำ ซึ่งยากต่อการอธิบายเหตุผลของ ผลลัพธ์ งานวิจัยด้าน Explainable Artificial Intelligence (XAI) จึงถูกพัฒนาขึ้นเพื่อเพิ่มความโปร่งใสและความเข้าใจของ ผู้ใช้งานต่อการตัดสินใจของโมเดล AI งานวิจัยในกลุ่มนี้ชี้ให้เห็นว่า XAI สามารถอธิบายปัจจัยที่มีอิทธิพลต่อผลการพยากรณ์ และช่วยให้ผู้เชี่ยวชาญสามารถตรวจสอบความสมเหตุสมผลของโมเดลได้ [49]–[52]

การทบทวนวรรณกรรมเชิงระบบยังสะท้อนว่า แม้เทคนิค XAI เช่น SHAP, LIME และ Rule-based Explanation จะมี ศักยภาพในการสนับสนุนงานด้าน Prognostics and Health Management (PHM) แต่การนำ XAI ไปใช้มักจำกัดอยู่ในระดับ การอธิบายโมเดล และยังไม่ถูกบูรณาการเข้ากับกระบวนการตัดสินใจเชิงระบบอย่างครบวงจร [53]–[55] นอกจากนี้ งานวิจัย ล่าสุดยังเสนอว่าการอธิบายผลลัพธ์ของ AI ควรถูกพิจารณาพร้อมกับประเด็นด้านความไว้วางใจ (trust) เพื่อเพิ่มการยอมรับของ ผู้ใช้งานในภาคอุตสาหกรรม [56]

ตารางที่ 3 Synthesis of Explainable Artificial Intelligence workflow

Component	Content (สรุปสาระสำคัญ)	Ref.
Human-centric AI & Industry 5.0	งานวิจัยกลุ่มนี้เสนอการเปลี่ยนผ่านจาก Industry 4.0 ไปสู่ Industry 5.0 โดยเน้นการทำงานร่วมกันระหว่าง มนุษย์และ AI (Human-AI collaboration) เพื่อให้ระบบอัจฉริยะสอดคล้องกับการตัดสินใจของมนุษย์และ เพิ่มการยอมรับในภาคอุตสาหกรรม	[49]– [50]
Explainable AI (XAI) in Industrial Systems	XAI ถูกเสนอเป็นกลไกสำคัญในการอธิบายเหตุผลของผลลัพธ์จากโมเดล AI ในระบบอุตสาหกรรม เพื่อเพิ่ม ความโปร่งใส ความเข้าใจ และความสามารถในการตรวจสอบของระบบอัตโนมัติ	[51]– [52]
XAI for Predictive Maintenance	งานวิจัยด้าน XAI สำหรับ PdM แสดงให้เห็นว่าเทคนิคการอธิบายสามารถช่วยให้ผู้เชี่ยวชาญเข้าใจปัจจัยที่ ส่งผลต่อการพยากรณ์ความผิดปกติและ RUL ของเครื่องจักรได้อย่างเป็นรูปธรรม	[53]
Systematic Review of XAI in PHM	การทบทวนวรรณกรรมเชิงระบบตามแนวทาง PRISMA ชี้ให้เห็นว่า XAI มีศักยภาพสูงในงาน Prognostics and Health Management (PHM) แต่การนำไปใช้ยังจำกัดอยู่ในระดับโมเดล และขาดการเชื่อมโยงกับ กระบวนการตัดสินใจเชิงระบบ	[54]
XAI-based PdM Frameworks	งานวิจัยบางส่วนเริ่มเสนอกรอบแนวคิด PdM ที่ผสมผสาน XAI เข้ากับโมเดลการพยากรณ์ เพื่อสนับสนุนการ ตัดสินใจที่อธิบายได้และสอดคล้องกับผู้ใช้งานในอุตสาหกรรม	[55]

Trust & Reliability in AI Predictions	งานวิจัยล่าสุดชี้ให้เห็นว่าความสามารถในการอธิบายของ AI ควรถูกพิจารณาควบคู่กับการประเมินระดับความไว้วางใจ (trust) และความน่าเชื่อถือของผลการพยากรณ์ เพื่อเพิ่มการยอมรับและการนำระบบไปใช้จริงในภาคอุตสาหกรรม	[56]
---------------------------------------	--	------

จากการสังเคราะห์งานวิจัยด้าน Explainable Artificial Intelligence (XAI) พบว่า แนวคิดการพัฒนา AI ในภาคอุตสาหกรรมมีการเปลี่ยนผ่านจากการมุ่งเน้นประสิทธิภาพของโมเดลเพียงอย่างเดียว ไปสู่แนวคิด Human-centric AI ภายใต้บริบท Industry 5.0 ซึ่งให้ความสำคัญกับการทำงานร่วมกันระหว่างมนุษย์และ AI เพื่อให้ผลลัพธ์การตัดสินใจสอดคล้องกับความเข้าใจและการยอมรับของผู้ใช้งานงานวิจัยชี้ให้เห็นว่า XAI มีบทบาทสำคัญในการเพิ่มความโปร่งใส ความเข้าใจ และความสามารถในการตรวจสอบของระบบอัตโนมัติในภาคอุตสาหกรรม โดยเฉพาะในงาน Predictive Maintenance ซึ่งเทคนิค XAI ช่วยอธิบายปัจจัยที่ส่งผลต่อการพยากรณ์ความผิดปกติและอายุการใช้งานคงเหลือของเครื่องจักรได้อย่างเป็นรูปธรรม อย่างไรก็ตาม การทบทวนวรรณกรรมเชิงระบบสะท้อนว่า XAI ส่วนใหญ่ยังถูกประยุกต์ใช้ในระดับโมเดล และยังขาดการเชื่อมโยงกับกระบวนการตัดสินใจเชิงระบบในระดับปฏิบัติการ นอกจากนี้ งานวิจัยเริ่มเสนอกรอบแนวคิด PdM ที่บูรณาการ XAI เพื่อสนับสนุนการตัดสินใจที่สามารถอธิบายได้และสอดคล้องกับผู้ใช้งาน ขณะเดียวกัน ความสามารถในการอธิบายของ AI ถูกระบุว่าเป็นปัจจัยสำคัญต่อความไว้วางใจและความน่าเชื่อถือของผลการพยากรณ์ ซึ่งเป็นเงื่อนไขสำคัญต่อการนำ AI ไปใช้งานจริงในภาคอุตสาหกรรมอย่างยั่งยืน

#### 1.5.2.4 อุตสาหกรรมไฟฟ้าจราจร (Traffic Electrical Industry)

อุตสาหกรรมไฟฟ้าจราจรเป็นอุตสาหกรรมเฉพาะทางที่เกี่ยวข้องโดยตรงกับความปลอดภัยสาธารณะและโครงสร้างพื้นฐานของเมือง เครื่องจักรที่ใช้ในการผลิตอุปกรณ์ไฟฟ้าจราจรมักต้องทำงานภายใต้ภาระงานสูงและสภาพแวดล้อมที่หลากหลาย ส่งผลให้เกิดการเสื่อมสภาพของเครื่องจักรอย่างต่อเนื่อง งานวิจัยด้านการออกแบบระบบอุตสาหกรรมยุคใหม่และการนำเสนอข้อมูลผ่านแดชบอร์ดแบบผู้ใช้เป็นศูนย์กลางได้ชี้ให้เห็นถึงความสำคัญของการสนับสนุนการรับรู้สถานการณ์และการตัดสินใจของผู้ปฏิบัติงานในบริบทเฉพาะทาง [57], [58]

อย่างไรก็ตาม ยังไม่ปรากฏงานวิจัยที่พัฒนากรอบแนวคิด PdM และ DSS ที่ออกแบบมาเพื่อตอบโจทย์อุตสาหกรรมไฟฟ้าจราจรโดยตรง ซึ่งสะท้อนช่องว่างเชิงบริบทที่สำคัญของงานวิจัยนี้

ตารางที่ 4 Synthesis of Traffic Electrical Industry workflow

Component	Content (สรุปสาระสำคัญ)	Ref.
Industrial Implementation of Data-Driven Maintenance	งานวิจัยกลุ่มนี้สะท้อนให้เห็นถึงแนวทางการนำระบบซ่อมบำรุงเชิงข้อมูลและการวิเคราะห์เชิงพยากรณ์ไปใช้จริงในบริบทอุตสาหกรรม โดยเน้นการเชื่อมโยงข้อมูลการทำงานของเครื่องจักรเข้ากับกระบวนการตัดสินใจของผู้ปฏิบัติงานในระดับหน้างานและระดับบริหาร	[57]
User-Centered Dashboard for Decision Support	การออกแบบแดชบอร์ดตามแนวคิดผู้ใช้เป็นศูนย์กลาง (User-Centered Design) มีบทบาทสำคัญในการสนับสนุนการรับรู้สถานการณ์ การตีความข้อมูล และการตัดสินใจในระบบอุตสาหกรรมที่มีความซับซ้อน โดยช่วยแปลงข้อมูลเชิงเทคนิคให้เป็นข้อมูลที่เข้าใจง่ายและนำไปใช้ได้จริง	[58]

จากการสังเคราะห์งานวิจัยด้านอุตสาหกรรมไฟฟ้าจราจร พบว่า การประยุกต์ใช้ระบบซ่อมบำรุงเชิงข้อมูลและการวิเคราะห์เชิงพยากรณ์ในบริบทอุตสาหกรรมมีบทบาทสำคัญต่อการเชื่อมโยงข้อมูลสมรรถนะของเครื่องจักรเข้ากับกระบวนการตัดสินใจทั้งในระดับผู้ปฏิบัติงานและผู้บริหาร ทำให้การซ่อมบำรุงมีความสอดคล้องกับสภาพการใช้งานจริงและสามารถตอบสนองต่อสถานการณ์ได้อย่างมีประสิทธิภาพ ขณะเดียวกัน งานวิจัยชี้ให้เห็นว่าการออกแบบแดชบอร์ดที่ยึดผู้ใช้เป็นศูนย์กลางมีบทบาทสำคัญในการแปลงข้อมูลเชิงเทคนิคที่ซับซ้อนให้เป็นสารสนเทศที่เข้าใจง่ายและนำไปใช้ได้จริง ช่วยเสริมการ

รับรู้สถานการณ์ การตีความข้อมูล และการตัดสินใจในระบบอุตสาหกรรมที่มีความซับซ้อน โดยเฉพาะในบริบทของ อุตสาหกรรมไฟฟ้าจราจร

1.5.2.5 อายุการใช้งานคงเหลือของเครื่องจักร (Remaining Useful Life RUL)

การประมาณอายุการใช้งานคงเหลือของเครื่องจักร (Remaining Useful Life RUL) เป็นองค์ประกอบหลักของระบบ Pdm เนื่องจากผลลัพธ์ RUL ถูกนำไปใช้ในการวางแผนซ่อมบำรุงและการตัดสินใจเชิงกลยุทธ์ งานวิจัยด้านการนำเสนอข้อมูล การออกแบบแดชบอร์ด และการประเมินการใช้งานระบบในระดับอุตสาหกรรมชี้ให้เห็นว่า RUL จะมีคุณค่าเชิงปฏิบัติก็ต่อเมื่อสามารถสื่อสารผลลัพธ์ให้ผู้ใช้งานเข้าใจและนำไปใช้ได้เหมาะสม [59]–[61]

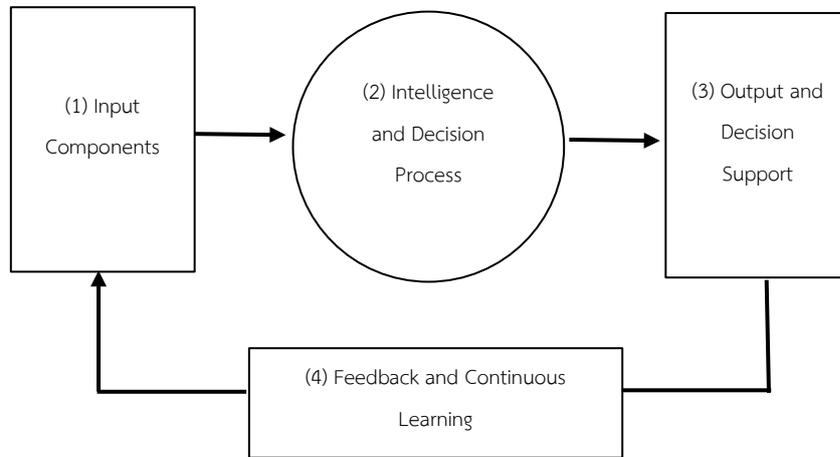
การบูรณาการ RUL เข้ากับ DSS และการนำเสนอข้อมูลผ่านแดชบอร์ดแบบผู้ใช้เป็นศูนย์กลางจึงเป็นแนวทางสำคัญในการยกระดับระบบซ่อมบำรุงเชิงพยากรณ์จากระดับการพยากรณ์ไปสู่ระดับการตัดสินใจเชิงระบบ ซึ่งสอดคล้องโดยตรงกับกรอบแนวคิดของงานวิจัยนี้

ตารางที่ 5 Synthesis of Remaining Useful Life workflow

Component	Content (สรุปสาระสำคัญ)	Ref.
RUL as Decision-Oriented Information	งานวิจัยกลุ่มนี้ชี้ให้เห็นว่า RUL ไม่ควรถูกใช้เป็นเพียงผลลัพธ์เชิงตัวเลขของโมเดลพยากรณ์ แต่ควรถูกนำเสนอในลักษณะข้อมูลเชิงการตัดสินใจที่สามารถสนับสนุนการวางแผนซ่อมบำรุงและการจัดการทรัพยากรในระดับองค์กรได้อย่างเป็นรูปธรรม	[59]
Visualization of RUL Information	การนำเสนอข้อมูล RUL ผ่านการแสดงผลเชิงภาพและแดชบอร์ดช่วยเพิ่มความเข้าใจของผู้ใช้งาน ลดภาระด้านการตีความข้อมูลเชิงเทคนิค และสนับสนุนการรับรู้สถานการณ์ของผู้ปฏิบัติงานในสภาพแวดล้อมอุตสาหกรรม	[60]
User-Centered RUL Dashboard	งานวิจัยด้านการออกแบบแดชบอร์ดแบบผู้ใช้เป็นศูนย์กลางชี้ให้เห็นว่า RUL จะมีคุณค่าเชิงปฏิบัติก็ต่อเมื่อการนำเสนอข้อมูลสอดคล้องกับบริบทการใช้งานจริงของผู้ใช้ และเชื่อมโยงผลการพยากรณ์กับการตัดสินใจด้านการซ่อมบำรุงอย่างชัดเจน	[61]

จากการสังเคราะห์งานวิจัยพบว่า ข้อมูลอายุการใช้งานคงเหลือของเครื่องจักร (Remaining Useful Life: RUL) ไม่ควรถูกนำเสนอเพียงในรูปค่าตัวเลขจากแบบจำลองพยากรณ์เท่านั้น แต่ควรถูกพัฒนาให้เป็นสารสนเทศเชิงการตัดสินใจที่สามารถสนับสนุนการวางแผนการซ่อมบำรุงและการจัดสรรทรัพยากรในระดับองค์กรได้อย่างเป็นรูปธรรม งานวิจัยชี้ให้เห็นว่าการนำเสนอข้อมูล RUL ผ่านการแสดงผลเชิงภาพและแดชบอร์ดช่วยเพิ่มความเข้าใจของผู้ใช้งาน ลดภาระในการตีความข้อมูลเชิงเทคนิค และเสริมการรับรู้สถานการณ์ในสภาพแวดล้อมอุตสาหกรรมที่มีความซับซ้อน โดยเฉพาะเมื่อการออกแบบแดชบอร์ดยึดผู้ใช้เป็นศูนย์กลางและเชื่อมโยงผลการพยากรณ์เข้ากับบริบทการตัดสินใจจริง ข้อมูล RUL จึงจะเกิดคุณค่าเชิงปฏิบัติอย่างแท้จริง

ผลจากการสังเคราะห์ถูกนำมาจัดโครงสร้างกรอบแนวคิดระบบ XAI-PdM DSS ภายใต้กรอบ IPOF (Input-Process-Output-Feedback) ซึ่งประกอบด้วย 4 ส่วนหลัก ได้แก่



ภาพที่ 2 โครงสร้างกรอบแนวคิด IPOF

(1) Input Components ประกอบด้วยข้อมูลจากการปฏิบัติงานจริงของระบบซ่อมบำรุง ได้แก่ ข้อมูลเซนเซอร์แบบเรียลไทม์ ข้อมูลการผลิต ประวัติการซ่อมบำรุง และข้อมูลเหตุขัดข้องของเครื่องจักร ซึ่งทำหน้าที่เป็นฐานข้อมูลสำหรับการวิเคราะห์เชิงพยากรณ์

(2) Intelligence and Decision Process ครอบคลุมกระบวนการวิเคราะห์ความผิดปกติ การพยากรณ์อายุการใช้งานคงเหลือของเครื่องจักร การจำแนกระดับความเสี่ยง และการอธิบายผลลัพธ์ด้วยเทคนิค XAI รวมถึงการจัดลำดับความสำคัญของงานซ่อมบำรุงด้วยเทคนิค MCDM เพื่อสนับสนุนการตัดสินใจอย่างเป็นระบบ

(3) Output and Decision Support ได้แก่ ผลลัพธ์เชิงการตัดสินใจ เช่น ค่าพยากรณ์ RUL ระดับความเสี่ยงและดัชนีสุขภาพเครื่องจักร แผนการซ่อมบำรุง และคำอธิบายเหตุผลของการตัดสินใจผ่าน Dashboard ซึ่งสามารถนำไปใช้สนับสนุนการตัดสินใจทั้งในระดับปฏิบัติการและระดับบริหาร

(4) Feedback and Continuous Learning เป็นกลไกการเรียนรู้ย้อนกลับของระบบ โดยนำผลการซ่อมบำรุงจริง ผลลัพธ์การตัดสินใจ และข้อมูลการใช้งานจากผู้ปฏิบัติงานกลับเข้าสู่ระบบ เพื่อปรับปรุงความแม่นยำของแบบจำลองการพยากรณ์ การอธิบายด้วย XAI และเกณฑ์การตัดสินใจอย่างต่อเนื่อง กลไก Feedback นี้ช่วยให้กรอบแนวคิด XAI-PdM DSS สามารถปรับตัวให้สอดคล้องกับสภาพการทำงานของเครื่องจักรที่เปลี่ยนแปลงไป และเพิ่มความเหมาะสมในการนำไปประยุกต์ใช้งานจริงในระยะยาว

การเชื่อมโยงองค์ประกอบทั้งสี่ส่วนถูกออกแบบให้เป็น วงจรการทำงานแบบปิด (Closed-loop System) เพื่อให้กรอบแนวคิดมีความสอดคล้องทั้งเชิงทฤษฎี เชิงระบบ และเชิงปฏิบัติ ตามแนวทางของระบบสนับสนุนการตัดสินใจอัจฉริยะในบริบทอุตสาหกรรม

### 1.5.3 การพัฒนาระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์สำหรับอุตสาหกรรมไฟฟ้าจราจร

จากกรอบแนวคิดที่พัฒนาขึ้น ผู้วิจัยได้สร้างเครื่องมือประเมินความเหมาะสมของกรอบแนวคิดในรูปแบบแบบสอบถามสำหรับผู้เชี่ยวชาญ โดยกำหนดข้อคำถามให้ครอบคลุมมิติสำคัญของระบบ XAI-PdM DSS จำนวนทั้งหมด 18 รายการ แบ่งออกเป็น 5 มิติ ได้แก่

- (1) คุณภาพของระบบ (System Quality)
- (2) คุณภาพของปัญญาประดิษฐ์ (Intelligence Quality)
- (3) คุณภาพการตัดสินใจ (Decision Quality)
- (4) ความสามารถในการเรียนรู้และปรับตัวของระบบ (Learning & Adaptation Quality)
- (5) ผลกระทบต่อผู้ใช้งานและการดำเนินงาน (User & Operational Impact Quality)

แบบสอบถามใช้มาตราส่วนประมาณค่า 5 ระดับ ตั้งแต่ระดับน้อยที่สุด (1) ถึงระดับมากที่สุด (5) พร้อมช่องสำหรับข้อเสนอแนะเพิ่มเติม เพื่อนำไปใช้ในการปรับปรุงกรอบแนวคิดให้มีความสมบูรณ์ยิ่งขึ้น

### 1.5.4 ขั้นตอนการเก็บรวบรวมข้อมูล

ผู้วิจัยจัดส่งเอกสารกรอบแนวคิดระบบ XAI-PdM DSS พร้อมแบบสอบถามการประเมินความเหมาะสมให้แก่ผู้เชี่ยวชาญ 15 คน ประกอบด้วย 1. ผู้เชี่ยวชาญด้านซ่อมบำรุง จำนวน 5 คน 2. ผู้เชี่ยวชาญด้านปัญญาประดิษฐ์ จำนวน 5 คน และ 3. ผู้เชี่ยวชาญด้านระบบสนับสนุนการตัดสินใจ จำนวน 5 คน ในรูปแบบออนไลน์ ผู้เชี่ยวชาญทำการศึกษารอบแนวคิดและประเมินแต่ละรายการตามความคิดเห็นเชิงวิชาชีพของตนเอง ข้อมูลที่ได้รับถูกตรวจสอบความครบถ้วนก่อนนำไปวิเคราะห์

### 1.5.5 ขั้นตอนการวิเคราะห์ข้อมูล

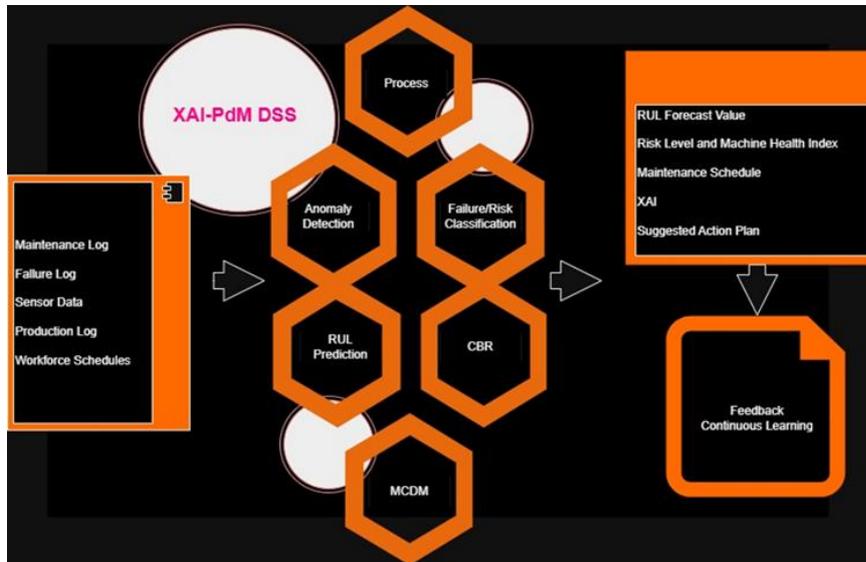
การวิเคราะห์ข้อมูลใช้สถิติเชิงพรรณนา ได้แก่ ค่าเฉลี่ย (Mean) และส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation: SD) เพื่ออธิบายระดับความเหมาะสมของกรอบแนวคิดในแต่ละมิติ โดยกำหนดเกณฑ์การแปลผลดังนี้: ค่าเฉลี่ย 4.50–5.00 หมายถึง เหมาะสมในระดับมากที่สุด, 3.50–4.49 หมายถึง เหมาะสมในระดับมาก, 2.50–3.49 หมายถึง เหมาะสมในระดับปานกลาง และต่ำกว่านั้นตามลำดับ

### 1.5.6 ข้อควรพิจารณาทางจริยธรรม

งานวิจัยนี้เป็นการประเมินเชิงแนวคิดโดยผู้เชี่ยวชาญ ไม่มีการเก็บข้อมูลส่วนบุคคลหรือข้อมูลอ่อนไหว ผู้เชี่ยวชาญทุกคนได้รับแจ้งวัตถุประสงค์ของการวิจัย และข้อมูลที่ได้รับจะถูกนำเสนอในภาพรวมโดยไม่เปิดเผยตัวตน

1.6 ผลการวิจัย

1.6.1. โครงสร้างกรอบแนวคิดระบบ XAI-PdM DSS



ภาพที่ 3 ระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ (XAI-PdM DSS)

จากภาพที่ 3. แสดงโครงสร้างกรอบแนวคิดของระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์ (Explainable Artificial Intelligence-based Predictive Maintenance Decision Support System: XAI-PdM DSS) ซึ่งออกแบบตามกรอบแนวคิด IPOF (Input-Process-Output-Feedback) เพื่อสะท้อนการทำงานของระบบในลักษณะวงจรรปิด (Closed-loop System) ที่สามารถเรียนรู้และปรับปรุงได้อย่างต่อเนื่อง

Input ระบบรับข้อมูลจากแหล่งข้อมูลหลักที่เกี่ยวข้องกับการดำเนินงานซ่อมบำรุง ได้แก่ ข้อมูลประวัติการซ่อมบำรุง (Maintenance Logs) ข้อมูลเหตุขัดข้องของเครื่องจักร (Failure Logs) ข้อมูลจากเซนเซอร์แบบเรียลไทม์ (Sensor Data) ข้อมูลด้านการผลิต (Product Logs) และข้อมูลตารางกำลังคนด้านการซ่อมบำรุง (Workforce Schedules) ซึ่งข้อมูลเหล่านี้สะท้อนถึงสภาพการทำงานของเครื่องจักรและบริบทเชิงปฏิบัติการในอุตสาหกรรมไฟฟ้าจราจร

Process เป็นแกนหลักของระบบ โดยประกอบด้วยกระบวนการอัจฉริยะหลายขั้นตอน ได้แก่ การตรวจจับความผิดปกติของเครื่องจักร (Anomaly Detection) การจำแนกประเภทความเสียหายและระดับความเสี่ยง (Failure/Risk Classification) การพยากรณ์อายุการใช้งานคงเหลือของเครื่องจักร (Remaining Useful Life Prediction) และการใช้เหตุผลเชิงกรณี (Case-Based Reasoning: CBR) เพื่อเปรียบเทียบกับประสบการณ์การซ่อมบำรุงในอดีต นอกจากนี้ ระบบยังใช้เทคนิคการตัดสินใจหลายเกณฑ์ (Multi-Criteria Decision Making: MCDM) ได้แก่ AHP และ TOPSIS เพื่อจัดลำดับความสำคัญของงานซ่อมบำรุงอย่างเป็นระบบ

Output ระบบนำเสนอผลลัพธ์เชิงการตัดสินใจที่สามารถนำไปใช้ได้จริง ประกอบด้วย ค่าพยากรณ์อายุการใช้งานคงเหลือของเครื่องจักร (RUL Forecast Value) ระดับความเสี่ยงและดัชนีสุขภาพของเครื่องจักร (Risk Level and Machine Health Index) แผนการซ่อมบำรุง (Maintenance Schedule) การอธิบายเหตุผลของผลการพยากรณ์และการตัดสินใจด้วยเทคนิค XAI เช่น SHAP Summary และ LIME Visualization รวมถึงข้อเสนอแนะเชิงปฏิบัติ (Suggested Action Plan) เพื่อสนับสนุนการตัดสินใจทั้งในระดับปฏิบัติการและระดับบริหาร

สำหรับส่วนของ Feedback ระบบใช้กลไกการเรียนรู้แบบต่อเนื่อง (Continuous Learning) โดยนำผลลัพธ์จากการซ่อมบำรุงจริงและการตัดสินใจกลับเข้าสู่ระบบ เพื่อปรับปรุงความแม่นยำของแบบจำลอง การอธิบายด้วย XAI และเกณฑ์การตัดสินใจในรอบถัดไป กลไกนี้ช่วยให้ระบบ XAI-PdM DSS สามารถปรับตัวให้สอดคล้องกับสภาพการทำงานของเครื่องจักรที่เปลี่ยนแปลงไป และเพิ่มความเหมาะสมในการนำไปใช้งานจริงในระยะยาว

แสดงให้เห็นว่ากรอบแนวคิด XAI-PdM DSS เป็นระบบสนับสนุนการตัดสินใจเชิงพยากรณ์ที่บูรณาการข้อมูล การวิเคราะห์อัจฉริยะ การอธิบายผลลัพธ์ และการเรียนรู้ย้อนกลับเข้าไว้ด้วยกันอย่างเป็นระบบและโปร่งใส ซึ่งสอดคล้องกับแนวทางการพัฒนาระบบอัจฉริยะในบริบทอุตสาหกรรมยุคดิจิทัล

### 1.6.2 ผลการประเมินความเหมาะสมของกรอบแนวคิดโดยผู้เชี่ยวชาญ

การประเมินความเหมาะสมของกรอบแนวคิดระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์ (XAI-PdM DSS) ดำเนินการโดยผู้เชี่ยวชาญจำนวน 15 คน ประกอบด้วย 1. ผู้เชี่ยวชาญด้านซ่อมบำรุงจำนวน 5 คน 2. ผู้เชี่ยวชาญด้านปัญญาประดิษฐ์ จำนวน 5 คนและ 3. ผู้เชี่ยวชาญด้านระบบสนับสนุนการตัดสินใจ จำนวน 5 คน การประเมินใช้แบบสอบถามมาตราส่วนประมาณค่า 5 ระดับ ครอบคลุมองค์ประกอบของกรอบแนวคิดตามกรอบ IPOF และมีคุณภาพของระบบ

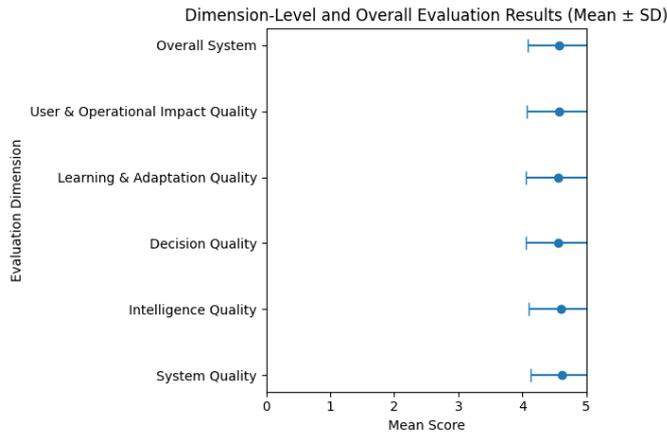
ตารางที่ 6 ผลการประเมินความเหมาะสมของระบบ XAI-PdM DSS (มาตรฐานค่า 5 ระดับ, n = 15 ผู้เชี่ยวชาญ)

มิติการประเมิน	รหัสข้อ	รายการประเมิน (ชื่อย่อ)	Mean ( $\bar{x}$ )	S.D.	ระดับ
System Quality	1	ระบบสามารถรวบรวมและแสดงข้อมูลบำรุงรักษาย้อนหลังได้ครบถ้วนและถูกต้อง	4.67	0.49	เหมาะสมมากที่สุด
	2	ข้อมูลเซนเซอร์ถูกนำมาใช้วิเคราะห์ได้อย่างเหมาะสม	4.60	0.51	เหมาะสมมากที่สุด
	3	ระบบสามารถเชื่อมโยงข้อมูลการผลิตกับข้อมูลบำรุงรักษาได้อย่างมีประสิทธิภาพ	4.73	0.46	เหมาะสมมากที่สุด
	4	Dashboard มีความชัดเจน เข้าใจง่าย และนำเสนอข้อมูลครบถ้วน	4.47	0.52	เหมาะสมมาก
ค่าเฉลี่ยรวมมิติ System Quality			4.62	0.49	เหมาะสมมากที่สุด
Intelligence Quality	5	ระบบสามารถตรวจจับความผิดปกติของเครื่องจักรได้อย่างแม่นยำ	4.67	0.49	เหมาะสมมากที่สุด
	6	แบบจำลอง AI-XAI สามารถพยากรณ์อายุการใช้งานคงเหลือ (RUL) ได้อย่างถูกต้อง	4.67	0.49	เหมาะสมมากที่สุด
	7	การอธิบายผลด้วย SHAP/LIME มีความชัดเจนและเข้าใจง่าย	4.47	0.52	เหมาะสมมาก

## สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

		ค่าเฉลี่ยรวมมิติ Intelligence Quality	4.60	0.50	เหมาะสมมากที่สุด
Decision Quality	8	ระบบจัดลำดับความสำคัญของงานซ่อมบำรุงด้วย AHP/TOPSIS ได้ตรงตามความเป็นจริง	4.60	0.51	เหมาะสมมากที่สุด
	9	การแสดงผลการพยากรณ์ช่วยลดเวลาในการวางแผนซ่อมบำรุง	4.47	0.52	เหมาะสมมากที่สุด
	10	ข้อมูลจากระบบสามารถใช้ประกอบการตัดสินใจของฝ่ายบริหารได้	4.60	0.51	เหมาะสมมากที่สุด
		ค่าเฉลี่ยรวมมิติ Decision Quality	4.56	0.50	เหมาะสมมากที่สุด
Learning & Adaptation Quality	11	ระบบสามารถเรียนรู้จากข้อมูลการซ่อมบำรุงที่ผ่านมาเพื่อปรับปรุงความแม่นยำของการพยากรณ์	4.47	0.52	เหมาะสมมากที่สุด
	12	ระบบสามารถนำข้อมูล Feedback จากผู้ใช้งานมาปรับปรุงแบบจำลองและการตัดสินใจ	4.60	0.51	เหมาะสมมากที่สุด
	13	ระบบสามารถปรับตัวให้สอดคล้องกับการเปลี่ยนแปลงของสภาพการทำงานเครื่องจักร	4.60	0.51	เหมาะสมมากที่สุด
		ค่าเฉลี่ยรวมมิติ Learning & Adaptation Quality	4.56	0.50	เหมาะสมมากที่สุด
User & Operational Impact Quality	14	ระบบสามารถช่วยลด Downtime ของเครื่องจักรได้จริง	4.33	0.49	เหมาะสมมากที่สุด
	15	ระบบช่วยเพิ่มประสิทธิภาพการจัดการทรัพยากรบุคคลด้านซ่อมบำรุง	4.67	0.49	เหมาะสมมากที่สุด
	16	ระบบช่วยลดค่าใช้จ่ายด้านการซ่อมบำรุงเมื่อเทียบกับวิธีเดิม	4.73	0.46	เหมาะสมมากที่สุด
	17	ระบบมีความเหมาะสมต่อการนำไปใช้งานจริงในโรงงานอุตสาหกรรมไฟฟ้าจรรยา	4.53	0.52	เหมาะสมมากที่สุด
	18	ความพึงพอใจโดยรวมของผู้เชี่ยวชาญต่อระบบ	4.60	0.51	เหมาะสมมากที่สุด
		ค่าเฉลี่ยรวมมิติ User & Operational Impact Quality	4.57	0.50	เหมาะสมมากที่สุด
ภาพรวมระบบ	ALL	ค่าเฉลี่ยรวมระบบ XAI-PdM DSS	<u>4.58</u>	<u>0.49</u>	เหมาะสมมากที่สุด

Overall System



ภาพที่ 4 สรุปประเมินความเหมาะสม Overall System

ภาพรวมระบบ ซึ่งนำเสนอค่าเฉลี่ย (Mean) และส่วนเบี่ยงเบนมาตรฐาน ( $\pm$  SD) ของผลการประเมินโดยผู้เชี่ยวชาญ พบว่า กรอบแนวคิดระบบ XAI-PdM DSS ได้รับการประเมินความเหมาะสมในระดับมากที่สุดทุกมิติ โดยมีค่าเฉลี่ยอยู่ในช่วง 4.56–4.62 และมีส่วนเบี่ยงเบนมาตรฐานอยู่ในระดับต่ำถึงปานกลาง (0.49–0.50) สะท้อนให้เห็นถึงความเห็นพ้องของผู้เชี่ยวชาญในระดับสูง เมื่อพิจารณาแยกตามมิติ พบว่า มิติคุณภาพของระบบ (System Quality) มีค่าเฉลี่ยสูงสุด ( $\bar{X}$  = 4.62, SD = 0.49) รองลงมาคือ มิติคุณภาพด้านปัญญาประดิษฐ์ (Intelligence Quality) ( $\bar{X}$  = 4.60, SD = 0.50) และ มิติผลกระทบต่อผู้ใช้และการดำเนินงาน (User & Operational Impact Quality) ( $\bar{X}$  = 4.57, SD = 0.50) ขณะที่ มิติคุณภาพด้านการตัดสินใจ (Decision Quality) และ มิติการเรียนรู้และการปรับตัวของระบบ (Learning & Adaptation Quality) มีค่าเฉลี่ยเท่ากัน ( $\bar{X}$  = 4.56, SD = 0.50) สำหรับ ผลการประเมินภาพรวมทั้งระบบ (Overall System) ( $\bar{X}$  = 4.58, SD = 0.49) ยืนยันว่ากรอบแนวคิด XAI-PdM DSS ที่พัฒนาขึ้นมีความเหมาะสม ครบถ้วน และมีศักยภาพในการนำไปประยุกต์ใช้งานจริง ทั้งในด้านโครงสร้างระบบ กระบวนการวิเคราะห์อัจฉริยะ การสนับสนุนการตัดสินใจ และผลกระทบต่อการใช้งานในบริบทอุตสาหกรรมไฟฟ้าจรรยา

ผลการประเมินความเหมาะสมของกรอบแนวคิดสะท้อนให้เห็นว่าผู้เชี่ยวชาญให้ความสำคัญกับความครบถ้วนของโครงสร้างระบบและกลไกการสนับสนุนการตัดสินใจ โดยเฉพาะในมิติด้านคุณภาพการตัดสินใจและผลกระทบต่อการใช้งานจริง ซึ่งบ่งชี้ว่ากรอบแนวคิดที่พัฒนาขึ้นมีศักยภาพในการลดการพึ่งพาประสบการณ์ส่วนบุคคล และช่วยให้การตัดสินใจด้านการซ่อมบำรุงมีความเป็นระบบและตรวจสอบได้มากขึ้นในบริบทอุตสาหกรรม

1.7 อภิปราย

อภิปรายผล

ผลการวิจัยสะท้อนให้เห็นว่าการออกแบบกรอบแนวคิดระบบ XAI-PdM DSS ที่บูรณาการการวิเคราะห์ข้อมูลและการตัดสินใจเข้าไว้ด้วยกันอย่างเป็นระบบ มีความเหมาะสมกับบริบทอุตสาหกรรมไฟฟ้าจรรยา ซึ่งสอดคล้องกับข้อเสนอในงานวิจัยด้าน Predictive Maintenance ที่ชี้ว่าการพยากรณ์เพียงอย่างเดียวไม่เพียงพอ หากไม่สามารถเชื่อมโยงผลลัพธ์ไปสู่

การตัดสินใจเชิงปฏิบัติได้อย่างเป็นระบบ [41]–[48] การอภิปรายนี้จึงชี้ให้เห็นว่าคุณค่าของ PdM ควรถูกประเมินจากบทบาทในการสนับสนุนการตัดสินใจ มากกว่าผลลัพธ์เชิงเทคนิคของแบบจำลองเพียงอย่างเดียว [26]–[29]

ในมิติของความฉลาดของระบบ การบูรณาการ Explainable Artificial Intelligence (XAI) ช่วยลดข้อจำกัดของระบบ PdM แบบกล่องดำ และเพิ่มความสามารถของผู้ใช้งานในการทำความเข้าใจเหตุผลของผลการพยากรณ์ ซึ่งเป็นปัจจัยสำคัญต่อความไว้วางใจและการยอมรับระบบในภาคอุตสาหกรรม [53]–[56] ประเด็นนี้สอดคล้องกับแนวคิด Human-centric AI และ Industry 5.0 ที่เน้นการทำงานร่วมกันระหว่างมนุษย์กับระบบอัจฉริยะ [49]–[52]

สำหรับคุณภาพการตัดสินใจ การนำ Multi-Criteria Decision Making (MCDM) มาใช้ช่วยจัดโครงสร้างการตัดสินใจด้านซ่อมบำรุงให้สามารถพิจารณาปัจจัยหลายมิติร่วมกันอย่างเป็นเหตุเป็นผล ซึ่งช่วยลดการพึ่งพาประสบการณ์ส่วนบุคคลและเพิ่มความสม่ำเสมอของการตัดสินใจในบริบทอุตสาหกรรม [26]–[35] เมื่อพิจารณาเชิงเปรียบเทียบ ระบบ PdM ที่ขาดทั้ง XAI และ MCDM แม้ให้ผลการพยากรณ์ได้ แต่ยังไม่สามารถทำหน้าที่เป็นระบบสนับสนุนการตัดสินใจได้อย่างแท้จริง

ในมิติของการนำไปใช้งาน การออกแบบแดชบอร์ดแบบผู้ใช้เป็นศูนย์กลางมีบทบาทสำคัญในการแปลงผลการพยากรณ์และข้อมูล RUL ให้เป็นข้อมูลเชิงการตัดสินใจที่สามารถนำไปใช้ได้จริง งานวิจัยด้านการนำ PdM ไปใช้ในภาคอุตสาหกรรมชี้ว่าการสื่อสารข้อมูลที่เหมาะสมช่วยเพิ่มการรับรู้สถานการณ์และคุณภาพการตัดสินใจของผู้ใช้งาน [57]–[61]

การอภิปรายนี้ชี้ให้เห็นว่างานวิจัยมีคุณค่าในฐานะกรอบแนวคิดที่ยกระดับ Predictive Maintenance จากการวิเคราะห์เชิงเทคนิคไปสู่ระบบสนับสนุนการตัดสินใจที่โปร่งใส เชื่อถือได้ และสอดคล้องกับการทำงานของมนุษย์ในอุตสาหกรรมเฉพาะทางผ่านการบูรณาการ PdM, XAI, MCDM และ Dashboard อย่างเป็นระบบ [41]–[61]

แม้งานวิจัยนี้จะแสดงให้เห็นถึงความเหมาะสมของกรอบแนวคิด XAI–PdM DSS อย่างชัดเจน แต่ยังมีข้อจำกัดบางประการที่ควรพิจารณา ประการแรก การประเมินกรอบแนวคิดอาศัยความคิดเห็นของผู้เชี่ยวชาญเป็นหลัก และยังไม่ได้ทดสอบกับข้อมูลเซนเซอร์จากสภาพแวดล้อมการผลิตจริง ประการที่สอง งานวิจัยยังไม่ได้เปรียบเทียบประสิทธิภาพของเทคนิค XAI หลายรูปแบบในเชิงทดลอง ซึ่งอาจส่งผลต่อระดับความเข้าใจและความไว้วางใจของผู้ใช้งาน ข้อจำกัดเหล่านี้เปิดโอกาสให้มีการศึกษาต่อยอดในอนาคตเพื่อยืนยันศักยภาพของกรอบแนวคิดในบริบทการใช้งานจริง

## 1.8. สรุปผลการวิจัย

### 1.8.1 สรุปผล

งานวิจัยนี้นำเสนอการพัฒนาระบบสนับสนุนการตัดสินใจซ่อมบำรุงเครื่องจักรเชิงพยากรณ์ที่อธิบายได้ด้วยปัญญาประดิษฐ์ (XAI–PdM DSS) สำหรับบริบทอุตสาหกรรมไฟฟ้าจราจร ซึ่งเป็นอุตสาหกรรมเฉพาะทางที่ต้องการความต่อเนื่องของการผลิตและความน่าเชื่อถือของเครื่องจักรในระดับสูง กรอบแนวคิดที่พัฒนาขึ้นได้บูรณาการการซ่อมบำรุงเชิงพยากรณ์ ปัญญาประดิษฐ์แบบอธิบายได้ การตัดสินใจเชิงหลายเกณฑ์ และการนำเสนอข้อมูลผ่านแดชบอร์ดแบบผู้ใช้เป็นศูนย์กลางเข้าไว้ด้วยกันอย่างเป็นระบบ

ผลการศึกษาแสดงให้เห็นว่าการพัฒนาระบบที่เชื่อมโยงผลการวิเคราะห์ของปัญญาประดิษฐ์เข้ากับกระบวนการตัดสินใจของผู้ใช้งานสามารถเพิ่มความโปร่งใส ความไว้วางใจ และศักยภาพในการนำระบบไปใช้งานจริงในภาคอุตสาหกรรมได้อย่างมี

นัยสำคัญ งานวิจัยนี้จึงช่วยขยายขอบเขตของงานด้าน Predictive Maintenance จากการมุ่งเน้นการพยากรณ์เชิงเทคนิคไปสู่ การสนับสนุนการตัดสินใจเชิงระบบที่คำนึงถึงมนุษย์เป็นศูนย์กลาง

ในเชิงวิชาการ งานวิจัยนี้มีส่วนสนับสนุนองค์ความรู้ด้านระบบสนับสนุนการตัดสินใจและ Explainable Artificial Intelligence โดยเสนอกรอบแนวคิดเชิงบูรณาการที่สามารถใช้เป็นฐานในการพัฒนาระบบซ่อมบำรุงอัจฉริยะในบริบท อุตสาหกรรมเฉพาะทาง ขณะที่ในเชิงปฏิบัติ กรอบแนวคิด XAI-PdM DSS สามารถใช้เป็นแนวทางในการออกแบบระบบซ่อม บำรุงที่โปร่งใส เชื่อถือได้ และสนับสนุนคุณภาพการตัดสินใจของผู้ปฏิบัติงานในอุตสาหกรรมไฟฟ้าจราจรได้อย่างเหมาะสม

#### 1.8.2 การพัฒนาระบบในอนาคต

แม้ว่างานวิจัยนี้จะแสดงให้เห็นถึงศักยภาพของกรอบแนวคิด XAI-PdM DSS อย่างชัดเจน แต่ยังมีแนวทางการศึกษา ต่อยอดที่สามารถพัฒนาเพิ่มเติมได้ในอนาคต ประการแรก งานวิจัยในอนาคตควรมุ่งเน้นการนำกรอบแนวคิดไปทดลองใช้กับ ข้อมูลจากสภาพแวดล้อมการผลิตจริง โดยเฉพาะข้อมูลเซนเซอร์จากเครื่องจักรในสายการผลิต เพื่อประเมินความสามารถของ ระบบในการรองรับข้อมูลแบบเรียลไทม์ ความทนทานของแบบจำลอง และผลกระทบเชิงปฏิบัติต่อการตัดสินใจด้านการซ่อม บำรุงในระยะยาว

ประการที่สอง สามารถขยายการศึกษาไปสู่การเปรียบเทียบประสิทธิภาพและความเหมาะสมของเทคนิค Explainable Artificial Intelligence ที่หลากหลาย เช่น SHAP และ LIME เพื่อวิเคราะห์ความแตกต่างด้านความเข้าใจของผู้ใช้งาน ความ สอดคล้องของคำอธิบาย และผลต่อความไว้วางใจในการตัดสินใจ ทั้งนี้ การเปรียบเทียบดังกล่าวจะช่วยสนับสนุนการเลือกใช้ เทคนิค XAI ที่เหมาะสมกับบริบทการซ่อมบำรุงเครื่องจักรในอุตสาหกรรมเฉพาะทาง

ประการที่สาม งานวิจัยในอนาคตอาจพิจารณาการบูรณาการกรอบแนวคิด XAI-PdM DSS เข้ากับระบบดิจิทัลอื่นในระดับ องค์กร เช่น ระบบ Digital Twin หรือระบบ Enterprise Resource Planning (ERP) เพื่อสนับสนุนการตัดสินใจด้านการซ่อม บำรุงในมุมมองเชิงระบบมากยิ่งขึ้น การเชื่อมโยงดังกล่าวจะช่วยให้ผลการพยากรณ์และข้อมูลเชิงการตัดสินใจสามารถถูก นำไปใช้ร่วมกับการวางแผนการผลิตและการจัดการทรัพยากรได้อย่างมีประสิทธิภาพ

สุดท้าย งานวิจัยในอนาคตสามารถขยายกรอบแนวคิดไปสู่บริบทอุตสาหกรรมอื่นที่มีลักษณะการทำงานใกล้เคียงกัน เพื่อ ประเมินความทั่วไปของกรอบแนวคิด และยืนยันศักยภาพของ XAI-PdM DSS ในการเป็นแนวทางการพัฒนาระบบสนับสนุน การตัดสินใจซ่อมบำรุงเชิงพยากรณ์ในภาคอุตสาหกรรมที่หลากหลาย

#### 1.9. รายการอ้างอิง (Reference)

[1] H. Li, D. Parikh, Q. He, B. Qian, Z. Li, D. Fang, and A. Hampapur, "Improving rail network velocity: A machine learning approach to predictive maintenance," *Transportation Research Part C: Emerging Technologies*, vol. 45, pp. 17–26, 2014, doi: 10.1016/j.trc.2014.04.013.

[2] C. Chen, H. Fu, Y. Zheng, F. Tao, and Y. Liu, "The advance of digital twin for predictive maintenance: The role and function of machine learning," *Journal of Manufacturing Systems*, vol. 71, pp. 581–594, Oct. 2023, doi:10.1016/j.jmsy.2023.10.010.

[3] J. Dalzochio, R. Kunst, E. Pignaton, A. Binotto, S. Sanyal, J. Favilla, and J. Barbosa, "Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges," *Computers in Industry*, vol. 123, Art. no. 103298, 2020, doi: 10.1016/j.compind.2020.103298

- [4] J. J. Montero Jimenez, S. Schwartz, R. Vingerhoeds, B. Grabot, and M. Salaün, “Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics,” *Journal of Manufacturing Systems*, vol. 56, pp. 539–557, 2020, doi: 10.1016/j.jmsy.2020.07.008.
- [5] T. Zonta, C. A. da Costa, F. A. Zeiser, G. de O. Ramos, R. Kunst, and R. da R. Righi, “A predictive maintenance model for optimizing production schedule using deep neural networks,” *Journal of Manufacturing Systems*, vol. 62, pp. 450–462, 2022, doi: 10.1016/j.jmsy.2021.12.013.
- [6] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. da P. Francisco, J. P. Basto, and S. G. S. Alcalá, “A systematic literature review of machine learning methods applied to predictive maintenance,” *Computers & Industrial Engineering*, vol. 137, Art. no. 106024, 2019, doi: 10.1016/j.cie.2019.106024.
- [7] T. Zonta, C. A. da Costa, R. da R. Righi, M. J. de Lima, E. S. da Trindade, and G. P. Li, “Predictive maintenance in the Industry 4.0: A systematic literature review,” *Computers & Industrial Engineering*, vol. 150, Art. no. 106889, 2020, doi: 10.1016/j.cie.2020.106889.
- [8] E. Florian, F. Sgarbossa, and I. Zennaro, “Machine learning-based predictive maintenance: A cost-oriented model for implementation,” *International Journal of Production Economics*, vol. 236, Art. no. 108114, 2021, doi: 10.1016/j.ijpe.2021.108114.
- [9] R. van Dinter, B. Tekinerdogan, and C. Catal, “Predictive maintenance using digital twins: A systematic literature review,” *Information and Software Technology*, vol. 151, Art. no. 107008, 2022, doi: 10.1016/j.infsof.2022.107008.
- [10] N. Sakib and T. Wuest, “Challenges and opportunities of condition-based predictive maintenance: A review,” *Procedia CIRP*, vol. 78, pp. 267–272, 2018, doi: 10.1016/j.procir.2018.08.318.
- [11] Z. M. Çınar, A. A. Nuhu, Q. Zeeshan, O. Korhan, M. Asmael, and B. Safaei, “Machine learning in predictive maintenance towards sustainable smart manufacturing in Industry 4.0,” *Sustainability*, vol. 12, no. 19, Art. no. 8211, 2020, doi: 10.3390/su12198211.
- [12] V. J. Jimenez, N. Bouhmala, and A. H. Gausdal, “Developing a predictive maintenance model for vessel machinery,” *Journal of Ocean Engineering and Science*, vol. 5, no. 4, pp. 358–386, 2020, doi: 10.1016/j.joes.2020.03.003.
- [13] P. Stodola and J. Stodola, “Model of predictive maintenance of machines and equipment,” *Applied Sciences*, vol. 10, no. 1, Art. no. 213, 2020, doi: 10.3390/app10010213.
- [14] M. Achouch *et al.*, “On predictive maintenance in Industry 4.0: Overview, models, and challenges,” *Applied Sciences*, vol. 12, no. 16, Art. no. 8081, 2022, doi: 10.3390/app12168081.

- [15] G. M. Sang, L. Xu, and P. de Vrieze, “A predictive maintenance model for flexible manufacturing in the context of Industry 4.0,” *Frontiers in Big Data*, vol. 4, Art. no. 663466, 2021, doi: 10.3389/fdata.2021.663466.
- [16] S. Kaparthy and D. Bumblauskas, “Designing predictive maintenance systems using decision tree-based machine learning techniques,” *International Journal of Quality & Reliability Management*, vol. 37, no. 4, pp. 659–686, 2020, doi: 10.1108/IJQRM-04-2019-0131.
- [17] S. Vollert, M. Atzmueller, and A. Theissler, “Interpretable machine learning: A brief survey from the predictive maintenance perspective,” in *Proc. IEEE Int. Conf. Emerging Technologies and Factory Automation (ETFA)*, 2021, pp. 1–8, doi: 10.1109/ETFA45728.2021.9613467.
- [18] W. Tiddens, J. Braaksma, and T. Tinga, “Exploring predictive maintenance applications in industry,” *Journal of Quality in Maintenance Engineering*, vol. 28, no. 1, pp. 68–85, 2022, doi: 10.1108/JQME-05-2020-0029.
- [19] M. Paolanti, L. Romeo, A. Felicetti, A. Mancini, E. Frontoni, and J. Loncarski, “Machine learning approach for predictive maintenance in Industry 4.0,” in *Proc. 14th IEEE/ASME Int. Conf. Mechatronic and Embedded Systems and Applications (MESA)*, Oulu, Finland, 2018, pp. 1–6, doi: 10.1109/MESA.2018.8439071.
- [20] G. A. Susto, A. Schirru, S. Pampuri, S. McLoone, and A. Beghi, “Machine learning for predictive maintenance: A multiple classifier approach,” *IEEE Transactions on Industrial Informatics*, vol. 11, no. 3, pp. 812–820, Jun. 2015, doi: 10.1109/TII.2014.2349359.
- [21] A. Kanawaday and A. Sane, “Machine learning for predictive maintenance of industrial machines using IoT sensor data,” in *Proc. Int. Conf. Data Management, Analytics and Innovation (ICDMAI)*, Pune, India, 2017, pp. 87–90, doi: 10.1109/ICDMAI.2017.8073501.
- [22] F. Arena, M. Collotta, L. Luca, M. Ruggieri, and F. G. Termine, “Predictive maintenance in the automotive sector: A literature review,” *Math. Comput. Appl.*, vol. 27, no. 2, Art. no. 2, 2022, doi: 10.3390/mca27010002.
- [23] B. Cline, R. S. Niculescu, D. Huffman, and B. Deckel, “Predictive maintenance applications for machine learning,” in *Proc. IEEE Int. Conf. Big Data*, Boston, MA, USA, 2017, pp. 4531–4536, doi:10.1109/BigData.2017.8258485.
- [24] K. A. Kaiser and N. Z. Gebraeel, “Predictive maintenance management using sensor-based degradation models,” *IEEE Trans. Syst., Man, Cybern. A*, vol. 39, no. 4, pp. 840–855, Jul. 2009, doi: 10.1109/TSMCA.2009.2016429.
- [25] N. Hivarekar, S. Jadav, V. Kuppusamy, P. Singh, and C. Gupta, “Preventive and predictive maintenance modeling,” in *Proc. IEEE Conf.*, 2016, pp. 1–6.

- [26] J. Gidiagba, L. Tartibu, and M. Okwu, “Sustainable supplier selection in the oil and gas industry: An integrated multi-criteria decision making approach,” *Procedia Computer Science*, vol. 217, pp. 1243–1255, 2023, doi: 10.1016/j.procs.2022.12.323.
- [27] Z. Wei, S. Zhu, X. Dai, X. Wang, L. M. Yapanto, and I. R. Raupov, “Multi-criteria decision making approaches to select appropriate enhanced oil recovery techniques in petroleum industries,” *Energy Reports*, vol. 7, pp. 2751–2758, 2021, doi: 10.1016/j.egy.2021.05.002.
- [28] L. Maretto, M. Faccio, and D. Battini, “A multi-criteria decision-making model based on fuzzy logic and AHP for the selection of digital technologies,” *IFAC PapersOnLine*, vol. 55, no. 2, pp. 319–324, 2022, doi: 10.1016/j.ifacol.2022.04.213.
- [29] S. Chakraborty, R. D. Raut, T. M. Rofin, and S. Chakraborty, “A comprehensive and systematic review of multi-criteria decision-making methods and applications,” *Healthcare Analytics*, vol. 4, Art. no. 100232, 2023, doi: 10.1016/j.health.2023.100232.
- [30] S. Ghosh, C. Bhowmik, S. Sinha, R. D. Raut, M. C. Mandal, and A. Ray, “An integrated multi-criteria decision-making and multivariate analysis towards sustainable procurement with application in automotive industry,” *Supply Chain Analytics*, vol. 3, Art. no. 100033, 2023, doi: 10.1016/j.sca.2023.100033.
- [31] S. Sriram, M. Ramachandran, S. Chinnasamy, and G. Mathivanan, “A review on multi-criteria decision-making and its application,” *REST Journal on Emerging Trends in Modelling and Manufacturing*, vol. 7, no. 4, pp. 101–107, 2021.
- [32] H.-Q. Nguyen, V.-T. Nguyen, D.-P. Phan, Q.-H. Tran, and N.-P. Vu, “Multi-criteria decision making in the PMEDM process by using MARCOS, TOPSIS, and MAIRCA methods,” *Applied Sciences*, vol. 12, no. 8, Art. no. 3720, 2022, doi: 10.3390/app12083720.
- [33] Y. S. Ozdemir, “A spherical fuzzy multi-criteria decision-making model for Industry 4.0 performance measurement,” *Axioms*, vol. 11, no. 7, Art. no. 325, 2022, doi: 10.3390/axioms11070325.
- [34] A. Kumari, P. Garg, S. Panti, M. Rani, and A. Kumar, “Multi-criteria decision-making techniques for complex decision making problems,” *Mathematics in Engineering, Science and Aerospace*, vol. 13, no. 3, pp. 791–803, 2022.
- [35] M. I. Youssef and B. Webster, “A multi-criteria decision making approach to the new product development process in industry,” *Reports in Mechanical Engineering*, vol. 3, no. 1, pp. 83–93, 2022, doi: 10.31181/rme2001260122y.

- [36] A. Pérez Gómez, “Rule-based expert systems for automated legal reasoning and contract analysis: A case study in knowledge representation,” *Advances in Computational Systems, Algorithms, and Emerging Technologies*, vol. 7, pp. 19–34, 2022.
- [37] J. I. Guerrero, G. Miro-Amarante, and A. Martín, “Decision support system in health care building design based on case-based reasoning and reinforcement learning,” *Expert Systems with Applications*, vol. 187, Art. no. 116037, 2022, doi: 10.1016/j.eswa.2021.116037.
- [38] R. Turgunbaev, “Rule-based reasoning and its role in intelligent decision making,” *Technical Science Integrated Research*, vol. 1, no. 2, pp. 10–14, Aug. 2025.
- [39] R. Das *et al.*, “Case-based reasoning for natural language queries over knowledge bases,” *arXiv preprint arXiv:2104.08762*, 2021.
- [40] C. Di Florio, H. Dong, and A. Rotolo, “Rule-based classifier models,” *arXiv preprint arXiv:2505.00474*, 2025.
- [41] F. B. N. Tonle *et al.*, “A road map for developing novel decision support system (DSS) for disseminating integrated pest management (IPM) technologies,” *Computers and Electronics in Agriculture*, vol. 217, Art. no. 108526, 2024, doi: 10.1016/j.compag.2023.108526.
- [42] E. Mahmoodi, M. Fathi, M. Tavana, M. Ghobakhloo, and A. H. C. Ng, “Data-driven simulation-based decision support system for resource allocation in Industry 4.0 and smart manufacturing,” *Journal of Manufacturing Systems*, vol. 72, pp. 287–307, 2024, doi: 10.1016/j.jmsy.2023.11.019.
- [43] I. Ara, L. Turner, M. T. Harrison, M. Monjardino, P. deVoil, and D. Rodriguez, “Application, adoption and opportunities for improving decision support systems in irrigated agriculture: A review,” *Agricultural Water Management*, vol. 257, Art. no. 107161, 2021, doi: 10.1016/j.agwat.2021.107161.
- [44] G. Talari, E. Cummins, C. McNamara, and J. O’Brien, “State of the art review of Big Data and web-based decision support systems (DSS) for food safety risk assessment with respect to climate change,” *Trends in Food Science & Technology*, vol. 126, pp. 192–204, 2022, doi: 10.1016/j.tifs.2021.08.032.
- [45] H. Soltan and S. Mostafa, “Lean and agile performance framework for manufacturing enterprises,” *Procedia Manufacturing*, vol. 2, pp. 476–484, 2015, doi: 10.1016/j.promfg.2015.07.082.
- [46] B. Unhelkar, S. Joshi, M. Sharma, S. Prakash, A. K. Mani, and M. Prasad, “Enhancing supply chain performance using RFID technology and decision support systems in Industry 4.0: A systematic literature review,” *International Journal of Information Management Data Insights*, vol. 2, Art. no. 100084, 2022, doi: 10.1016/j.ijime.2022.100084.

- [47] M. Soori, F. K. G. Jough, R. Dastres, and B. Arezoo, “AI-based decision support systems in Industry 4.0: A review,” *Journal of Economy and Technology*, 2024, doi: 10.1016/j.ject.2024.08.005.
- [48] A. B. Rashid and M. A. K. Kausik, “AI revolutionizing industries worldwide: A comprehensive overview of its diverse applications,” *Hybrid Advances*, vol. 7, Art. no. 100277, 2024, doi: 10.1016/j.hybadv.2024.100277.
- [49] X. Sun and Y. Song, “Unlocking the synergy: Increasing productivity through human–AI collaboration in the Industry 5.0 era,” *Computers & Industrial Engineering*, vol. 200, Art. no. 110657, 2025, doi:10.1016/j.cie.2024.110657.
- [50] Z. Huang *et al.*, “Hybrid learning-based digital twin for manufacturing process: Modeling framework and implementation,” *Robotics and Computer-Integrated Manufacturing*, vol. 82, Art. no. 102545, 2023, doi: 10.1016/j.rcim.2023.102545.
- [51] M. Golovianko, V. Terziyan, V. Branytskyi, and D. Malyk, “Industry 4.0 vs. Industry 5.0: Co-existence, transition, or a hybrid,” *Procedia Computer Science*, vol. 217, pp. 102–113, 2023, doi: 10.1016/j.procs.2022.12.206.
- [52] A. Tóth, L. Nagy, R. Kennedy, B. Bohuš, J. Abonyi, and T. Ruppert, “The human-centric Industry 5.0 collaboration architecture,” *MethodsX*, vol. 11, Art. no. 102260, 2023, doi:10.1016/j.mex.2023.102260.
- [53] L. Lin, C. Walker, and V. Agarwal, “Explainable machine-learning tools for predictive maintenance of circulating water systems in nuclear power plants,” *Nuclear Engineering and Technology*, vol. 57, Art. no. 103588, 2025, doi: 10.1016/j.net.2025.103588.
- [54] A. K. M. Nor, S. R. Pedapati, and M. Muhammad, “Explainable AI (XAI) for PHM of industrial asset: A state-of-the-art, PRISMA-compliant systematic review,” 2021.
- [55] S. Pashami *et al.*, “Explainable Predictive Maintenance,” *arXiv preprint arXiv:2306.05120*, 2023.
- [56] R. K. Kundu and K. A. Hoque, “Explainable predictive maintenance is not enough: Quantifying trust in remaining useful life estimation,” in *Proc. Annual Conf. Prognostics and Health Management Society*, 2023, pp.
- [57] O. Serradilla Casado, *Design and validation of a methodology to implement data-driven predictive maintenance in industrial environments*, Ph.D. dissertation, Dept. Electron. Comput. Sci., Mondragon Unibertsitatea, Mondragon, Spain, 2021.
- [58] A. Salvi *et al.*, “Development of a Real-Time Dashboard for Overdose Touchpoints: User-Centered Design Approach,” *JMIR Human Factors*, vol. 11, e57239, 2024.

[59] B. Ansari, *Taking a User-Centered Design Approach to Develop a Data Dashboard for New York State Department of Health and Implications for Improving the Usability of Public Data Dashboards*, Ph.D. dissertation, Univ. at Albany, State Univ. of New York, Albany, NY, USA, 2022

[60] A. W. Bennett and S. Müller Loose, “User-centered development of an online dashboard tool for economic sustainability for small and medium enterprises,” *Sustainability*, vol. 16, no. 2, Art. no. 557, 2024, doi: 10.3390/su16020557.

[61] P. Stahmann, L. S. Gravemeier, A. Dittmer, C. Janiesch, and O. Thomas, “User-centered visual design of alarms in manufacturing dashboards: Insights on comprehensibility and preferences,” in *Proc. Int. Conf. Information Systems (ICIS)*, Hyderabad, India, 2023.

