



รายงานวิจัยฉบับสมบูรณ์

การประยุกต์ใช้งานความเป็นจริงเสริมในงานด้านอุตสาหกรรมอัตโนมัติ
(ระยะที่ 2)

Applied Augmented Reality for Industrial Automation (Phase 2)

นายประจักษ์ จิตเงินมะดัน หัวหน้าโครงการวิจัย

โครงการวิจัยประเภทเงินรายได้

คณะวิทยาการสารสนเทศ

ประจำปีงบประมาณ พ.ศ. 2567

มหาวิทยาลัยบูรพา

สัญญาเลขที่ 014/2567

รายงานวิจัยฉบับสมบูรณ์

การประยุกต์ใช้งานความเป็นจริงเสริมในงานด้านอุตสาหกรรมอัตโนมัติ
(ระยะที่ 2)

นายประจักษ์ จิตเงินมะดัน หัวหน้าโครงการวิจัย

คณะวิทยาการสารสนเทศ

2568

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนสนับสนุนการวิจัยจากเงินรายได้ คณะวิทยาการสารสนเทศ ประจำปีงบประมาณ พ.ศ. 2567 เลขที่สัญญา 014/2567

คณะผู้วิจัยขอขอบคุณคณะวิทยาการสารสนเทศ และห้องปฏิบัติการวิจัยสื่อดิจิทัลและปฏิสัมพันธ์ (Digital Media and Interaction Laboratory) มหาวิทยาลัยบูรพา ที่เอื้อเฟื้องบประมาณในการดำเนินการ และสถานที่ในการวางแผน ปฏิบัติ และทดสอบชิ้นงานใหม่ที่มีความสมบูรณ์ รวมถึงการให้บริการด้านสาธารณูปโภคต่าง ๆ ด้วย

และในท้ายที่สุด คณะผู้วิจัยขอขอบคุณผู้ร่วมออกแบบการทดลอง และทีมงานสนับสนุนทุกคนที่ทุ่มเท แรงกายแรงใจในการดำเนินการงานวิจัยนี้สำเร็จลุล่วงไปได้ด้วยดี

มิถุนายน 2568

บทคัดย่อ

ในอุตสาหกรรมและเทคโนโลยีการผลิตสมัยใหม่ การบำรุงรักษาที่รวดเร็วและแม่นยำเป็นแนวคิดที่สำคัญอย่างยิ่ง การศึกษานี้ได้นำเสนอระบบผู้เชี่ยวชาญระยะไกลที่ขับเคลื่อนด้วย AI ซึ่งเปลี่ยนแปลงการบำรุงรักษาในอุตสาหกรรมอัตโนมัติผ่านการบูรณาการเทคโนโลยีปัญญาประดิษฐ์ (AI) ความเป็นจริงผสม (MR) และการประมวลผลภาษาธรรมชาติ (NLP) เข้าด้วยกัน โดยมีการทดสอบการนำไปใช้งานด้วยโมเดล YOLOv8s บนอุปกรณ์แว่น Microsoft HoloLens 2 สำหรับการรู้จำวัตถุแบบเรียลไทม์และการตรวจจับสถานะไฟแสดง LED บนอุปกรณ์ PLCnext ช่วยให้ผู้ใช้ปฏิบัติงานซ่อมบำรุงได้รับข้อมูลการตรวจสอบและวินิจฉัยในทันที การตรวจสอบความถูกต้องด้วยการทดลองและการทดสอบภาคสนามแสดงให้เห็นถึงประสิทธิภาพของระบบที่มีประสิทธิภาพด้วยค่า mAP50 ที่ 0.993 และ mAP50-95 ที่ 0.844 และระบบสามารถสร้างคำแนะนำในการซ่อมบำรุงเครื่องจักรโดยใช้โมเดล NLP ที่ได้รับการพัฒนาเสริมข้อมูลเฉพาะทาง ซึ่งสามารถให้คำแนะนำเฉพาะทางแบบอัตโนมัติตามปัญหาที่ระบุ โดยแนวทางในการพัฒนานวัตกรรมนี้ สร้างกระบวนการทัศน์ใหม่สำหรับการซ่อมบำรุงในอุตสาหกรรมอัตโนมัติที่ช่วยลดเวลาหยุดทำงานของเครื่องจักรอย่างมีนัยสำคัญ เพิ่มประสิทธิภาพการดำเนินงาน และลดต้นทุนการบำรุงรักษาในภาพรวม

Abstract

In modern industries and manufacturing techniques, quick and precise maintenance is a vital concept. This study introduces an AI-driven Remote Expert System that transforms industrial maintenance through the integration of artificial intelligence (AI), mixed reality (MR), and natural language processing (NLP) technologies. Our implementation utilizes YOLOv8s on Microsoft HoloLens 2 for real-time object recognition and LED status indicator detection on PLCnext controllers, enabling on-site operators to receive immediate diagnostic information. Experimental validation and field trials demonstrate robust system performance with an mAP50 of 0.993 and mAP50-95 of 0.844, while optimizing CPU utilization and battery consumption during video streaming operations. The system automatically generates NLP-based maintenance recommendations corresponding to identified issues. This innovative approach establishes a new paradigm for industrial maintenance that significantly reduces equipment downtime, enhances operational efficiency, and minimizes maintenance costs.

สารบัญ

1	บทนำ	1
1.1	ที่มาและความสำคัญ.....	1
1.2	วัตถุประสงค์.....	2
1.3	ขอบเขตของการวิจัย.....	2
1.4	เครื่องมือที่ใช้การพัฒนา.....	3
1.4.1	อุปกรณ์ด้านฮาร์ดแวร์ (Hardware).....	3
1.4.2	ซอฟต์แวร์ที่ใช้ในการพัฒนา (Software).....	3
1.5	วิธีการดำเนินการวิจัย (Research methodology).....	3
1.5.1	ศึกษาปัญหาและงานวิจัยที่เกี่ยวข้อง.....	3
1.5.2	ศึกษาและสร้างตัวต้นแบบโมเดลสำหรับการรู้จำความผิดปกติของเครื่องจักรด้วยวิธีการ Object Detection.....	4
1.5.3	เขียนโปรแกรมเพื่อทดสอบการทำงานของ AR และทำการเก็บข้อมูลการใช้งาน.....	4
1.5.4	วิเคราะห์ผลจากข้อมูลที่รวบรวมไว้ ทำการปรับปรุงกระบวนการตามความเหมาะสม.....	4
1.5.5	เขียนบทความวิจัยและตีพิมพ์บทความวิจัย.....	4
1.4.6	สรุปผลและทำรายงานฉบับสมบูรณ์.....	4
1.6	ประโยชน์ที่คาดว่าจะได้รับ.....	4
2	ทฤษฎีและโครงการที่เกี่ยวข้อง.....	5
2.1	ทฤษฎีที่เกี่ยวข้อง.....	5
2.1.1	ทฤษฎีการมองเห็นด้วยคอมพิวเตอร์.....	5
2.1.2	ปัญญาประดิษฐ์.....	5
2.1.3	การตรวจจับวัตถุ.....	5
2.1.4	ระบบเสริมความเป็นจริงหรือเทคโนโลยีความเป็นจริงเสริม (Augmented Reality).....	6

2.1.5	HoloLens.....	6
2.1.6	โปรแกรมยูนิตี้ (Unity).....	7
2.1.7	โปรแกรมอนาคอนด้า (Anaconda).....	8
2.1.8	Pretrained Model	8
2.1.9	YOLO.....	9
2.2	งานที่เกี่ยวข้อง (Related Works)	9
2.2.1	การบูรณาการ YOLOv8s และ HoloLens 2 สำหรับการประยุกต์ใช้ในอุตสาหกรรม.....	9
2.2.2	เทคนิคการเพิ่มข้อมูลสำหรับชุดข้อมูลอุตสาหกรรมที่มีข้อจำกัด.....	10
2.2.3	การพัฒนาของโมเดล YOLO และการประยุกต์ใช้ในอุตสาหกรรม.....	10
3	วิธีการดำเนินงานโครงการ	12
3.1	ภาพรวมของการดำเนินงาน	12
3.1.1	ส่วนของการรับข้อมูล (Data Acquisition Phase).....	12
3.1.2	ส่วนของการประมวลผล (Processing Phase).....	13
3.2	การเตรียมข้อมูล	14
3.2.1	การบันทึกวิดีโอ (Video Capture).....	14
3.2.2	การแยกเฟรม (Frame Extraction)	14
3.2.3	การใส่คำอธิบายข้อมูล (Data Annotation).....	15
3.2.4	การเพิ่มข้อมูล (Data Augmentation)	15
3.3	การพัฒนาโมเดล.....	15
3.3.1	การนำ YOLOv8s มาใช้งาน (YOLOv8s Implementation).....	15
3.3.2	กระบวนการฝึกโมเดล (Model Training Process).....	16
3.3.3	คลาสที่ตรวจจับและพารามิเตอร์ (Detection Classes and Parameters).....	16
3.4	การบูรณาการการประมวลผลภาษาธรรมชาติ (Natural Language Processing Integration).....	17

3.5	การวิเคราะห์และออกแบบระบบ	18
3.5.1	การออกแบบ Use Case Diagram.....	18
3.5.2	ขั้นตอนการทำงานของระบบ Remote Expert System	19
4	ผลการดำเนินการ	21
4.1	ประสิทธิภาพของโมเดล (Model Performance Metrics).....	21
4.2	ความแม่นยำในการตรวจจับแบบเรียลไทม์ (การทดสอบภาคสนาม)	23
4.2.1	ประสิทธิภาพการตรวจจับที่ 2 ระยะ.....	23
4.2.2	ผลกระทบของความล่าช้าของระบบต่อประสิทธิภาพการตรวจจับ	24
4.3	การวิเคราะห์ประสิทธิภาพของฮาร์ดแวร์.....	24
4.3.1	การใช้แบตเตอรี่ของ HoloLens 2	24
4.3.2	เมตริกการใช้งาน CPU.....	25
4.3.3	เมตริกการใช้หน่วยความจำ	25
4.4	ผลลัพธ์การทำงานของระบบ AI-driven Remote Expert System	26
5	สรุปผล.....	35
5.1	สรุปผลการดำเนินงาน.....	35
5.2	ข้อค้นพบสำคัญ	35
5.3	ปัญหา อุปสรรค และข้อจำกัด	36
5.4	ข้อเสนอแนะ	37
5.5	แนวทางในการพัฒนาในอนาคต.....	37
6	บรรณานุกรม	39
References	39
7	ภาคผนวก.....	40
7.1	ตัวอย่างภาพจากชุดข้อมูล.....	40

7.1.1	ชุดข้อมูลระยะใกล้	40
7.1.2	ชุดข้อมูลระยะไกล	42
7.2	การรับรองจริยธรรมวิจัย	45
7.3	ผลงานวิจัยที่อยู่ระหว่างการตีพิมพ์และเผยแพร่	46
8	ประวัตินักวิจัยและคณะ	58
8.1	หัวหน้าโครงการวิจัย	58

สารบัญตาราง

ตารางที่ 1 ประสิทธิภาพของโมเดล YOLOv8s แยกตามคลาส.....	21
ตารางที่ 2 ความแม่นยำในการจำแนกของโมเดล YOLOv8s แยกตามคลาส.....	21
ตารางที่ 3 Confusion Matrix ในการตรวจจับระยะใกล้.....	23
ตารางที่ 4 Confusion Matrix ในการตรวจจับระยะไกล.....	24

สารบัญภาพ

ภาพที่ 1 ระบบเสริมความเป็นจริง (Augmented Reality)	6
ภาพที่ 2 Hololens	7
ภาพที่ 3 Unity	8
ภาพที่ 4 Anaconda	8
ภาพที่ 5 ภาพรวมสถาปัตยกรรมระบบผู้เชี่ยวชาญระยะไกลด้วย AI.....	12
ภาพที่ 6 ขั้นตอนการเตรียมข้อมูล.....	14
ภาพที่ 7 การออกแบบ Use Case Diagram	18
ภาพที่ 8 Flowchart การทำงานในภาพรวมของระบบ Remote Expert System	19
ภาพที่ 9 เส้นโค้ง Precision-Recall สำหรับทุกคลาส.....	22
ภาพที่ 10 การใช้งาน CPU ของ HoloLens 2 ในช่วงเวลา 5 นาที.....	25
ภาพที่ 11 การใช้งานหน่วยความจำของ HoloLens 2 ในช่วงเวลา 5 นาที.....	25
ภาพที่ 12 ภาพรวมการทดสอบระบบฯ.....	26
ภาพที่ 13 เมื่อระบบตรวจสอบเจอข้อผิดพลาด.....	28
ภาพที่ 14 ตัวอย่างแนวทางในการแก้ปัญหา	29
ภาพที่ 15 แสดงการตรวจไม่พบข้อผิดพลาด	30
ภาพที่ 16 ปุ่มสำหรับการเปิด (ก)/ปิด (ข) หน้าต่างสนทนาของแชทบอท.....	32
ภาพที่ 17 ภาพหน้าต่างสนทนากับแชทบอท.....	33
ภาพที่ 18 แสดงการตอบคำถามจากแชทบอท	34
ภาพที่ 19 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 39	40
ภาพที่ 20 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 40	41
ภาพที่ 21 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 9.....	42
ภาพที่ 22 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 10	43
ภาพที่ 23 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 11	44

คำอธิบายสัญลักษณ์และคำย่อ

คำศัพท์	คำอธิบาย
Augmented Reality (AR)	Augmented Reality (AR) คือ การผสมผสานข้อมูลเสมือนจริงเข้ากับโลกแห่งความเป็นจริง ทำให้ผู้ใช้งานสามารถมองเห็นวัตถุหรือข้อมูลเสมือนจริงปรากฏบนสภาพแวดล้อมจริงที่พวกเขาสัมผัสอยู่ ผ่านอุปกรณ์เช่น แว่นตา AR, สมาร์ทโฟน หรือแท็บเล็ต. ผู้ใช้งานสามารถรับประสบการณ์ที่เพิ่มเติมจากข้อมูลเสมือนจริงที่ซ้อนทับกับโลกจริง ทำให้สามารถทำงานหรือโต้ตอบกับสิ่งแวดล้อมได้อย่างมีประสิทธิภาพ AR ช่วยเพิ่มการรับรู้และการตอบสนองต่อสถานการณ์โดยการเสริมสิ่งที่เราเห็นด้วยข้อมูลกราฟิกหรือข้อความที่มีประโยชน์ เช่น การแสดงข้อมูลเทคนิคเกี่ยวกับเครื่องจักรที่ผู้ปฏิบัติงานกำลังมองเห็น หรือการแสดงทิศทางในการนำทางในสภาพแวดล้อมจริง
Virtual Reality (VR)	Virtual Reality (VR) คือ การสร้างระบบหรือสิ่งแวดล้อมจำลองในรูปแบบของภาพสามมิติ โดยผู้ใช้งานจะต้องใช้แว่นพิเศษที่เรียกว่า แว่น VR ในการรับรู้ความรู้สึกเสมือนจริงเมื่อใช้งานระบบ โดยจะมีการจำลองของจริงและ ผู้ใช้งานสามารถปฏิสัมพันธ์กับวัตถุหรือสิ่งแวดล้อมจำลองนั้นได้
HoloLens	HoloLens คือ อุปกรณ์ความเป็นจริงเสริม (Augmented Reality, AR) จาก Microsoft ที่สร้างประสบการณ์ที่ผสมผสานเอาโลกเสมือนจริงเข้ากับโลกจริงผ่านแว่นตาอัจฉริยะ. ผู้ใช้ HoloLens สามารถมองเห็นวัตถุหรือแอปพลิเคชันที่มีรูปแบบสามมิติซึ่งซ้อนทับกับสิ่งแวดล้อมจริงที่ตนอยู่ โดยไม่ต้องใช้อุปกรณ์เพิ่มเติมใด ๆ การออกแบบที่ผสมผสานนี้ช่วยให้ผู้ใช้สามารถโต้ตอบกับวัตถุเสมือนจริงโดยใช้การเคลื่อนไหวของมือและคำสั่งเสียงได้อย่างอิสระ ทำให้สามารถใช้งานได้หลากหลายตั้งแต่การออกแบบ, การศึกษา, การผลิตจนถึงการฝึกอบรม. HoloLens มอบประสบการณ์ที่ไม่เหมือนใครในการเชื่อมต่อข้อมูลดิจิทัลกับโลกจริง ซึ่งช่วยเพิ่มประสิทธิภาพในการทำงานและปรับปรุงการเรียนรู้ผ่านการโต้ตอบแบบเสริมภาพ

คำศัพท์	คำอธิบาย
Unity	Unity เป็นเอ็นจินพัฒนาเกมที่ทำให้ความสามารถในการสร้างประสบการณ์ความเป็นจริงเสริม (AR) ที่ได้ตอบโต้ด้วย Unity นักพัฒนาสามารถออกแบบวัตถุและสภาพแวดล้อมเสมือนที่ซ้อนทับอยู่บนโลกจริง อนุญาตให้ผู้ใช้มองเห็นและโต้ตอบกับเนื้อหาดิจิทัลผ่านอุปกรณ์ต่าง ๆ เช่น HoloLens และสมาร์ทโฟน Unity นำเสนอเครื่องมือที่มีประสิทธิภาพสำหรับการพัฒนา AR ทำให้เป็นเครื่องมือที่นิยมใช้ในหลาย ๆ อุตสาหกรรม
Artificial Intelligence (AI)	ปัญญาประดิษฐ์ (Artificial Intelligence, AI) เป็นสาขาของวิทยาการคอมพิวเตอร์ที่เน้นการพัฒนาเครื่องจักรและระบบที่สามารถจำลองความสามารถทางปัญญาของมนุษย์ได้ เช่น การเรียนรู้, การแก้ปัญหา, และการตัดสินใจ AI ทำงานโดยการวิเคราะห์ข้อมูลขนาดใหญ่และระบุรูปแบบที่ซับซ้อนเพื่อทำนายผลลัพธ์หรือตัดสินใจโดยอัตโนมัติ ปัญญาประดิษฐ์ถูกใช้งานอย่างแพร่หลายในหลาย ๆ อุตสาหกรรม รวมทั้งในการพัฒนาโซลูชันที่ช่วยให้ระบบสามารถปรับตัวและตอบสนองต่อเหตุการณ์แบบเรียลไทม์ได้ AI มีความสำคัญในการปรับปรุงกระบวนการ, ประหยัดเวลา, และเพิ่มประสิทธิภาพในหลากหลายสาขาวิชา
Machine Learning (ML)	Machine Learning (ML) เป็นสาขาย่อยของปัญญาประดิษฐ์ (AI) ที่ศึกษาการพัฒนาอัลกอริธึมที่ช่วยให้คอมพิวเตอร์มีความสามารถในการเรียนรู้จากข้อมูลและปรับปรุงการทำงานโดยอัตโนมัติโดยไม่ต้องมีการเขียนโปรแกรมแบบชัดเจน การเรียนรู้ของเครื่องจะประมวลผลข้อมูลขนาดใหญ่, ระบุรูปแบบและความสัมพันธ์ภายในข้อมูล และใช้ความรู้นั้นในการตัดสินใจหรือทำนายผลลัพธ์ในอนาคต. Machine Learning ถูกนำไปใช้ในหลาย ๆ อุตสาหกรรมเพื่อเพิ่มความแม่นยำและความเร็วในการตัดสินใจ รวมทั้งในการพัฒนาแอปพลิเคชันที่ต้องการการโต้ตอบอย่างฉับไวและเฉพาะเจาะจงต่อสถานการณ์ที่เกิดขึ้นจริง

1 บทนำ

1.1 ที่มาและความสำคัญ

เทคโนโลยีความเป็นจริงเสริมนั้นได้เข้ามามีบทบาทในอุตสาหกรรมอัตโนมัติอย่างมากเมื่อไม่นานมานี้ หนึ่งในเหตุผลที่สำคัญคือ การที่เทคโนโลยีนี้สามารถเติมเต็มข้อมูลให้กับผู้ปฏิบัติงานได้อย่างเพียงพอที่จะสามารถทำงานได้อย่างไม่มีสะดุด การให้ข้อมูลเสริมเข้าไปในสิ่งแวดล้อมจริงนี้ เรียกว่า Augmented Reality (AR) หรือ ความเป็นจริงเสริม (Wikipedia, 2023) ซึ่งความเป็นจริงเสริมนี้ จะช่วยให้มีข้อมูลเพื่อการตัดสินใจเพิ่มขึ้นสำหรับผู้ใช้งาน หรือสามารถประยุกต์ใช้เพื่อการทำงานหรือฝึกปฏิบัติในอุตสาหกรรมอัตโนมัติ เช่น การซ่อมบำรุง การตรวจสอบสถานะของเครื่องจักร การวิเคราะห์การทำงานของเครื่องจักร เป็นต้น

มีงานวิจัยมากมายที่ศึกษาเกี่ยวกับเทคโนโลยี AR กับอุตสาหกรรมอัตโนมัติ เช่น งานวิจัยของ Chiang et al. (Chiang, Shang, & Qiao, 2022) แสดงให้เห็นถึงการประยุกต์ใช้งานเทคโนโลยี AR กับการฝึกปฏิบัติในวิทยาลัยเทคนิคและการอาชีพเกี่ยวกับการฝึกประสบการณ์การทำงานในอุตสาหกรรม ซึ่งได้ผลดีมากและสามารถนำไปต่อยอดในการฝึกปฏิบัติในด้านอื่น ๆ ได้อีกด้วย นอกจากนี้ ในแง่ของทางเศรษฐกิจ ข้อมูลจาก World Economic Forum ระบุว่า การใช้งาน AR นั้น จะเกิดขึ้นอย่างแพร่หลาย เนื่องจากเทคโนโลยีนี้ สามารถนำมาเพิ่มการรับรู้ด้วยการสร้างภาพกราฟิก การเพิ่มข้อมูลเฉพาะส่วน และการบอกเล่าเรื่องราว ซึ่งจะทำให้การเรียนรู้และการทำงานนั้นสะดวกสบายขึ้นมาก (World Economic Forum, 2023) นอกจากนี้ ยังมีการใช้เทคโนโลยี AR ในเชิงอุตสาหกรรมอัตโนมัติ ที่ช่วยให้สามารถทำงานได้อย่างรวดเร็ว เช่น การทำงานร่วมกับแขนกลหรือหุ่นยนต์ ที่สามารถระบุตำแหน่งได้อย่างแม่นยำ การทำงานในเชิงการซ่อมบำรุงที่สามารถแก้ไขความบกพร่องของเครื่องจักรเบื้องต้นได้อย่างทันที โดยอาจจะมีการใช้เทคโนโลยีอื่น ๆ เข้ามาช่วยในการทำงานได้ด้วย เช่น การโทรศัพท์แบบวิดีโอกับวิศวกรผู้เชี่ยวชาญ หรือการเชื่อมต่อกับเซ็นเซอร์หรืออุปกรณ์ต่าง ๆ เพื่อรับข้อมูลนำเข้าจากอุปกรณ์จำพวก Internet of Things (IoT) และสามารถส่งไปทำการวิเคราะห์และประมวลผลเพื่อทำการแก้ปัญหาต่อไป (Sureshkumar, Agash, Ramya, Kaviyaraj, & Elanchezhian, 2021) เป็นต้น

ในการวิจัยนี้ เป็นการศึกษาเกี่ยวกับการผสมผสานเทคโนโลยี AR เข้ากับการรู้จำภาพในรูปแบบ Object Detection และการใช้ปัญญาประดิษฐ์ (Artificial Intelligence: AI) ที่เหมาะสมในการวิเคราะห์เครื่องจักรในอุตสาหกรรมอัตโนมัติ เพื่อทำการตรวจสอบ ดูแล และซ่อมบำรุงได้ตามลักษณะทางกายภาพที่ปรากฏ เช่น มีการกระพริบของไฟสัญญาณที่เกี่ยวข้อง มีการแจ้งเตือนหรือ alarm ไฟสัญญาณ หรือมีการชำรุดเสียหายของชิ้นส่วน เป็นต้น โดยในการวิเคราะห์นี้ จะใช้พื้นฐานการควบคุมเครื่องจักรด้วยเครื่องควบคุม PLCnext (PLCnext Community, 2023) และการสร้างตัวต้นแบบโมเดลในการรู้จำความผิดปกติของเครื่องควบคุมนั้น บนพื้นฐานของการรู้จำภาพแบบ Object Detection เพื่อสร้างกระบวนการหรือขั้นตอนในการดูแล ปรับปรุง หรือซ่อมแซม

เครื่องจักรนั้นตามความเหมาะสม รวมถึงการพัฒนาตัวต้นแบบของแอปพลิเคชัน AR สำหรับงานด้านการบำรุงรักษาเครื่องจักรนี้ด้วย

อุตสาหกรรม 4.0 ทำให้การบำรุงรักษาอุตสาหกรรมมีความซับซ้อนมากขึ้นเนื่องจากเครื่องจักรและกระบวนการที่มีความซับซ้อนเพิ่มขึ้น โซลูชันระยะไกลในปัจจุบันขาดความสามารถในการวินิจฉัยแบบเรียลไทม์และความเข้าใจบริบท ในขณะที่วิธีการแบบดั้งเดิมที่ต้องการผู้เชี่ยวชาญที่หน้างานทำให้เกิดความล่าช้าในการดำเนินงานและค่าใช้จ่ายที่สูงขึ้น งานวิจัยของเราจึงพัฒนาระบบผู้เชี่ยวชาญระยะไกลอัจฉริยะที่บูรณาการการประมวลผลภาพด้วยคอมพิวเตอร์ (YOLOv8s สำหรับการตรวจจับและจำแนกประเภทแบบเรียลไทม์) ความเป็นจริงผสม (HoloLens 2 สำหรับการแสดงภาพเชิงพื้นที่) และการประมวลผลภาษาธรรมชาติ (แชทบอทแบบ RAG สำหรับการแนะนำการแก้ไขปัญหา) การบูรณาการเทคนิคนี้ช่วยให้สามารถวินิจฉัยและแก้ไขปัญหาการซ่อมบำรุงระยะไกลได้อย่างมีประสิทธิภาพ ซึ่งช่วยลดเวลาที่อุปกรณ์หยุดทำงานและปัญหาการหยุดชะงักในการดำเนินงานอย่างมีนัยสำคัญ

การนำระบบดังกล่าวไปใช้อย่างมีประสิทธิภาพสามารถลดเวลาในการซ่อมและวินิจฉัยได้อย่างมาก ลดเวลาที่เครื่องจักรหยุดทำงาน เพิ่มประสิทธิภาพโดยรวมของอุปกรณ์ (OEE) และเพิ่มประสิทธิภาพการใช้ทรัพยากรโดยใช้ประโยชน์จากความเชี่ยวชาญระยะไกล แนวทางนี้ช่วยลดค่าใช้จ่ายในการเดินทาง ปรับปรุงความสามารถในการขยายขนาดของการซ่อมบำรุง และอาจนำไปสู่การประยุกต์ใช้เทคโนโลยี AI และ AR ในวงกว้างในภาคอุตสาหกรรม ส่งเสริมให้เกิดนวัตกรรมในยุคอุตสาหกรรม 4.0

1.2 วัตถุประสงค์

- 1) เพื่อศึกษาความเป็นไปได้ในการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์บนพื้นฐานของการรู้จำภาพแบบ Object Detection กับเทคโนโลยีความเป็นจริงเสริม (Augmented Reality: AR) เพื่อการใช้งานในอุตสาหกรรมอัตโนมัติ
- 2) เพื่อศึกษาและพัฒนาตัวต้นแบบแอปพลิเคชัน AR สำหรับงานด้านอุตสาหกรรมอัตโนมัติ

1.3 ขอบเขตของการวิจัย

- 1) เทคโนโลยีควบคุมเครื่องจักรที่ใช้งานคือ PLCnext
- 2) เทคโนโลยี AR ที่ใช้งาน อยู่บนพื้นฐานเทคโนโลยีของ Microsoft
- 3) การสร้างแบบจำลองจะใช้งานได้กับ AR เท่านั้น ไม่รวม VR
- 4) การใช้ YOLOv8s เป็นแบบจำลองหลักในการตรวจจับวัตถุ
- 5) การตรวจจับไฟสถานะ LED บนอุปกรณ์ PLCnext
- 6) การทดสอบประสิทธิภาพที่ระยะทางแตกต่างกัน (ใกล้และไกล)

- 7) การวิเคราะห์ประสิทธิภาพฮาร์ดแวร์ของระบบบน HoloLens 2
- 8) การประยุกต์ใช้ RAG สำหรับการสร้างคำแนะนำในการซ่อมบำรุง

1.4 เครื่องมือที่ใช้การพัฒนา

1.4.1 อุปกรณ์ด้านฮาร์ดแวร์ (Hardware)

ลักษณะและส่วนประกอบคอมพิวเตอร์ที่แนะนำ

- 1) กราฟฟิก (Graphic) : NVIDIA RTX A1000 6GB Laptop
- 2) หน่วยประมวลผล (Processor) : Intel i7-13700H equivalent or greater หรือดีกว่า
- 3) หน่วยความจำ (Memory) : RAM 32 GB หรือมากกว่า
- 4) การแสดงผลวิดีโอ (Output) : HDMI 1.4, DisplayPort 1.2 หรือใหม่กว่า
- 5) พอร์ต USB (Port USB) : 1x USB 2.0 หรือดีกว่า
- 6) ระบบปฏิบัติการ (Operator System) : Windows 11

อุปกรณ์ด้านฮาร์ดแวร์อื่น ๆ

- 1) Microsoft HoloLens 2
- 2) Monitor
- 3) PLCnext Controller

1.4.2 ซอฟต์แวร์ที่ใช้ในการพัฒนา (Software)

- 1) Unity Application กับ XR Interaction Toolkits และ MRTK
- 2) VLC Network Stream protocol และ OBS Screen Capture
- 3) Flask application framework
- 4) WebSocket Communication

1.5 วิธีการดำเนินการวิจัย (Research methodology)

1.5.1 ศึกษาปัญหาและงานวิจัยที่เกี่ยวข้อง

- 1) วางแผนการดำเนินงานและศึกษาความเป็นไปได้
- 2) ศึกษาและรวบรวมข้อมูลเกี่ยวกับภาษาที่ใช้ในการเขียนโปรแกรมและเครื่องมือที่ใช้

1.5.2 ศึกษาและสร้างตัวต้นแบบโมเดลสำหรับการรู้จำความผิดปกติของเครื่องจักรด้วยวิธีการ Object Detection

- 1) ทดลองการทำงานและการแสดงข้อมูลของอุปกรณ์
- 2) นำโมเดล Object Detection ที่เหมาะสมมาใช้งานร่วมกับอุปกรณ์ AR

1.5.3 เขียนโปรแกรมเพื่อทดสอบการทำงานของ AR และทำการเก็บข้อมูลการใช้งาน

- 1) การออกแบบวิธีการนำข้อมูลจากโมเดลมาใช้งาน
- 2) การออกแบบการแสดงผลข้อมูลที่ได้จากโมเดล

1.5.4 วิเคราะห์ผลจากข้อมูลที่รวบรวมไว้ ทำการปรับปรุงกระบวนการตามความเหมาะสม

- 1) ทดลองและวิเคราะห์หาจุดบกพร่องของโมเดล
- 2) ปรับปรุงโมเดลด้วยการเรียนรู้จากจุดบกพร่อง

1.5.5 เขียนบทความวิจัยและตีพิมพ์บทความวิจัย

1.5.6 สรุปผลและทำรายงานฉบับสมบูรณ์

1.6 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ลดเวลาหยุดทำงานของอุปกรณ์และเพิ่มประสิทธิภาพการดำเนินงาน
- 2) ลดการพึ่งพาผู้เชี่ยวชาญที่หน้างาน
- 3) ลดต้นทุนการบำรุงรักษาและการเดินทาง
- 4) สร้างกระบวนการทัศน์ใหม่สำหรับการซ่อมบำรุงอุตสาหกรรม
- 5) ส่งเสริมการประยุกต์ใช้เทคโนโลยี AI, MR และ NLP ในภาคอุตสาหกรรม

2 ทฤษฎีและโครงการที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 ทฤษฎีการมองเห็นด้วยคอมพิวเตอร์

การมองเห็นด้วยคอมพิวเตอร์ (Computer Vision) เป็นหนึ่งในสาขาวิทยาการที่สำคัญในด้านปัญญาประดิษฐ์ ซึ่งมีหลักการทำงานที่เกี่ยวข้องกับการให้คอมพิวเตอร์มีความสามารถในการ "มองเห็น" และตีความสิ่งที่มองเห็นได้จากภาพหรือวิดีโอ สาขานี้มุ่งเน้นไปที่การพัฒนาอัลกอริทึมที่สามารถตรวจจับ ระบุ และจำแนกวัตถุหรือลักษณะต่าง ๆ ที่ปรากฏในภาพเพื่อให้สามารถทำการวิเคราะห์หรือตัดสินใจได้อย่างอัตโนมัติ การใช้งานของการมองเห็นด้วยคอมพิวเตอร์นั้นกว้างขวาง ตั้งแต่การตรวจสอบคุณภาพในสายการผลิต การนำทางของหุ่นยนต์ ไปจนถึงการวิเคราะห์ข้อมูลทางการแพทย์และการจดจำใบหน้า ด้วยการพัฒนาที่รวดเร็วในเทคโนโลยีเซ็นเซอร์และอัลกอริทึม การมองเห็นด้วยคอมพิวเตอร์ได้กลายเป็นเครื่องมือที่สำคัญในการเพิ่มประสิทธิภาพและการทำงานอัตโนมัติในหลาย ๆ อุตสาหกรรม

2.1.2 ปัญญาประดิษฐ์

ปัญญาประดิษฐ์ (Artificial Intelligence, AI) เป็นสาขาของวิทยาการคอมพิวเตอร์ที่เกี่ยวข้องกับการสร้างระบบหรือเครื่องจักรที่สามารถจำลองความสามารถทางปัญญาของมนุษย์ได้ รวมถึงการเรียนรู้ (learning) การอ้างอิงตามเหตุผล (reasoning) การรับรู้ (perception) การทำความเข้าใจภาษาธรรมชาติ (natural language understanding) และการแก้ไขปัญหา ในปัจจุบัน AI ถูกนำมาใช้ในหลากหลายอุตสาหกรรมเพื่อเพิ่มความเร็วและความแม่นยำในการทำงาน โดยระบบ AI สามารถพัฒนาจากการเรียนรู้ข้อมูลขนาดใหญ่ผ่านเทคนิคต่าง ๆ เช่น เครื่องเรียนรู้ (machine learning) และการเรียนรู้เชิงลึก (deep learning) การเรียนรู้เหล่านี้อาศัยเครือข่ายประสาทเทียมที่สามารถจำลองกระบวนการทางประสาทของสมองมนุษย์เพื่อรับรู้และประมวลผลข้อมูล ความก้าวหน้าของ AI มีบทบาทสำคัญในการเปลี่ยนแปลงวิธีการทำงานในหลาย ๆ ภาคส่วน ทำให้งานที่ซับซ้อนหรือต้องการความแม่นยำสูงสามารถทำได้ง่ายขึ้นและมีประสิทธิภาพมากขึ้น

2.1.3 การตรวจจับวัตถุ

การตรวจจับวัตถุ (Object Detection) เป็นหนึ่งในสาขาย่อยของการมองเห็นด้วยคอมพิวเตอร์ที่มีการศึกษาวิธีการในการระบุและระบุตำแหน่งของวัตถุหนึ่งหรือหลายวัตถุภายในภาพหรือวิดีโอ กระบวนการนี้ไม่เพียงแต่จำแนกประเภทวัตถุเท่านั้น แต่ยังระบุขอบเขตของวัตถุนั้นในภาพหรือวิดีโอ (bounding boxes) การตรวจจับวัตถุมีความสำคัญมากในหลาย ๆ แอปพลิเคชัน เช่น การวิเคราะห์วิดีโอจากกล้องวงจรปิดเพื่อการรักษาความปลอดภัย ระบบนำทางของยานพาหนะอัตโนมัติ การจดจำวัตถุเพื่อการควบคุมคุณภาพในการผลิต และอื่น ๆ

เทคนิคในการตรวจจับวัตถุมักจะพึ่งพาการใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก โดยใช้เครือข่ายประสาทเทียมที่ได้รับการฝึกฝนเพื่อรู้จำและทำความเข้าใจเกี่ยวกับลักษณะต่าง ๆ ของวัตถุจากฐานข้อมูลภาพขนาดใหญ่ ตัวอย่างของโมเดลที่ใช้ในการตรวจจับวัตถุ ได้แก่ YOLO (You Only Look Once), SSD (Single Shot MultiBox Detector) และ Faster R-CNN ซึ่งแต่ละโมเดลมีจุดเด่นและข้อจำกัดที่ต่างกันเหมาะสำหรับการประยุกต์ใช้งานที่แตกต่างกัน

2.1.4 ระบบเสริมความเป็นจริงหรือเทคโนโลยีความเป็นจริงเสริม (Augmented Reality)

เทคโนโลยีความเป็นจริงเสริม (Augmented Reality หรือ AR) เป็นเทคโนโลยีที่ผสมผสานโลกดิจิทัลกับโลกจริงโดยการเพิ่มข้อมูลเสมือนเข้ามาในสภาพแวดล้อมจริงผ่านอุปกรณ์ต่าง ๆ เช่น แว่นตา AR หรือสมาร์ทโฟน การใช้ AR ช่วยให้ผู้ใช้สามารถมองเห็นและโต้ตอบกับวัตถุเสมือนที่ปรากฏในโลกจริง ทำให้เกิดประสบการณ์ที่เสมือนจริงและมีการโต้ตอบอย่างมีปฏิสัมพันธ์กับสภาพแวดล้อมในชีวิตประจำวัน โดยไม่ต้องตัดขาดจากโลกจริง เช่นเดียวกับเทคโนโลยี VR

เทคโนโลยี AR ถูกนำมาใช้ในหลากหลายด้าน ไม่ว่าจะเป็นการฝึกอบรม การบำบัดรักษาทางการแพทย์ การท่องเที่ยว และการเล่นเกม ตัวอย่างเช่น การใช้ AR ในการฝึกอบรมสามารถช่วยให้ผู้เรียนเข้าใจเนื้อหาได้ง่ายขึ้นด้วยการแสดงภาพ 3 มิติ หรือการใช้ AR ในทางการแพทย์เพื่อช่วยในการวินิจฉัยโรคและการรักษาที่แม่นยำขึ้น ด้วยความสามารถในการเพิ่มข้อมูลเสมือนเข้ามาในสภาพแวดล้อมจริง AR จึงเป็นเทคโนโลยีที่มีศักยภาพในการปรับปรุงประสิทธิภาพและเพิ่มความน่าสนใจในหลากหลายกิจกรรม



ภาพที่ 1 ระบบเสริมความเป็นจริง (Augmented Reality)

2.1.5 HoloLens

HoloLens เป็นอุปกรณ์สวมศีรษะที่พัฒนาโดย Microsoft ซึ่งรวมเทคโนโลยีความเป็นจริงเสริม (Augmented Reality - AR) และความเป็นจริงผสม (Mixed Reality - MR) ไว้ด้วยกัน HoloLens ช่วยให้ผู้ใช้

สามารถมองเห็นและโต้ตอบกับวัตถุเสมือนในโลกจริงผ่านหน้าจอแว่นที่มีความโปร่งใส ซึ่งช่วยให้การทำงานและการเรียนรู้มีความสมจริงและมีปฏิสัมพันธ์มากขึ้น

HoloLens รองรับการพัฒนาแอปพลิเคชันผ่านแพลตฟอร์มการพัฒนาอย่าง Unity และ Unreal Engine ทำให้นักพัฒนาสามารถสร้างแอปพลิเคชัน 3D และ AR ได้อย่างมีประสิทธิภาพ ด้วยเครื่องมือที่ครบครันและการรองรับการเขียนโค้ดด้วยภาษา C# และ API ที่หลากหลาย นักพัฒนาสามารถเพิ่มวัตถุเสมือนเข้าไปในโลกจริงและสร้างประสบการณ์ที่น่าทึ่งให้กับผู้ใช้

หนึ่งในความสามารถที่โดดเด่นของ HoloLens คือการตรวจจับและติดตามตำแหน่งของวัตถุและผู้ใช้ในพื้นที่จริง ซึ่งช่วยให้การโต้ตอบกับวัตถุเสมือนมีความแม่นยำและสมจริง HoloLens ยังมีระบบเสียงแบบสามมิติที่ช่วยให้ผู้ใช้สามารถรับรู้ทิศทางของเสียงในพื้นที่เสมือนจริง ทำให้ประสบการณ์การใช้งานมีความสมบูรณ์ยิ่งขึ้น

ด้วยความสามารถในการสร้างแอปพลิเคชัน AR และ MR ที่มีประสิทธิภาพและใช้งานง่าย HoloLens จึงเป็นเครื่องมือที่มีความสำคัญในหลาย ๆ วงการ ไม่ว่าจะเป็นการแพทย์ การศึกษา การฝึกอบรม และการผลิต ทำให้นักพัฒนาและผู้ใช้สามารถสร้างสรรค์นวัตกรรมใหม่ ๆ และปรับปรุงกระบวนการทำงานให้มีประสิทธิภาพมากขึ้น



ภาพที่ 2 HoloLens

2.1.6 โปรแกรมยูนิตี้ (Unity)

Unity เป็นแพลตฟอร์มการพัฒนาเกมและการสร้างภาพจำลองแบบสามมิติที่ได้รับความนิยมอย่างแพร่หลาย เนื่องจากมีเครื่องมือที่ครบครันและใช้งานง่าย Unity รองรับการเขียนโค้ดด้วยภาษา C# และมี API ที่หลากหลาย ช่วยให้ผู้พัฒนาสามารถสร้างเกมและแอปพลิเคชัน 3D ได้อย่างมีประสิทธิภาพ นอกจากนี้ Unity ยังมีความสามารถในการสร้างแอปพลิเคชัน AR (Augmented Reality) ที่ช่วยให้ผู้พัฒนาสามารถเพิ่มวัตถุเสมือนเข้าไปในโลกจริงผ่านอุปกรณ์ต่าง ๆ เช่น สมาร์ทโฟนหรือแว่นตา AR Unity มีเครื่องมือที่ช่วยในการสร้างและจัดการ

วัตถุ 3D รวมถึงระบบฟิสิกส์ที่สมจริง ทำให้การพัฒนาแอปพลิเคชัน AR เป็นไปได้อย่างรวดเร็วและง่ายดาย เหมาะสำหรับทั้งผู้เริ่มต้นและผู้พัฒนามืออาชีพ



ภาพที่ 3 Unity

2.1.7 โปรแกรมอนาคอนด้า (Anaconda)

Anaconda เป็นโปรแกรมโอเพ่นซอร์สที่ช่วยในการจัดการทรัพยากรและสภาพแวดล้อมการพัฒนาในงานวิทยาศาสตร์ข้อมูลและการเรียนรู้ของเครื่อง (Machine Learning) รองรับหลายแพลตฟอร์มทั้ง Windows, macOS และ Linux ผู้ใช้สามารถสร้างและจัดการสภาพแวดล้อมการพัฒนาหลายแบบได้อย่างง่ายดายผ่านคำสั่ง conda ทำให้ติดตั้งแพ็คเกจและไลบรารีที่จำเป็นได้ในแต่ละสภาพแวดล้อมโดยไม่เกิดปัญหาความเข้ากันไม่ได้ นอกจากนี้ยังมี Jupyter Notebook สำหรับการพัฒนาและทดสอบโค้ดแบบอินเตอร์แอคทีฟ ช่วยให้นักวิจัยและผู้พัฒนาทดลองและปรับแก้โค้ดได้สะดวก Anaconda เป็นเครื่องมือที่มีประสิทธิภาพและเป็นที่ยอมรับในวงการนี้



ภาพที่ 4 Anaconda

2.1.8 Pretrained Model

Pretrained models เป็นโมเดลที่ถูกฝึกฝนล่วงหน้าบนชุดข้อมูลขนาดใหญ่และมีประสิทธิภาพสูงในการประมวลผลและวิเคราะห์ข้อมูลในด้านต่าง ๆ เช่น การตรวจจับวัตถุ (Object Detection) การจำแนกภาพ (Image Classification) และการประมวลผลภาษาธรรมชาติ (Natural Language Processing) การใช้โมเดลที่ถูกฝึกฝนล่วงหน้าเป็นที่ยอมรับในวงการปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง (Machine Learning) เนื่องจากช่วยลดเวลาและทรัพยากรในการฝึกฝนโมเดลใหม่จากศูนย์ โมเดลเหล่านี้สามารถนำไปใช้ในโปรเจกต์ต่าง ๆ ได้อย่างรวดเร็วและมีประสิทธิภาพ นอกจากนี้ pretrained models ยังสามารถปรับแต่งให้เหมาะสมกับงานเฉพาะได้ง่าย ทำให้นักพัฒนาและนักวิจัยสามารถสร้างสรรค์นวัตกรรมใหม่ ๆ ได้โดยไม่ต้องเริ่มต้นจากศูนย์ ซึ่งเป็นการเพิ่มประสิทธิภาพในการพัฒนาและทดสอบโมเดลในสภาพแวดล้อมที่หลากหลาย

2.1.9 YOLO

YOLO (You Only Look Once) เป็นหนึ่งในโมเดลการตรวจจับวัตถุ (Object Detection) ที่ได้รับความนิยมและมีประสิทธิภาพสูง YOLO มีความโดดเด่นในการตรวจจับวัตถุได้อย่างรวดเร็วและแม่นยำในภาพเดียว โดยไม่ต้องแบ่งภาพออกเป็น ส่วน ๆ การใช้งาน YOLO สามารถตอบสนองความต้องการของหลาย ๆ อุตสาหกรรม ไม่ว่าจะเป็นการรักษาความปลอดภัย การตรวจสอบคุณภาพสินค้า หรือการประยุกต์ใช้ในยานยนต์ไร้คนขับ หนึ่งในเวอร์ชันที่ได้รับความนิยมคือ YOLOv5 ซึ่งได้รับการพัฒนาให้มีความแม่นยำสูงขึ้นและมีประสิทธิภาพในการประมวลผลที่ดีกว่า YOLO เวอร์ชันก่อนหน้า YOLOv5 ถูกออกแบบมาให้มีขนาดโมเดลที่เล็กลงแต่ยังคงความสามารถในการตรวจจับวัตถุที่รวดเร็วและแม่นยำ โดยรองรับการใช้งานที่หลากหลายและง่ายต่อการนำไปประยุกต์ใช้ในโปรเจกต์ต่าง ๆ ของนักพัฒนาและนักวิจัย

2.2 งานที่เกี่ยวข้อง (Related Works)

2.2.1 การบูรณาการ YOLOv8s และ HoloLens 2 สำหรับการประยุกต์ใช้ในอุตสาหกรรม

การพัฒนาล่าสุดในเทคโนโลยีความเป็นจริงเสริม (AR) และอัลกอริทึมการตรวจจับวัตถุได้เปิดโอกาสใหม่สำหรับการประยุกต์ใช้ในอุตสาหกรรม Li และคณะ (Li, Zhang, Guo, Chen, & Wang, 2024) พบว่าการเพิ่มกลไกความสนใจ (attention mechanisms) เข้าไปใน YOLOv8 ช่วยเพิ่มความเร็วและความแม่นยำในการตรวจสอบสถานะไฟฟ้าย่อยอย่างมาก พร้อมให้ข้อมูลป้อนกลับแบบเรียลไทม์สำหรับการแก้ไขข้อบกพร่องอย่างรวดเร็ว ในสภาพแวดล้อมอุตสาหกรรมที่มีการเชื่อมต่อจำกัด Łysakowski และคณะ (Łysakowski et al., 2023) ประสบความสำเร็จในการติดตั้ง YOLOv8 โดยตรงบน HoloLens 2 โดยไม่ต้องพึ่งพาระบบคลาวด์ ซึ่งช่วยลดปัญหาความล่าช้าของเครือข่ายและเพิ่มการตอบสนองและความน่าเชื่อถือของระบบ เพื่อปรับปรุงประสบการณ์ผู้ใช้และประสิทธิภาพการทำงานในสถานการณ์อุตสาหกรรมที่มีการเปลี่ยนแปลง Bahri และ Krčmář (Bahri & Krčmář, 2019) ได้พัฒนา YOLOv8 ให้สามารถตรวจจับวัตถุแบบเรียลไทม์ด้วยกรอบขอบเขตที่แม่นยำในระดับมิลลิวินาที

งานวิจัยนี้รวมพัฒนาการเหล่านี้เข้าเป็นโซลูชันเดียวสำหรับการประยุกต์ใช้ในการซ่อมบำรุงอุตสาหกรรม เราใช้กลยุทธ์การประมวลผลบนอุปกรณ์ของ Łysakowski เพื่อให้ได้ผลตอบกลับที่มีความล่าช้าต่ำพร้อมการโต้ตอบ AR ที่ราบรื่น ปรับใช้วิธีการของ Li เพื่อเพิ่มความแม่นยำในการตรวจจับสถานะไฟ LED และนำแนวทางเพิ่มประสิทธิภาพของ Bahri มาใช้สำหรับการตรวจสอบเครื่องจักรที่ตอบสนองได้ดี วิธีแบบบูรณาการนี้แก้ไขความท้าทายเฉพาะของการซ่อมบำรุงอุตสาหกรรม ซึ่งต้องการการตรวจจับสถานะอุปกรณ์ที่รวดเร็วและแม่นยำเพื่อการแก้ไขปัญหาที่มีประสิทธิภาพและลดเวลาที่อุปกรณ์หยุดทำงาน

2.2.2 เทคนิคการเพิ่มข้อมูลสำหรับชุดข้อมูลอุตสาหกรรมที่มีข้อจำกัด

การรวบรวมข้อมูลที่มีคุณภาพและมีคำอธิบายประกอบในการมองเห็นด้วยคอมพิวเตอร์เชิงอุตสาหกรรมมีความท้าทายอย่างมากเนื่องจากข้อจำกัดในการผลิตและสภาวะข้อบกพร่องที่เกิดขึ้นไม่บ่อย การเพิ่มข้อมูลแก้ไขข้อจำกัดนี้โดยการขยายชุดข้อมูลฝึกอบรมในขณะที่รักษาคุณลักษณะสำคัญไว้ กลยุทธ์การเพิ่มข้อมูลต่าง ๆ ให้ประโยชน์ที่แตกต่างกันสำหรับการประยุกต์ใช้ในอุตสาหกรรม

การแปลงทางเรขาคณิตเป็นพื้นฐานของการเพิ่มข้อมูลภาพอุตสาหกรรม Zhang (Zhang, 2024) แสดงให้เห็นว่าการแปลงเหล่านี้รักษาความสมบูรณ์ทางความหมายไว้ในขณะที่สร้างความแปรปรวนของตำแหน่ง ซึ่งจำเป็นสำหรับระบบการมองเห็นของเครื่องจักรที่ต้องจดจำอุปกรณ์จากหลายมุมมอง การใช้การหมุนและการพลิกกับตัวอย่างที่มีจำกัด ช่วยให้โมเดลพัฒนาการทั่วไปที่ดีขึ้นสำหรับมุมมองการตรวจสอบที่แตกต่างกันในสภาพแวดล้อมจริง

สำหรับการขยายข้อมูลที่ซับซ้อนยิ่งขึ้น Jebraeeli และคณะ (Jebraeeli, Jiang, Krim, & Cansever, 2024) ได้แสดงการประสานลักษณะและการแมปกราฟขยายเพื่อสร้างตัวอย่างที่หลากหลายจากชุดข้อมูลที่มีจำกัด เทคนิคเหล่านี้รักษาทั้งการกระจายข้อมูลและความสัมพันธ์ของลักษณะเฉพาะ ทำให้มีคุณค่าสำหรับอุตสาหกรรมที่การรวบรวมข้อมูลข้อบกพร่องที่ครอบคลุมเป็นไปได้ในทางปฏิบัติหรือมีค่าใช้จ่ายสูงเกินไป

วิธีการสร้างขั้นสูงให้ความสามารถที่ยิ่งใหญ่ยิ่งขึ้นในการสร้างข้อมูลที่สมจริง Ekwaro-Osire และคณะ (Ekwaro-Osire, Ponugupati, Al Noman, Bode, & Thoben, 2025) แสดงให้เห็นว่า Generative Adversarial Networks (GANs) สามารถสร้างตัวอย่างสังเคราะห์คุณภาพสูงสำหรับการประยุกต์ใช้การมองเห็นในอุตสาหกรรม โดยเฉพาะกับข้อมูลที่ไม่ใช่อนุกรมเวลาและลักษณะเครื่องจักรที่มีความสัมพันธ์กัน ในทำนองเดียวกัน Wu และคณะ (Wu, Shen, & Ye, 2024) พิสูจน์ว่า Variational Autoencoders (VAEs) สร้างตัวอย่างเสมือนจากข้อมูลอนุกรมเวลาที่ตรงกับการกระจายข้อมูลการดำเนินงานจริงได้อย่างมีประสิทธิภาพ ทำให้สามารถจำลองสถานการณ์ข้อบกพร่องที่หายากซึ่งยากต่อการทำซ้ำในการดำเนินงานปกติได้

เมื่อนำการเพิ่มข้อมูลมาใช้กับการประยุกต์ใช้ในอุตสาหกรรม ผู้ปฏิบัติต้องสร้างความสมดุลระหว่างความซับซ้อนของเทคนิคกับประโยชน์ด้านประสิทธิภาพ ทรัพยากรการคำนวณที่จำเป็นสำหรับวิธีการขั้นสูงเช่น GANs ต้องมีการรับรองโดยการปรับปรุงที่สอดคล้องกันในประสิทธิภาพของโมเดล (Jebraeeli et al., 2024) โดยเฉพาะอย่างยิ่งในสภาพแวดล้อมอุตสาหกรรมที่มีทรัพยากรจำกัด

2.2.3 การพัฒนาของโมเดล YOLO และการประยุกต์ใช้ในอุตสาหกรรม

YOLO (You Only Look Once) ได้รับการพัฒนาต่อเนื่องมาตั้งแต่เวอร์ชันแรก ผ่าน YOLOv2, YOLOv3 และ YOLOv4 โดยแต่ละเวอร์ชันได้มีการเพิ่มความเร็วและความแม่นยำในการตรวจจับวัตถุ (Bochkovskiy, Wang, & Liao, 2020) สำหรับ YOLOv5 มีการปรับปรุงในด้านความเร็วและความแม่นยำของการตรวจจับวัตถุ

ทำให้เหมาะสมมากยิ่งขึ้นสำหรับการใช้ตรวจจับส่วนประกอบต่าง ๆ ของเครื่องจักรเช่น PLCnext (Yao et al., 2021)

การตรวจจับแบบเรียลไทม์มีความสำคัญอย่างยิ่งในหลายภาคส่วน โดยเฉพาะอย่างยิ่งในด้านความปลอดภัยและการตรวจจับวัตถุหรือบุคคลในภาพหรือวิดีโอ ในบริบทของการตรวจจับส่วนต่าง ๆ ของเครื่องจักร เช่น PLCnext, YOLOv8s สามารถนำมาใช้เพื่อระบุและจัดหมวดหมู่ชิ้นส่วนต่าง ๆ ของเครื่องจักรได้แบบเรียลไทม์ ทำให้สามารถเฝ้าติดตามและตรวจสอบสถานะของเครื่องจักรได้อย่างรวดเร็วและแม่นยำ (Kongon, Jantarakongkul, & Jitngernmadan, 2024)

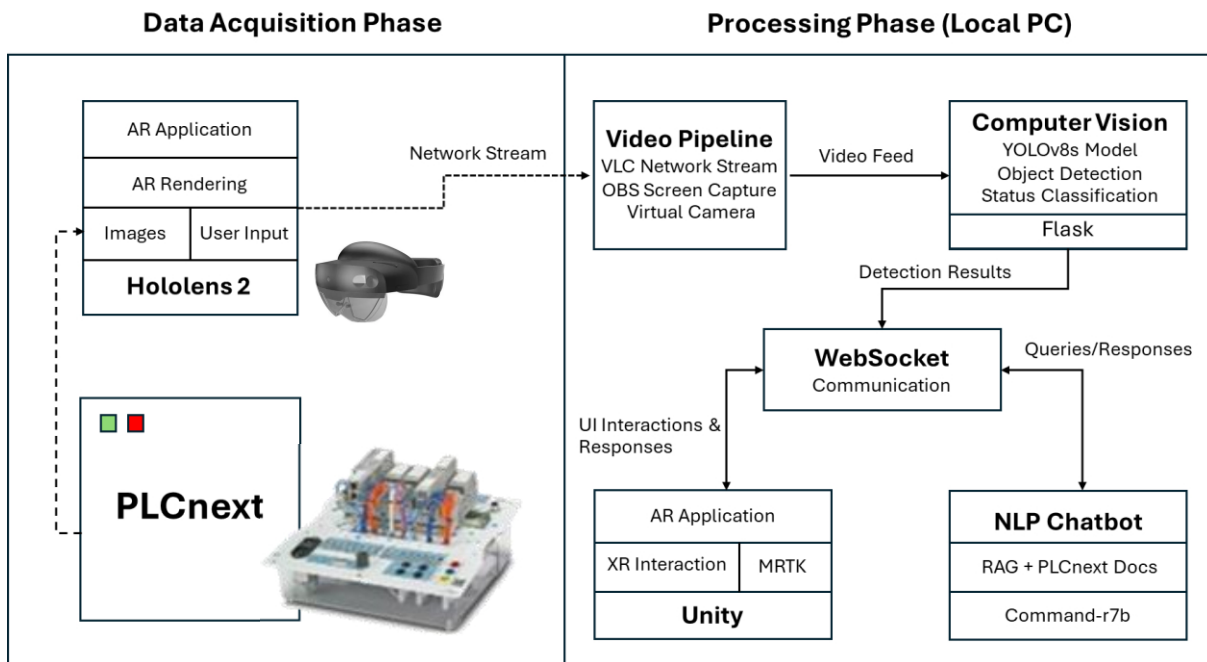
การผสมรวมโมเดลที่ผ่านการฝึกอบรมเข้ากับ Unity 3D engine นั้นท้าทาย เว็บไซต์ของ GitHub มีทรัพยากรที่ยอดเยี่ยมสำหรับเรื่องนี้ (EnoxSoftware, 2023) เว็บไซต์นี้มีบทเรียนที่มีประโยชน์เกี่ยวกับการส่งออกโมเดล YOLO รวมถึงโค้ดที่พร้อมใช้งาน นอกจากนี้ยังมีเวอร์ชันอ้างอิงของ Unity ที่ทำงานร่วมกับโมเดลเหล่านี้ได้อย่างราบรื่น ทรัพยากรนี้พิสูจน์แล้วว่ามีความสำคัญอย่างยิ่งในการพัฒนาระบบผู้เชี่ยวชาญระยะไกลที่ขับเคลื่อนด้วย AI

3 วิธีการดำเนินงานโครงการ

3.1 ภาพรวมของการดำเนินงาน

ระบบผู้เชี่ยวชาญระยะไกลด้วย AI นี้เป็นการผสมผสานเทคโนโลยีปัญญาประดิษฐ์ (AI) การประมวลผลภาษาธรรมชาติ (NLP) ความเป็นจริงผสม (AR/MR) และเทคโนโลยีวิทัศน์คอมพิวเตอร์ (Computer Vision) เพื่อการซ่อมบำรุงเครื่องจักร ระบบนี้ช่วยให้สามารถวินิจฉัยเครื่องจักรได้แบบเรียลไทม์ทั้งในพื้นที่จริงและจากระยะไกล ทำให้ลดความจำเป็นในการเรียกผู้เชี่ยวชาญมายังสถานที่จริงเมื่อเครื่องจักรเกิดความผิดปกติ

ระบบถูกออกแบบให้มีโครงสร้างที่เป็นส่วนของการทำงานสองส่วนหลัก ดังแสดงในภาพที่ 5 ซึ่งแสดงโครงสร้างระบบในภาพรวม โดยเน้นการเคลื่อนที่ของข้อมูลและการสื่อสารระหว่างองค์ประกอบหลักในแต่ละระดับ



ภาพที่ 5 ภาพรวมสถาปัตยกรรมระบบผู้เชี่ยวชาญระยะไกลด้วย AI

3.1.1 ส่วนของการรับข้อมูล (Data Acquisition Phase)

ส่วนของการรับข้อมูลถูกรวมเข้ากับพื้นที่ในการใช้งานในอุตสาหกรรมและทำหน้าที่เป็นอินเทอร์เฟซของระบบ โดยใช้อุปกรณ์แว่น Microsoft HoloLens 2 ซึ่งถูกสวมใส่โดยผู้ปฏิบัติงานในพื้นที่และทำการรับภาพวิดีโอของอุปกรณ์ PLCnext โดยระบบ HoloLens 2 ทำงานผ่านแอปพลิเคชัน AR ที่มีฟังก์ชันการประมวลผลภาพและการแปลความหมายตามคำสั่งจากผู้ใช้ ซึ่งชุดอุปกรณ์แว่น HoloLens ทำงานแบบไม่ต้องใช้อุปกรณ์ควบคุมภายนอก ทำให้ผู้ปฏิบัติงานสามารถมองเห็นอุปกรณ์จริงไปพร้อมกับการรับข้อมูลในรูปแบบความเป็นจริงเสริมที่แสดงข้อมูลการวิเคราะห์และคำแนะนำ โดยที่ภาพวิดีโอจาก HoloLens 2 จะถูกส่งผ่านการเชื่อมต่อเครือข่ายไปยังส่วนของการประมวลผล ซึ่งเป็นการสร้างไปป์ไลน์ข้อมูลเริ่มต้นสำหรับระบบนี้

3.1.2 ส่วนของการประมวลผล (Processing Phase)

ส่วนของการประมวลผลอยู่ภายในเครื่องคอมพิวเตอร์ที่ตั้งอยู่ในพื้นที่และประกอบด้วยโมดูลพิเศษ เฉพาะงานหลายโมดูลที่ทำงานร่วมกันเพื่อวิเคราะห์สภาพอุปกรณ์และให้คำแนะนำเฉพาะทาง โดยส่วนประกอบ โมดูล ได้แก่


1. **โมดูลไปป์ไลน์วิดีโอ (Video Pipeline Module)** - ระบบรับสตรีมวิดีโอของ HoloLens 2 ผ่านโปรโตคอล VLC Network Stream และดำเนินการประมวลผลเบื้องต้นโดยใช้ OBS Screen Capture ซึ่งแปลงสตรีมที่เข้ามาให้เป็นรูปแบบ Virtual Camera ที่สามารถใช้งานร่วมกับ องค์ประกอบระบบในลำดับถัดไป
2. **โมดูลการสื่อสาร WebSocket** - องค์ประกอบหลักของระบบคือ ช่องทางการสื่อสารแบบ สองทิศทางที่อำนวยความสะดวกในการแลกเปลี่ยนข้อมูลแบบเรียลไทม์ระหว่างโมดูลระบบ ทั้งหมด โดยส่งผลการตรวจจับไปยังทั้งแอปพลิเคชัน Unity และเซิร์ฟเวอร์ NLP พร้อมกับการ กระจายคำถามของผู้ใช้และคำสั่งอินเทอร์เฟซไปทั่วสถาปัตยกรรมระบบ
3. **โมดูลเซิร์ฟเวอร์ NLP** - เซิร์ฟเวอร์ AI ให้คำแนะนำการแก้ไขปัญหาระดับผู้เชี่ยวชาญตามเงื่อนไขที่ วินิจฉัย โดยใช้เทคโนโลยี Retrieval-Augmented Generation (RAG) ที่รวมเอกสาร PLCnext และขับเคลื่อนโดยโมเดลภาษา Command-r7b ทำให้เซิร์ฟเวอร์สามารถวิเคราะห์การวินิจฉัย อย่างครอบคลุมและให้คำแนะนำในการบำรุงรักษาตามลำดับหลังจากที่ระบุข้อผิดพลาดแล้ว
4. **โมดูลวิทัศน์คอมพิวเตอร์ (Computer Vision Module)** - โมดูลวิทัศน์คอมพิวเตอร์ใช้โมเดล YOLOv8s เพื่อทำการตรวจจับวัตถุแบบเรียลไทม์และจำแนกสถานะของไฟแสดงสถานะ LED บนอุปกรณ์ PLCnext โดยโมเดลได้รับการฝึกเป็นพิเศษเพื่อระบุสถานะการทำงานและเงื่อนไข ข้อผิดพลาดต่าง ๆ ผ่านการสังเกตด้วยสายตา ผลการตรวจจับทั้งหมดจะถูกประมวลผลและ กระจายผ่านเฟรมเวิร์คแอปพลิเคชัน Flask
5. **โมดูลแอปพลิเคชัน Unity** - โมดูลนี้ขับเคลื่อนการแสดงผลแบบความเป็นจริงผสมและ อินเทอร์เฟซที่แสดงภายในอุปกรณ์แว่น HoloLens 2 โดยใช้ XR Interaction Toolkits และ ส่วนประกอบไลบรารี MRTK (Mixed Reality Toolkit) เพื่อสร้างสภาพแวดล้อมแบบโต้ตอบ ซึ่ง ผลการตรวจจับจะถูกวางซ้อนทับบนอุปกรณ์จริงในมุมมองของผู้ปฏิบัติงาน พร้อมกับให้ อินเทอร์เฟซที่โต้ตอบได้กับเซิร์ฟเวอร์ของ NLP ซึ่งการผสมผสานนี้สร้างประสบการณ์ความเป็น จริงผสมที่ราบรื่นสำหรับผู้ปฏิบัติงาน

ระบบที่ถูกพัฒนานี้จะทำงานผ่านขั้นตอนการทำงานอย่างต่อเนื่อง โดยที่ในการปฏิบัติงานของผู้ปฏิบัติงาน ที่ใช้งานอุปกรณ์แว่น HoloLens 2 จะถูกบันทึก แล้วประมวลผลเพื่อระบุไฟแสดงสถานะ และวิเคราะห์เพื่อกำหนด ข้อผิดพลาดที่อาจเกิดขึ้น และเสริมด้วยคำแนะนำและข้อมูลภาพที่เหมาะสม ซึ่งกลไกการตอบสนองแบบเรียลไทม์

นี้ช่วยให้สามารถตอบสนองต่อความผิดปกติของอุปกรณ์ได้ทันทีโดยไม่ต้องมีช่างเทคนิคผู้เชี่ยวชาญอยู่ในสถานที่จริง ซึ่งเป็นวิธีการที่ช่วยลดเวลาหยุดทำงานของเครื่องจักร และเพิ่มประสิทธิภาพในการบำรุงรักษาอุตสาหกรรมได้ดียิ่งขึ้น

3.2 การเตรียมข้อมูล

การเตรียมข้อมูล ประกอบด้วย 4 ขั้นตอนหลัก ดังแสดงในภาพที่ 6 และมีรายละเอียดดังนี้



ภาพที่ 6 ขั้นตอนการเตรียมข้อมูล

3.2.1 การบันทึกวิดีโอ (Video Capture)

กระบวนการรับข้อมูลวิดีโอ เริ่มต้นด้วยการบันทึกวิดีโอแบบมีโครงสร้างโดยเน้นที่การบันทึกอุปกรณ์ PLCnext โดยเฉพาะอย่างยิ่งในส่วนไฟแสดงสถานะของ LED เพื่อบันทึกสถานะการทำงานทั้งหมด โดยเราได้ทำการบันทึกวิดีโอความยาว 5 วินาทีจำนวน 2 รายการ ซึ่งบันทึกที่ 30 เฟรมต่อวินาที (30 fps) เพื่อให้มั่นใจว่ามีความละเอียดเชิงเวลาเพียงพอสำหรับการแยกความแตกต่างระหว่างสถานะของ LED ทั้งแบบนิ่งและแบบกะพริบ โดยการบันทึกข้อมูลภาพวิดีโอทั้งหมดนี้ ถูกดำเนินการภายใต้สภาพแสงที่ควบคุมความสว่างให้คงที่ โดยให้ความใส่ใจเป็นพิเศษกับตำแหน่งของกล้องเพื่อให้มองเห็นไฟแสดงสถานะทั้งหมดได้อย่างชัดเจน วิธีการเก็บข้อมูลอย่างเป็นระบบนี้ ทำให้ได้ข้อมูลภาพที่มีคุณภาพสูง เหมาะสำหรับการประมวลผลในลำดับถัดไป

3.2.2 การแยกเฟรม (Frame Extraction)

ขั้นตอนนี้เกี่ยวข้องกับการแยกเฟรมแต่ละเฟรมจากวิดีโอที่บันทึกไว้ ซึ่งวิดีโอแต่ละชุดความยาว 5 วินาที โดยบันทึกที่ 30 เฟรมต่อวินาที ทำให้มีประมาณ 150 เฟรมต่อวิดีโอ ซึ่งทำให้ได้เฟรมทั้งหมด 300 เฟรมจากการบันทึกทั้ง 2 วิดีโอ การแยกเฟรมดำเนินการโดยใช้ซอฟต์แวร์เฉพาะทางที่สามารถแบ่งเนื้อหาวิดีโอเป็นภาพแยกได้ในขณะที่ยังคงรักษาความสมบูรณ์ของภาพแต่ละภาพตลอดขั้นตอนการทำงาน เฟรมที่แยกแต่ละเฟรมถูกบันทึกในรูปแบบไฟล์ที่เหมาะสมซึ่งได้รับการปรับให้เหมาะสมกับความต้องการในการประมวลผลในลำดับถัดไป โดยดำเนินการตามขั้นตอนเป็นไปตามมาตรฐานการปฏิบัติงานเพื่อตรวจสอบว่าไฟแสดงสถานะ LED ทั้งหมดยังคงมองเห็นได้อย่างชัดเจนในแต่ละเฟรม ซึ่งเป็นสิ่งจำเป็นสำหรับกระบวนการใส่คำอธิบายในลำดับถัดไป

3.2.3 การใส่คำอธิบายข้อมูล (Data Annotation)

ในระหว่างขั้นตอนการใส่คำอธิบาย เฟรมที่แยกออกมาจะผ่านกระบวนการติดฉลาก (Labeling) อย่างทั่วถึงเพื่อจัดหมวดหมู่และระบุสถานะ LED ที่มองเห็นได้ มีการกำหนดหมวดหมู่การจำแนกที่แตกต่างกัน 4 หมวดหมู่ ได้แก่ RUN_green_steady, D_green_steady, BF_D_red_flash และ PLC ซึ่งระบุทั้งคุณลักษณะของสี (เขียว/แดง) และคุณลักษณะเชิงเวลา (นิ่ง/กะพริบ) ของไฟแสดงสถานะ LED โดยสีเหลี่ยมผืนผ้าที่แสดงขอบเขตจะถูกวาดรอบไฟแสดงสถานะ LED แต่ละดวงอย่างแม่นยำ โดยมีการกำหนดฉลากคลาสที่เหมาะสมตามสถานะที่สังเกตเห็นในคำอธิบายประกอบ กระบวนการนี้ต้องการความละเอียดในการระบุขอบเขตของไฟแสดงสถานะและจำแนกสถานะการทำงานอย่างถูกต้อง โดยเฉพาะอย่างยิ่งเมื่อจับภาพเฟรมที่แสดงช่วงเปลี่ยนผ่านในลำดับการกะพริบ

3.2.4 การเพิ่มข้อมูล (Data Augmentation)

เพื่อเพิ่มความเสถียร ถูกต้องแม่นยำ และความสามารถในการทำงานของโมเดล เทคนิคการเพิ่มข้อมูลได้ถูกนำมาใช้กับชุดภาพที่ได้รับการติดฉลากนี้ ซึ่งวิธีการเพิ่มข้อมูลหลักที่ใช้คือ การหมุนทั้งซ้ายและขวา โดยเทคนิคนี้สร้างรูปแบบเพิ่มเติม 2 รูปแบบสำหรับต้นฉบับแต่ละภาพ โดยมีการขยายชุดข้อมูลจาก 300 ภาพ เป็น 900 ภาพ ซึ่งกระบวนการเพิ่มข้อมูลนี้ ได้รับการออกแบบมาโดยเฉพาะเพื่อปรับปรุงความสามารถของโมเดลในการรู้จำสถานะ LED จากมุมมองที่แตกต่างกันเล็กน้อย ซึ่งเป็นความสามารถที่สำคัญเมื่อนำระบบไปใช้ในสภาพแวดล้อมการทำงานจริง ที่ตำแหน่งของกล้องอาจแตกต่างกันได้ตามสภาพการใช้งาน

3.3 การพัฒนาโมเดล

3.3.1 การนำ YOLOv8s มาใช้งาน (YOLOv8s Implementation)

ระบบนี้ใช้ YOLOv8s เป็นโมเดลตรวจจับวัตถุหลักสำหรับการระบุไฟแสดงสถานะไฟ LED บนอุปกรณ์ PLCnext โดยการเลือกโมเดลนี้มาจากการวิจัยก่อนหน้านี้ของเราที่แสดงให้เห็นถึงประสิทธิภาพของอัลกอริทึม YOLO ในงานอุตสาหกรรม โดยเฉพาะอย่างยิ่งสำหรับการตรวจจับความผิดปกติในสภาพแวดล้อมการผลิต ซึ่งโมเดลตระกูล YOLO ที่ทำงานร่วมกับอุปกรณ์ HoloLens 2 นี้ แสดงศักยภาพที่สำคัญในการเพิ่มประสิทธิภาพการบำรุงรักษาเชิงคาดการณ์ (Preventive Maintenance) และลดเวลาหยุดทำงานของเครื่องจักรในสภาพแวดล้อมอุตสาหกรรมที่กำลังผลิตอยู่ โดยตัวโมเดล YOLOv8s ให้ความสมดุลที่เหมาะสมระหว่างความแม่นยำในการตรวจจับและความเร็วในการประมวลผล ซึ่งทำให้เหมาะสำหรับการใช้งานแบบเรียลไทม์บนอุปกรณ์ฮาร์ดแวร์ที่มีข้อจำกัดในการคำนวณเช่น อุปกรณ์ HoloLens 2 โดยสถาปัตยกรรมของโมเดลช่วยให้สามารถตรวจจับวัตถุหลายคลาสที่มีความซับซ้อนสูงได้ ซึ่งถือเป็นข้อกำหนดที่สำคัญและจำเป็นอย่างยิ่งสำหรับการระบุและจำแนกสถานะไฟ LED ต่าง ๆ พร้อมกันได้

3.3.2 กระบวนการฝึกโมเดล (Model Training Process)

กระบวนการฝึกโมเดลนั้นใช้กระบวนการที่เรียกว่า การเรียนรู้ถ่ายโอน (transfer learning) จากค่าน้ำหนักที่ผ่านการฝึกมาก่อน เพื่อปรับให้เหมาะสมกับระยะเวลาการฝึกและประสิทธิภาพของโมเดลบนชุดข้อมูลที่ค่อนข้างจำกัดของเรา โดยโมเดล AI นี้ได้รับการฝึกโดยใช้ภาพ 900 ภาพ ซึ่งแต่ละภาพมีเส้นขอบเขต (bordering line) ที่มีคำอธิบายสำหรับการจำแนกสถานะ LED ในแต่ละหมวดหมู่ โดยมีการกำหนดพารามิเตอร์สำหรับการฝึกดังนี้ คือ

- 1) 300 epochs
- 2) batch size 16
- 3) ขนาดภาพอินพุต 640×640 พิกเซล และ
- 4) optimizer momentum 0.937

เพื่อเพิ่มขีดความสามารถในการทำงานของโมเดลในภาพรวม นอกจากนั้น เราใช้เทคนิคการเพิ่มข้อมูลในรูปแบบต่าง ๆ (Augmentation) ซึ่งรวมถึงการพลิกแนวนอนแบบสุ่ม การแปลง การปรับขนาด และการลบแบบสุ่ม และมีการเปิดใช้งานการฝึกแบบ mixed precision เพื่อเพิ่มประสิทธิภาพของหน่วยความจำและเร่งกระบวนการฝึกอีกด้วย ในการตรวจสอบความถูกต้องของโมเดลนั้น มีการดำเนินการโดยใช้ชุดข้อมูลตรวจสอบความถูกต้องที่เป็นอิสระแยกจากกัน ซึ่งประเมินประสิทธิภาพหลักโดยใช้ค่า mean Average Precision (mAP) ที่ค่าขีดเริ่ม Intersection over Union (IoU) = 0.7

3.3.3 คลาสที่ตรวจจับและพารามิเตอร์ (Detection Classes and Parameters)

โมเดลถูกออกแบบมาเพื่อจำแนกและระบุหมวดหมู่ที่แตกต่างกัน 4 หมวดหมู่ ได้แก่

1. ไฟแสดง RUN สีเขียวแบบหนึ่งที่แสดงถึงการทำงานปกติ
2. ไฟแสดง D สีเขียวแบบหนึ่งที่แสดงถึงการสื่อสารข้อมูลที่เหมาะสม
3. ไฟแสดง BF_D สีแดงแบบกะพริบที่แสดงถึงข้อผิดพลาดหรือข้อบกพร่อง และ
4. อุปกรณ์ PLCnext โดยรวมที่ทำหน้าที่เป็นจุดอ้างอิงเชิงพื้นที่

ระบบการจำแนกนี้ได้เพิ่มเติมการวิจัยก่อนหน้านี้ของเราในการตรวจสอบสถานะอุปกรณ์ควบคุมเครื่องจักรอุตสาหกรรม โดยมีการรวมความสามารถในการตรวจจับสถานะแบบเวลาจริงเข้ามาด้วย สำหรับการทำ inference แบบเรียลไทม์นั้น โมเดลถูกกำหนดค่าด้วยค่า confidence threshold = 0.25 และ IoU = 0.7 และการตรวจจับสูงสุด 300 epochs ในการทำงานนี้ การตรวจจับสถานะการณีกะพริบของหลอดไฟ LED เป็นความท้าทายอย่างยิ่ง โดยหลักการสำคัญคือ จำเป็นต้องมีการวิเคราะห์เชิงเวลาของเฟรมอย่างต่อเนื่องร่วมกับอัลกอริทึม

การกรองข้อมูลแบบเฉพาะทาง เพื่อแยกความแตกต่างระหว่างไฟแสดงสถานะที่นิ่งและไฟแสดงสถานะที่กระพริบได้อย่างแม่นยำ

3.4 การบูรณาการการประมวลผลภาษาธรรมชาติ (Natural Language Processing Integration)

ระบบที่นำเสนอนี้ มีการรวมโมดูลการประมวลผลภาษาธรรมชาติ (NLP) เพื่อให้การสนับสนุนการแก้ไขปัญหาอย่างชาญฉลาดโดยใช้แชทบอท AI โดยแชทบอทนี้ให้ข้อมูลและการสนับสนุนที่ไวแก่ผู้ปฏิบัติงานตามบริบทการใช้งานที่มีการดึงข้อมูลจากเอกสารเฉพาะของอุปกรณ์ PLCnext ออกมาด้วย

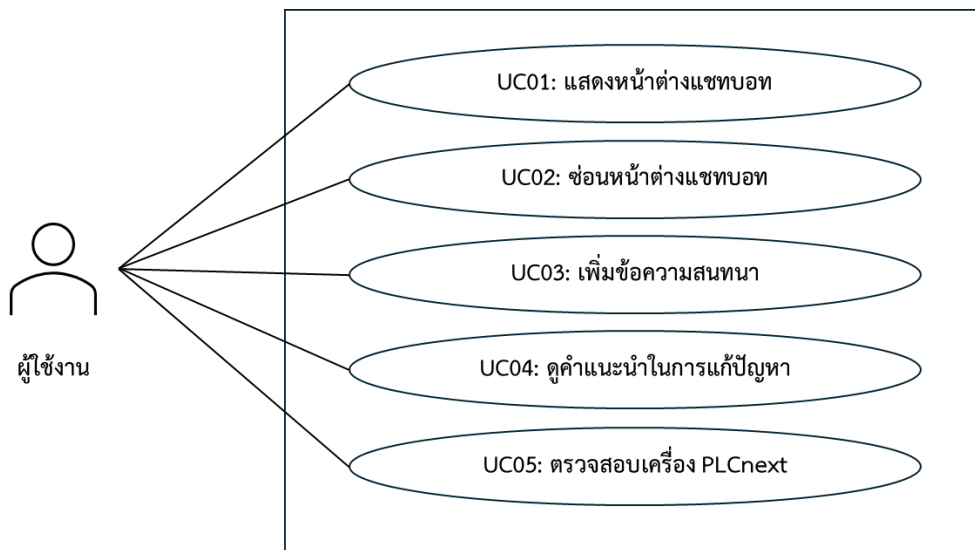
สำหรับฐานความรู้ของแชทบอทนี้ เราได้นำวิธีการ Retrieval-Augmented Generation (RAG) มาใช้ ซึ่งมีการรวมโมเดลภาษาที่ผ่านการฝึกล่วงหน้ากับเอกสารที่เกี่ยวข้องนี้ โดยมีการประเมินความสามารถของโมเดลภาษาขนาดใหญ่ (LLMs) จำนวน 2 โมเดล คือ 1) deepseek-r1 และ 2) command-r7b ซึ่งทั้งคู่มีพารามิเตอร์จำนวน 7 พันล้านตัว (7B)

เอกสาร PLCnext ที่ถูกฝึกและใช้งานในระบบ RAG มีข้อมูลสำคัญที่เชื่อมโยงรูปแบบไฟแสดงสถานะ LED กับสถานะของอุปกรณ์ โดยมีการให้ความหมายของสถานะเหล่านั้น จากการฝึกและผสมเอกสารทางเทคนิคของ PLCnext นี้เข้ากับ LLMs ส่งผลให้แชทบอทที่พัฒนาขึ้นนี้ สามารถตีความหมายของสถานะ LED ที่จับภาพได้อย่างแม่นยำและสามารถให้คำแนะนำในการแก้ไขปัญหาที่เกี่ยวข้องแก่ผู้ปฏิบัติงานได้ในเวลาจริง

นอกจากนั้น เรายังมีการทดสอบประสิทธิภาพของทั้ง 2 โมเดลและพบว่า โมเดล command-r7b มีประสิทธิภาพเหนือกว่าโมเดล deepseek-r1 อย่างมีนัยสำคัญเมื่อนำไปใช้ภายในกรอบการทำงานของ RAG ที่ใช้เอกสาร PLCnext ซึ่งโมเดล command-r7b แสดงความสามารถที่เหนือกว่าในการสร้างคำตอบสำหรับการตอบสนองที่ถูกต้องตามข้อเท็จจริงและเหมาะสมตามบริบท และยังตอบสนองในเวลาที่ดีกว่าและรวดเร็วกว่าในระหว่างการทดสอบการทำงาน

3.5 การวิเคราะห์และออกแบบระบบ

3.5.1 การออกแบบ Use Case Diagram



ภาพที่ 7 การออกแบบ Use Case Diagram

ภาพที่ 7 แสดงให้เห็นระบบส่วนติดต่อระหว่างมนุษย์และเครื่องจักร (Human-Machine Interface) ที่ซับซ้อน ซึ่งผสมผสานเทคโนโลยีแชทบอทที่ขับเคลื่อนด้วยปัญญาประดิษฐ์เข้ากับแพลตฟอร์มระบบ ซ่อมบำรุงที่ใช้ตัวอย่างของอุปกรณ์ PLCnext เป็นข้อมูลพื้นฐาน โดยเป็นตัวอย่างที่สำคัญของการประยุกต์ใช้เทคโนโลยีอุตสาหกรรม 4.0

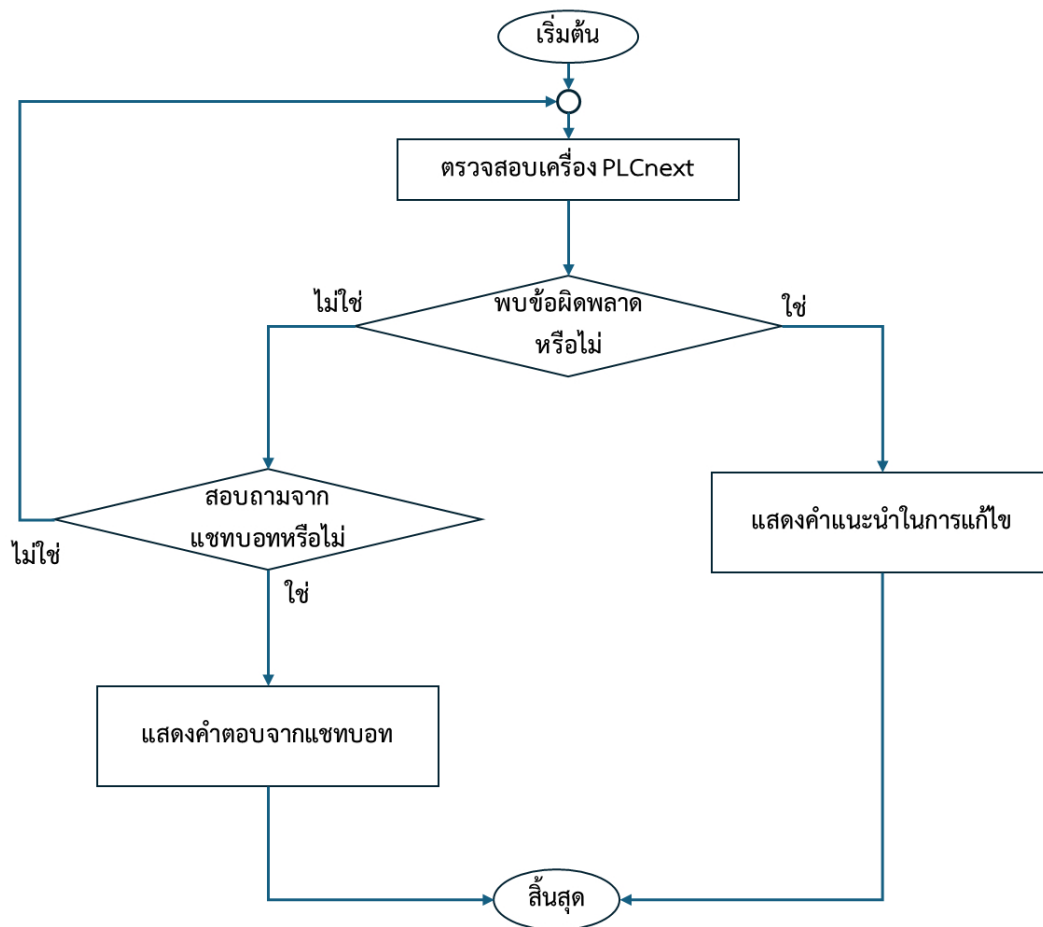
ผู้ใช้งานซึ่งเป็นตัวแสดงหลัก (Actor) สามารถโต้ตอบกับ use case ที่แตกต่างกัน 5 รายการ โดย UC01 (แสดงหน้าต่างแชทบอท) และ UC02 (ซ่อนหน้าต่างแชทบอท) สร้างขึ้นส่วนติดต่อพื้นฐาน ทำให้เกิดการโต้ตอบที่ราบรื่นระหว่างผู้ปฏิบัติงานและระบบซ่อมบำรุงฯ โดยจะมีปุ่มที่สลับการทำงานในกรณีที่ผู้ใช้งานต้องการให้มีการเปิดหน้าต่างหรือปิดหน้าต่างแชทบอท ซึ่งในขณะที่ปฏิบัติงานอาจจะมีพื้นที่ที่ต้องการการมองเห็นที่ชัดเจน ดังนั้น หน้าต่างแชทบอทนี้ จึงออกแบบมาให้สามารถเปิดหรือปิดได้ตามความต้องการ

UC03 (เพิ่มข้อความสนทนา) เป็นกรณีที่อำนวยความสะดวกในการสื่อสารสองทิศทาง ช่วยให้ผู้ปฏิบัติงานสามารถป้อนคำถาม คำสั่ง หรือคำขอสถานะผ่านการประมวลผลภาษาธรรมชาติได้ ซึ่งข้อมูลที่แสดงนั้น จะเป็นข้อมูลที่เกิดจากการทำ RAG ร่วมกับโมเดล commad-r7b ที่ได้รับการปรับปรุงให้มีความรู้เพิ่มเติมเฉพาะในส่วน of ข้อมูล PLCnext ซึ่งจะช่วยให้ผู้ปฏิบัติงานสามารถได้รับข้อมูลที่ตรงกับความต้องการ ณ ขณะนั้นมากที่สุด และ UC04 (ดูคำแนะนำในการแก้ปัญหา) จะเป็นการดูหรือรับทราบข้อแนะนำจากแชทบอทที่สามารถดำเนินการตามได้อย่างเป็นขั้นตอน

UC05 (ตรวจสอบเครื่อง PLCnext) เป็นการตรวจสอบหาข้อผิดพลาดของเครื่องจักรโดยการวิเคราะห์ภาพที่ได้จากกล้องของแว่น HoloLens 2 ซึ่งภาพที่อ่านจากกล้องของแว่น HoloLens 2 จะถูกส่งไปประมวลผลด้วยโมเดล Object Detection ที่ได้รับการเทรนนิ่งเมื่อก่อนหน้านี้ เพื่อวินิจฉัยว่า ข้อผิดพลาดที่เกิดขึ้นนั้นคืออะไร และจะมีการแนะนำวิธีการแก้ปัญหาให้กับผู้ใช้งานด้วย

3.5.2 ขั้นตอนการทำงานของระบบ Remote Expert System

ในการประยุกต์ใช้งานเทคโนโลยีความเป็นจริงเสริม (AR) และเทคโนโลยีปัญญาประดิษฐ์ (AI) นั้น เราได้ทำการพัฒนาระบบ Remote Expert System ขึ้นมาเพื่อให้บริการและสนับสนุนผู้ปฏิบัติงานด้านซ่อมบำรุงในโรงงานอุตสาหกรรมอัตโนมัติ โดยระบบนี้จะช่วยให้ผู้ปฏิบัติงานด้านการซ่อมบำรุงในอุตสาหกรรมอัตโนมัติไม่จำเป็นต้องติดต่อผู้เชี่ยวชาญเฉพาะด้านเพื่อขอคำแนะนำในการซ่อมบำรุงอุปกรณ์ที่มีความซับซ้อนหรืออุปกรณ์ขั้นสูง โดยระบบจะใช้ NLP ที่ได้รับการพัฒนาและเสริมความรู้ด้วย RAG ในการช่วยเหลือผู้ปฏิบัติงานนั้น และในภาพรวมของการทำงาน สามารถดูได้จากภาพที่ 8



ภาพที่ 8 Flowchart การทำงานในภาพรวมของระบบ Remote Expert System

จากภาพที่ 8 กระบวนการเริ่มต้นด้วยการ "ตรวจสอบเครื่อง PLCnext" ซึ่งเป็นขั้นตอนพื้นฐานของระบบ Remote Expert System ที่มีความสำคัญต่อการบำรุงรักษาเชิงพยากรณ์ ที่การผสมผสานการทำงานของ AI เข้ากับระบบควบคุมช่วยให้สามารถตัดสินใจแบบเรียลไทม์ได้ เมื่อมีการรับภาพเข้ามา จะมาที่จุดตัดสินใจแรก "พบข้อผิดพลาดหรือไม่" เป็นขั้นตอนสำคัญที่แสดงความสามารถในการวิเคราะห์และตรวจจับความผิดปกติ หากพบข้อผิดพลาด ระบบจะดำเนินการต่อไปยัง "แสดงคำแนะนำในการแก้ไข" ซึ่งเป็นฟีเจอร์ที่แสดงถึงความสามารถของระบบในการให้คำปรึกษาเชิงป้องกันได้ แต่ถ้าหากไม่พบข้อผิดพลาด ระบบจะเข้าสู่จุดตัดสินใจที่สอง "สอบถามจากช่างบอทหรือไม่" ซึ่งเป็นการสอบถามจากผู้ใช้หากต้องการความช่วยเหลือจากระบบช่างบอท AI หรือไม่ การออกแบบนี้แสดงให้เห็นถึงการให้ทางเลือกแก่ผู้ใช้ในการเข้าถึงข้อมูลและคำแนะนำผ่านส่วนติดต่อที่เป็นธรรมชาติ โดยเนื้อหาที่แสดงนี้ ได้รับการปรับปรุงให้เป็นเนื้อหาเฉพาะสำหรับการบำรุงรักษาเครื่อง PLCnext ด้วยวิธีการ RAG ตามที่ได้กล่าวมาแล้ว เมื่อผู้ใช้เลือกใช้บริการช่างบอท ระบบจะดำเนินการ "แสดงคำตอบจากช่างบอท" ซึ่งเป็นการให้บริการแบบ interactive support ที่ช่วยให้ผู้ปฏิบัติงานได้รับการช่วยเหลือตามบริบทที่เป็นอยู่

การทำงานนี้จะลูบการดำเนินงานกลับไปยังการตรวจสอบเริ่มต้น แสดงให้เห็นถึงลักษณะการทำงานแบบต่อเนื่อง (continuous monitoring) ซึ่งเป็นหลักการสำคัญของระบบอุตสาหกรรม 4.0 ซึ่งการใช้เทคนิค AI ช่วยในการทำงานในตลอดวงจรชีวิตของอุปกรณ์อุตสาหกรรมนั้น ช่วยในการเพิ่มประสิทธิภาพการควบคุมกระบวนการในภาพรวม อำนวยความสะดวกในการตัดสินใจ และยกระดับกลยุทธ์การบำรุงรักษาในอุตสาหกรรมอัตโนมัติได้

4 ผลการดำเนินการ

4.1 ประสิทธิภาพของโมเดล (Model Performance Metrics)

โมเดล YOLOv8s ที่พัฒนาขึ้นสำหรับระบบผู้เชี่ยวชาญระยะไกลด้วย AI (AI-driven Remote Expert System) ที่นำเสนอนี้ ได้แสดงประสิทธิภาพการตรวจจับที่โดดเด่นในทุกหมวดหมู่ตามการจำแนกเป้าหมายที่กำหนด โดยหลังจากการฝึกโมเดลที่ 300 epochs นั้น โมเดลได้บรรลุประสิทธิภาพโดยรวมที่น่าพึงพอใจเป็นอย่างมาก โดยมีค่า recall และ precision ที่สูงมาก ซึ่งเป็นคุณลักษณะหลักที่จำเป็นสำหรับการพัฒนาระบบตรวจสอบและรู้จำในอุตสาหกรรมอัตโนมัติที่เชื่อถือได้

ตารางที่ 1 ประสิทธิภาพของโมเดล YOLOv8s แยกตามคลาส

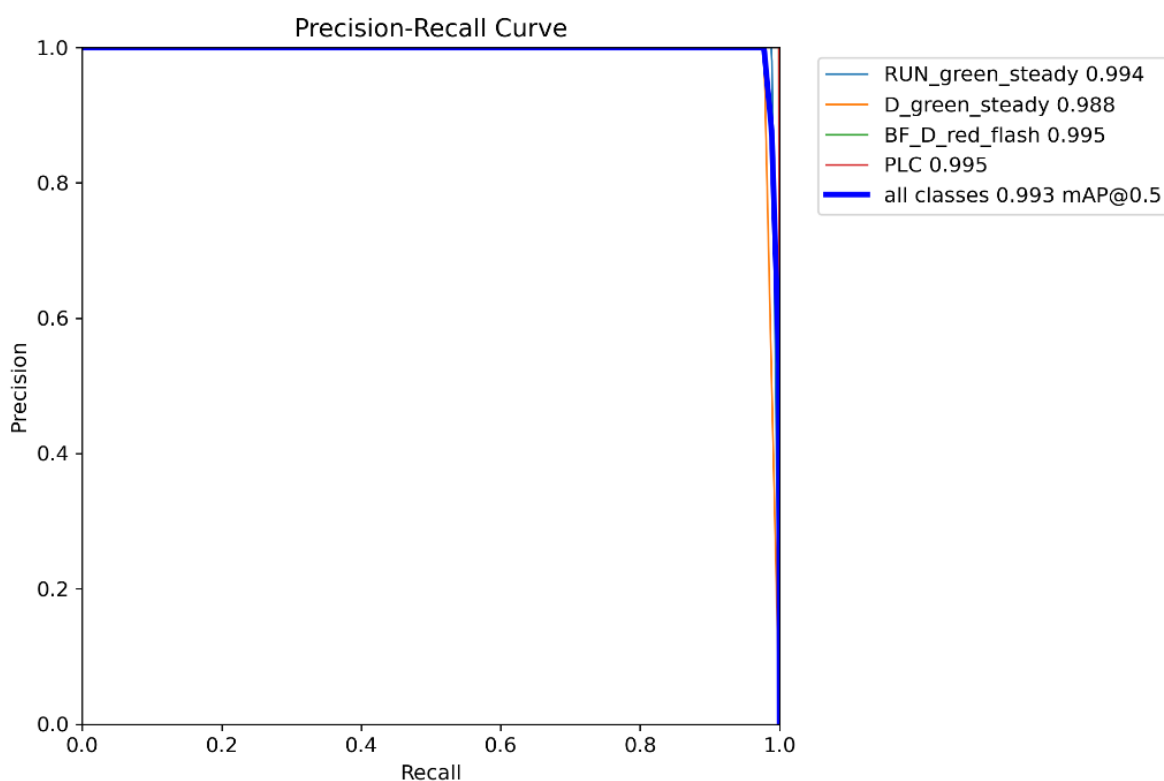
คลาส	ภาพ	ตัวอย่าง	Precision	Recall	mAP50	mAP50-95
RUN_green_steady	178	178	1.0	0.966	0.994	0.795
D_green_steady	178	178	1.0	0.965	0.988	0.773
BF_D_red_flash	85	85	0.993	1.0	0.995	0.814
PLC	178	178	0.995	1.0	0.995	0.995
Overall	178	619	0.997	0.983	0.993	0.844

ตามที่แสดงในตารางที่ 1 จะพบว่าโมเดลบรรลุค่า mean Average Precision (mAP50) = 0.993 ในทุกคลาสที่จำแนก ซึ่งแสดงถึงความแม่นยำในการตรวจจับที่มีประสิทธิภาพ โดยมีค่า Intersection over Union (IoU) = 50% และค่า mAP50-95 ที่ 0.844 ซึ่งยืนยันประสิทธิภาพของโมเดลนี้ จากตารางจะเห็นว่า จุดที่เป็นที่น่าสังเกตคือ คลาส BF_D_red_flash มีคะแนน recall ที่มีประสิทธิภาพสูงสุดแม้จะมีตัวอย่างภาพของการฝีกน้อยกว่า ซึ่งคุณลักษณะของประสิทธิภาพนี้มีความสำคัญอย่างยิ่ง เนื่องจากคลาสนี้แสดงถึงเงื่อนไขข้อผิดพลาดที่เกิดขึ้นกับเครื่อง PLCnext และต้องได้รับความใส่ใจทันทีในการแก้ไขจากผู้ปฏิบัติงาน

ตารางที่ 2 ความแม่นยำในการจำแนกของโมเดล YOLOv8s แยกตามคลาส

คลาส	ความแม่นยำในการจำแนกประเภท	จำแนกผิดเป็นพื้นหลัง
RUN_green_steady	0.96	0.04
D_green_steady	0.95	0.05
BF_D_red_flash	0.99	0.01
PLC	1.00	0

ตารางที่ 2 แสดงความแม่นยำในการจำแนกของโมเดล AI ในทุกคลาสเป้าหมายที่กำหนด โดยค่าความแม่นยำสูง (0.95 - 1.00) แสดงให้เห็นถึงประสิทธิภาพการจำแนกที่สูงโดยมีการจำแนกผิดพลาดน้อยมาก ซึ่งคลาส PLC บรรลุความแม่นยำในการจำแนกที่มีประสิทธิภาพสูงสุด (1.00) ในขณะที่การจำแนกไฟแสดงสถานะ LED แสดงประสิทธิภาพที่สูงโดยมีการจำแนกผิดพลาดน้อยที่สุด (0.01 - 0.05) เมื่อเทียบกับการตรวจจับพื้นหลัง



ภาพที่ 9 เส้นโค้ง Precision-Recall สำหรับทุกคลาส

ภาพที่ 9 แสดงกราฟ Precision-Recall สำหรับหมวดหมู่ในการจำแนกทั้งหมด ซึ่งแสดงให้เห็นถึงความสามารถของโมเดลในการรักษาค่าความแม่นยำสูงแม้ในระดับการ Recall ที่สูง โดยดูได้จากโปรไฟล์ที่เกือบเป็นรูปสี่เหลี่ยมผืนผ้าของกราฟเหล่านี้ โดยเฉพาะอย่างยิ่งที่เห็นได้ชัดในคลาส PLC (เส้นสีแดง) แสดงให้เห็นว่าโมเดลรักษาความแม่นยำสูงอย่างสม่ำเสมอตลอดทั้งการทำงานของ Recall ซึ่งคุณลักษณะประสิทธิภาพนี้มีความสำคัญอย่างยิ่งในการใช้งานในอุตสาหกรรม ซึ่งการตรวจจับทั้ง false positive และ false negative อาจนำไปสู่การแนะนำวิธีการบำรุงรักษาที่ไม่เหมาะสมและก่อให้เกิดความเสียหายได้

4.2 ความแม่นยำในการตรวจจับแบบเรียลไทม์ (การทดสอบภาคสนาม)

ในส่วนของการวัดผลนั้น เราประเมินประสิทธิภาพของโมเดล AI ผ่านการใช้งานบนอุปกรณ์ HoloLens 2 ที่มีระยะห่างของการทำงาน 2 ระยะจากอุปกรณ์ PLCnext คือ 1) ระยะใกล้ (ประมาณ 0.2 เมตร) และ 2) ระยะไกล (ประมาณ 1 เมตร) โดยมีการทดสอบระบบที่เป็นการทดสอบการตรวจจับไฟแสดงสถานะ LED ที่สำคัญสามชนิด ได้แก่ RUN_green_steady, D_green_steady และ BF_D_red_flash ซึ่งไฟแสดงสถานะเหล่านี้แสดงถึงสถานะการทำงานปกติและสถานะที่มีข้อผิดพลาดซึ่งเป็นเงื่อนไขที่จำเป็นสำหรับการใช้งานในการวินิจฉัยข้อผิดพลาดในงานอุตสาหกรรม

4.2.1 ประสิทธิภาพการตรวจจับที่ 2 ระยะ

ในการตรวจจับที่ระยะใกล้ (ตามที่แสดงในตารางที่ 3) โมเดล AI แสดงความสามารถในการตรวจจับที่ประสิทธิภาพสูงสุด (ความแม่นยำ 100%) โดยตรวจจับไฟสีเขียวแสดงสถานะแบบนิ่งทั้ง 2 ตัว คือ RUN และ D แต่ในการตรวจจับไฟสีแดงที่กะพริบนั้น ถือเป็นความท้าทายอย่างมากในการตรวจจับอย่างต่อเนื่อง โดยประสบความสำเร็จได้ความแม่นยำเพียงแค่ 59% เท่านั้น ซึ่งความแตกต่างในประสิทธิภาพนี้ คาดว่าน่าจะมาจากลักษณะของไฟสีแดงที่กะพริบตามจังหวะเวลา ที่มีผลต่อการตรวจจับแบบเฟรมต่อเฟรม (frame by frame) ที่โดยธรรมชาติแล้วจะมีความซับซ้อนยิ่งขึ้น

สำหรับการตรวจจับในระยะไกลนั้น พบว่าประสิทธิภาพการตรวจจับจะลดลงที่ระยะทางที่ไกลขึ้น ดังแสดงในตารางที่ 4 โดยมีความแม่นยำของ RUN_green_steady ลดลงเหลือ 85.7% เท่านั้น ในขณะที่ความแม่นยำในการตรวจจับ D_green_steady ลดลงเหลือ 76.7% ซึ่งตรงกันข้ามกับความคาดหวัง และการตรวจจับ BF_D_red_flash มีการเปลี่ยนแปลงเล็กน้อยเป็น 62.0% ที่ระยะทางไกลขึ้น โดยความแตกต่างในด้านประสิทธิภาพที่ระยะห่างของการมองที่ต่างกันนี้ อาจเป็นผลมาจากความซับซ้อนของภาพที่มากขึ้นในเฟรมระยะไกลหรือการเปลี่ยนแปลงลักษณะของรูปภาพในการกะพริบของไฟ LED ในระยะไกลก็เป็นได้

ตารางที่ 3 Confusion Matrix ในการตรวจจับระยะใกล้

ตัวระบุสถานะ	True Negative	False Positive	False Negative	True Positive	Accuracy
RUN_green_steady	0	0	0	300	100%
D_green_steady	0	0	0	300	100%
BF_D_red_flash	85	68	55	92	59%

ตารางที่ 4 Confusion Matrix ในการตรวจจับระยะไกล

ตัวระบุสถานะ	True Negative	False Positive	False Negative	True Positive	Accuracy
RUN_green_steady	0	0	43	257	85.7%
D_green_steady	0	0	70	230	76.7%
BF_D_red_flash	100	46	68	86	62%

4.2.2 ผลกระทบของความล่าช้าของระบบต่อประสิทธิภาพการตรวจจับ


ความล่าช้าสะสมตลอดทั้งระบบ (system-wide delay) เป็นหนึ่งในปัจจัยสำคัญที่ส่งผลต่อคุณภาพการตรวจจับแบบเรียลไทม์ ในการจับภาพจากกล้องของแว่น HoloLens 2 ที่มีความซับซ้อน ไปจนถึงการแสดงผลความเป็นจริงเสริม (AR) ทำให้เกิดความล่าช้าของระบบสะสมที่ประมาณ 220 - 280 มิลลิวินาที แม้ว่าความล่าช้านี้จะยังคงยอมรับได้สำหรับแอปพลิเคชันความเป็นจริงเสริมทั่วไป แต่มันลดคุณภาพการตรวจจับอย่างมากในสถานการณ์ที่เกี่ยวข้องกับไฟแสดงที่กะพริบที่มีการเคลื่อนไหวหรือปรับเปลี่ยนตลอดเวลา เนื่องจากเฟรมของรูปภาพที่จับได้ในช่วงเวลานั้น ๆ อาจไม่ตรงกับสถานะของไฟ LED จริงก็เป็นได้ ปัจจัยความล่าช้านี้ช่วยอธิบายเหตุผลได้ว่าทำไมไฟแสดงสถานะที่นิ่งจึงมีประสิทธิภาพเหนือกว่าไฟแสดงที่กะพริบในการทดสอบที่ผ่านมา ไฟแสดงสถานะที่นิ่งมีสถานะคงที่ซึ่งช่วยให้การตรวจจับมีความแม่นยำสูงมาก โดยไม่ต้องคำนึงถึงผลกระทบที่ภาพของไฟ LED จะมีผลในการประมวลผล

4.3 การวิเคราะห์ประสิทธิภาพของฮาร์ดแวร์

4.3.1 การใช้แบตเตอรี่ของ HoloLens 2

ในระหว่างการทดสอบประสิทธิภาพของระบบ AI-driven Remote Expert System นี้ เราสังเกตเห็นความแตกต่างอย่างมีนัยสำคัญในการใช้พลังงานเมื่อเปรียบเทียบการสตรีมวิดีโอแบบ stand alone กับการทำงานของระบบเต็มรูปแบบบน HoloLens 2 โดยในการใช้งานแบบเต็มรูปแบบนั้น มีการใช้พลังงานเพิ่มขึ้นในอัตราประมาณ 8% ต่อ 10 นาทีของการใช้งานอย่างต่อเนื่อง และในทางกลับกัน เมื่อใช้เฉพาะฟังก์ชันการสตรีมวิดีโอ การใช้พลังงานเพิ่มขึ้นในอัตราที่ต่ำกว่าที่ประมาณ 6% ต่อ 10 นาทีเท่านั้น การทดสอบนี้ เผยให้เห็นถึงความสัมพันธ์ระหว่างระยะเวลาการทำงาน อุณหภูมิของอุปกรณ์ และการใช้พลังงาน ที่มีความสัมพันธ์กันอย่างมีนัยสำคัญ โดยเมื่อ HoloLens 2 ถูกใช้งานเป็นเวลานาน อุณหภูมิของอุปกรณ์จะเพิ่มขึ้น ซึ่งสอดคล้องกับอัตราการใช้พลังงานที่เพิ่มขึ้นด้วย


4.3.2 เมตริกการใช้งาน CPU



ภาพที่ 10 การใช้งาน CPU ของ HoloLens 2 ในช่วงเวลา 5 นาที

ภาพที่ 10 แสดงการใช้งาน CPU ของอุปกรณ์แว่น HoloLens 2 ในช่วงการทำงาน 5 นาทีในขณะที่ใช้งานระบบ AI-driven Remote Expert System โดยการใช้งาน CPU นั้น มีความผันผวนอย่างมากตลอดช่วงระยะเวลาการทำงานของระบบนี้ โดยมีจุดสูงสุดที่เหนือ 5.5% ในบางช่วงเวลาของการทำงาน ซึ่งการใช้งาน CPU โดยเฉลี่ยจะอยู่ในช่วง 3 - 4% เป็นหลัก ซึ่งแสดงถึงภาระการประมวลผลขนาดปานกลางบนอุปกรณ์ฮาร์ดแวร์ของ HoloLens 2 โดยจุดสูงสุดของการใช้งาน CPU ที่สังเกตเห็นบนกราฟนั้นสามารถอธิบายได้ว่าเป็นกรณีของการคำนวณประมวลผลที่เข้มข้น โดยเฉพาะอย่างยิ่งเมื่อโมดูลการรู้จำภาพเพื่อตรวจสอบข้อผิดพลาดของอุปกรณ์ PLCnext มีการประมวลผลข้อมูลอย่างเต็มประสิทธิภาพ เพื่อจดจำและระบุสถานะการทำงานของอุปกรณ์ PLCnext และนำเสนอวิธีการแก้ไขนั่นเอง

4.3.3 เมตริกการใช้หน่วยความจำ




ภาพที่ 11 การใช้งานหน่วยความจำของ HoloLens 2 ในช่วงเวลา 5 นาที

ภาพที่ 11 แสดงโปรไฟล์การใช้หน่วยความจำของอุปกรณ์ HoloLens 2 โดยแสดงให้เห็นถึงการจัดสรรหน่วยความจำอย่างมีประสิทธิภาพ โดย "Non-Paged Pool Commit" คงที่ต่ำกว่า 950 MB อย่างสม่ำเสมอ และ "Standby Lists (Total)" ต่ำกว่า 300 MB เล็กน้อย นอกจากนี้ "Total Physical Memory" ยังแสดงการใช้งานอย่างคงที่ตลอดช่วงระยะเวลาการทดสอบ การวิเคราะห์นี้แสดงให้เห็นว่า แอปพลิเคชัน AI-driven Remote Expert System นี้ ใช้หน่วยความจำที่มากในจำนวนหนึ่งแต่มีการจัดการอย่างมีประสิทธิภาพ การประเมินการใช้งานฮาร์ดแวร์แสดงให้เห็นถึงอัตราการใช้แบตเตอรี่ที่เพิ่มขึ้นเมื่อใช้งานเต็มระบบ โดยการทำงานที่รักษาเสถียรภาพของการใช้งานหน่วยความจำนี้ ส่งผลให้ระบบสามารถทำงานได้อย่างต่อเนื่อง โดยไม่มีการใช้งานทรัพยากรที่เกินกำลังของฮาร์ดแวร์ที่อาจจะนำไปสู่การล่มของระบบได้

4.4 ผลลัพธ์การทำงานของระบบ AI-driven Remote Expert System

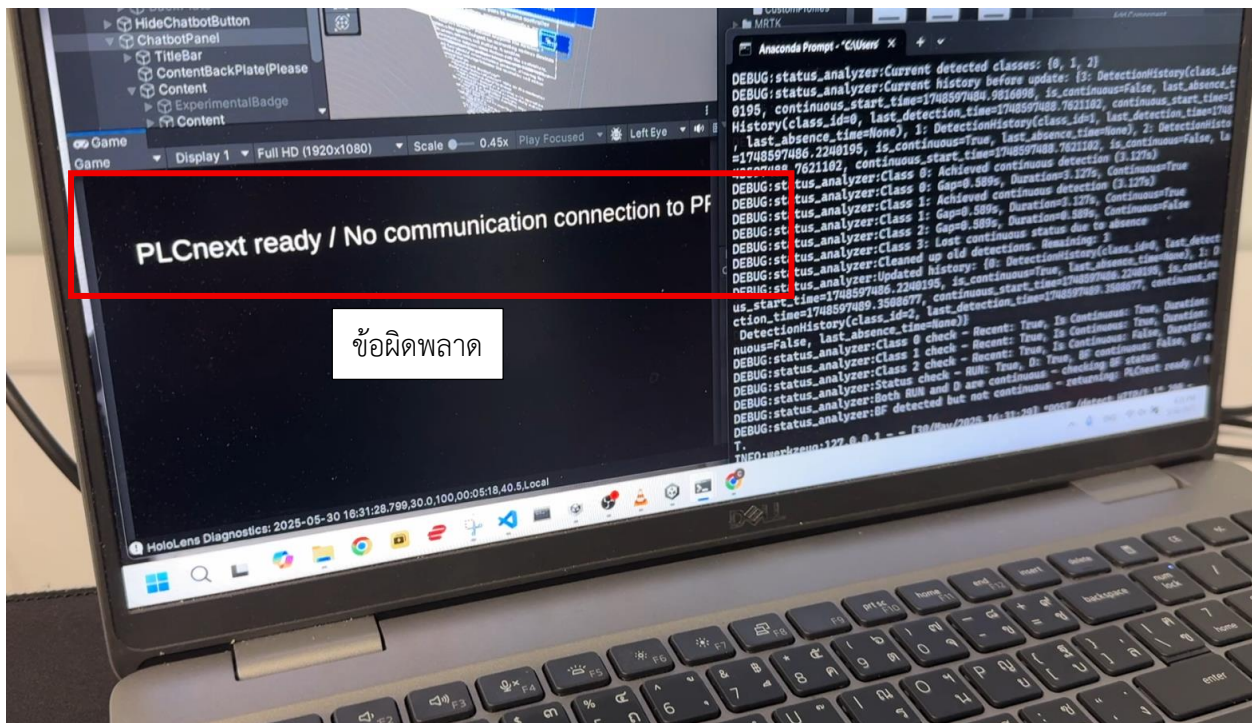
ในการทดสอบการทำงานของระบบ AI-driven Remote Expert System นั้น มีการทดสอบในห้องปฏิบัติการ โดยมีการทดสอบการตรวจจับอุปกรณ์ PLCnext เพื่อวิเคราะห์และตรวจหาข้อผิดพลาดที่เกิดขึ้นกับอุปกรณ์ และนำเสนอวิธีการแก้ปัญหาแบบเฉพาะเจาะจงกับข้อผิดพลาดนั้น ๆ ตามบริบทของการใช้งาน



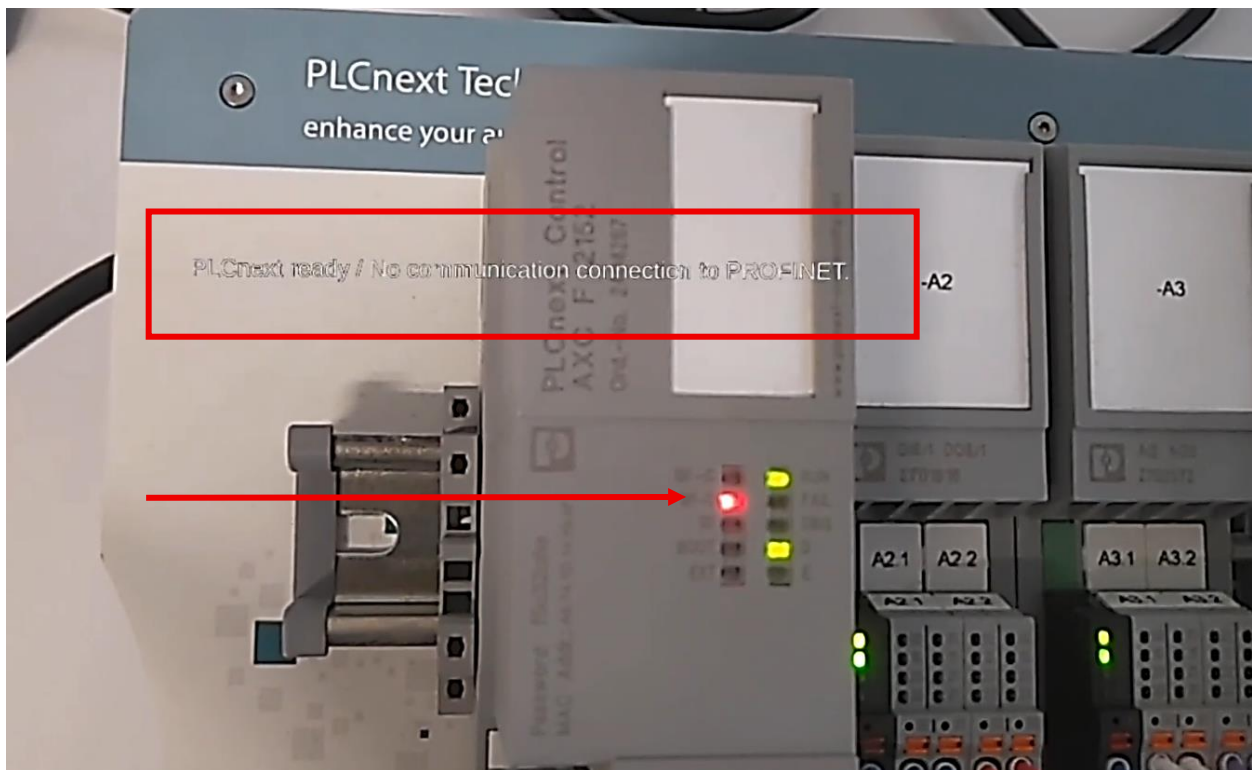
ภาพที่ 12 ภาพรวมการทดสอบระบบฯ

จากภาพที่ 12 ผู้ทดสอบทำการสวมใส่อุปกรณ์แว่น HoloLens 2 เพื่อเข้าสู่ระบบ AI-driven Remote Expert System โดยระบบจะมีการสตรีมวิดีโอไปยังเครื่องคอมพิวเตอร์และมีการประมวลผลเพื่อตรวจหา

ข้อผิดพลาดที่อาจเกิดขึ้นกับเครื่อง PLCnext ได้ พร้อมทั้งนำเสนอข้อเสนอแนะในการแก้ปัญหา โดยในภาพ ผู้ทดสอบได้ใช้แว่น HoloLens 2 มองเครื่อง PLCnext ที่ระยะห่างประมาณ 30 เซนติเมตร ซึ่งเป็นระยะปกติที่ใช้ในการทำงานซ่อมบำรุงในโรงงานอุตสาหกรรม และเมื่อมีการรู้จำข้อผิดพลาด ก็จะมีการแนะนำให้โดยอัตโนมัติ



(ก)




(ข)

ภาพที่ 13 เมื่อระบบตรวจสอบเจอข้อผิดพลาด

จากภาพที่ 13 ระบบ AI-driven Remote Expert System ตรวจพบข้อผิดพลาดคือ

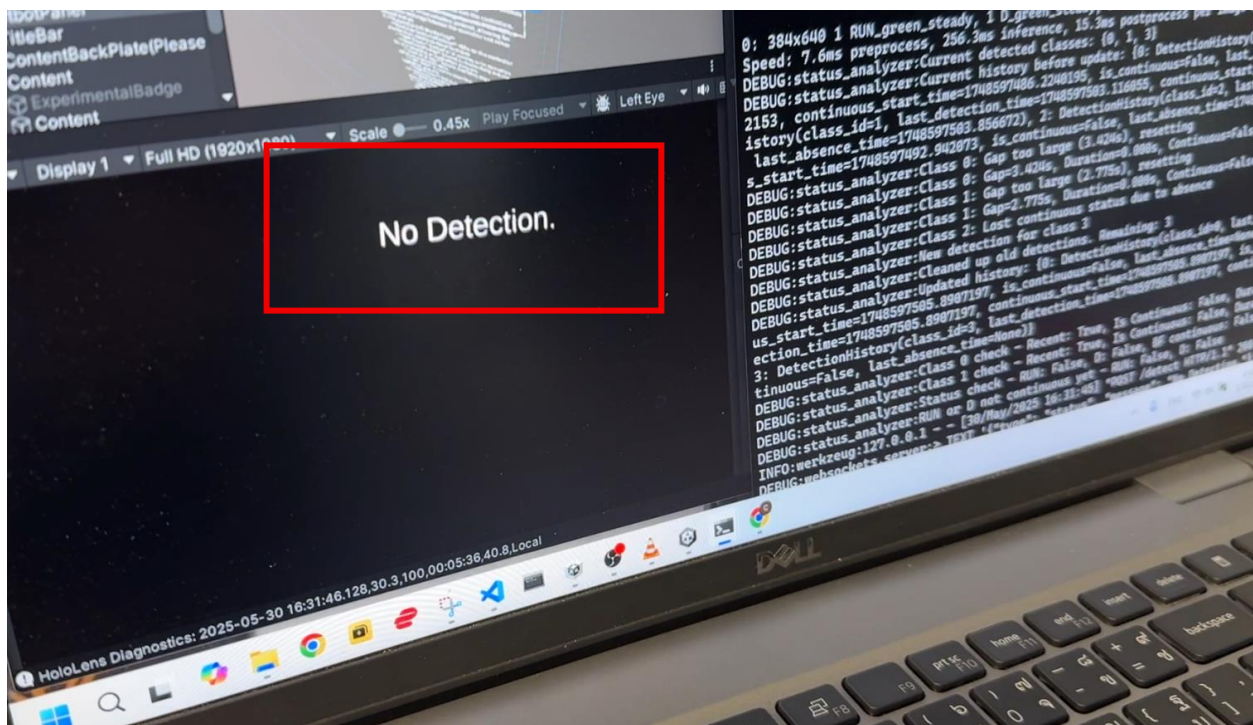
- 1) PLCnext ready หมายถึง เครื่อง PLCnext ทำงานปกติ
- 2) No communication connection to PROFINET คือ ไม่มีการเชื่อมต่อไปยังอุปกรณ์ PROFINET

แนวทางในการแก้ปัญหาของการทำงานนี้คือ การเชื่อมต่อสายเคเบิลสำหรับการสื่อสารกับอุปกรณ์ PROFINET ซึ่งแสดงในภาพที่ 14

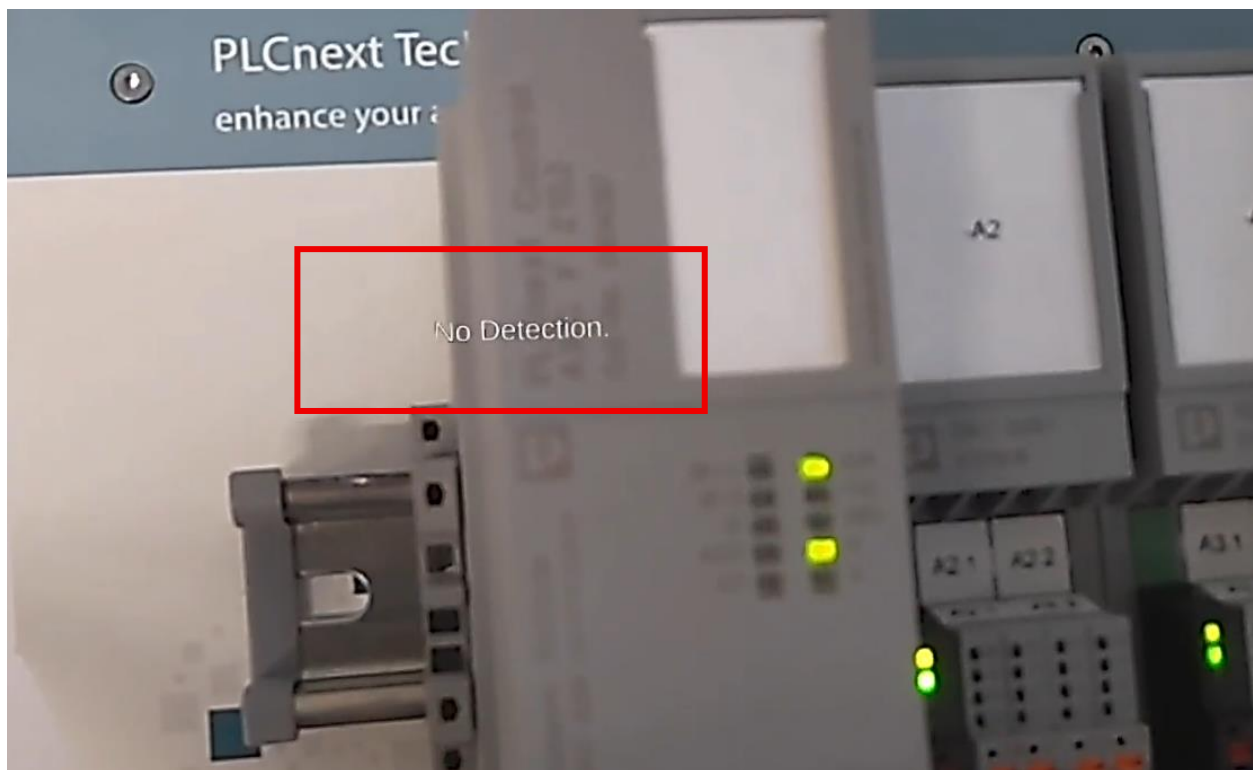


ภาพที่ 14 ตัวอย่างแนวทางในการแก้ปัญหา

ซึ่งเมื่อดำเนินการแก้ปัญหาตามที่แนะนำไปแล้ว ระบบ AI-driven Remote Expert System ก็จะตรวจไม่พบข้อผิดพลาดนั้นอีก ดังแสดงในรูปที่ 15



(ก)



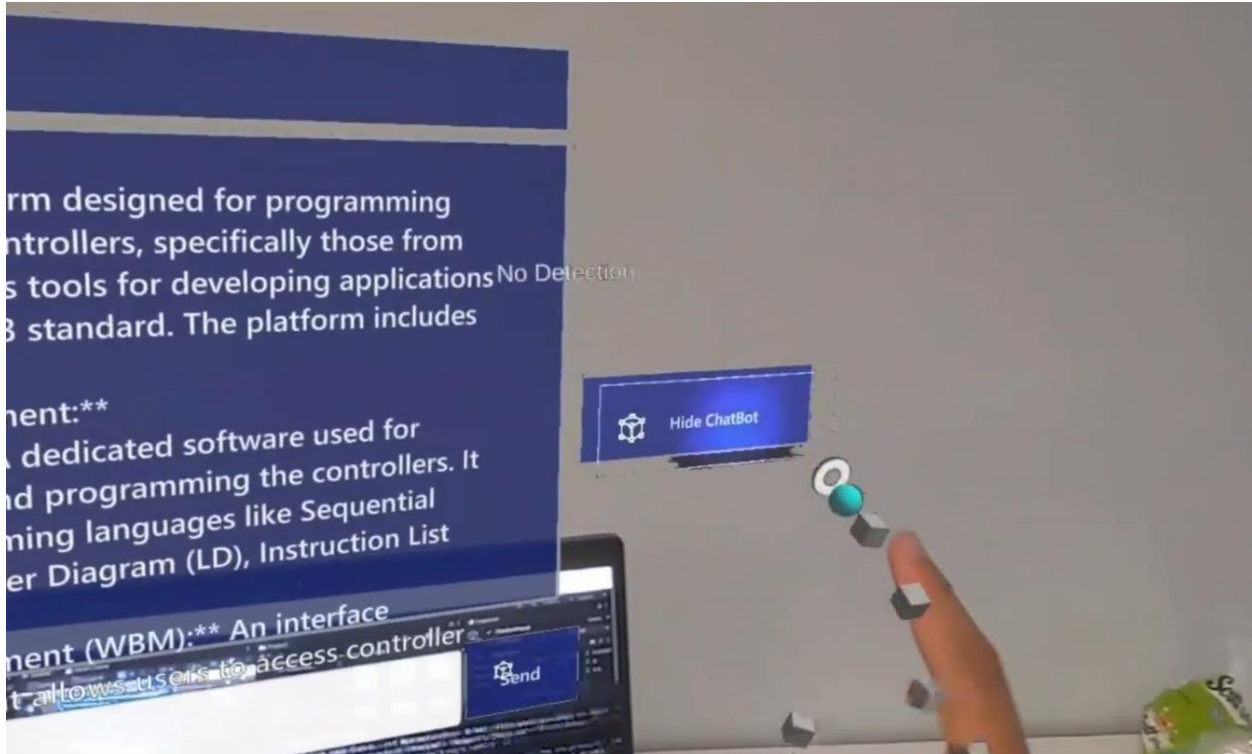
(ข)

ภาพที่ 15 แสดงการตรวจไม่พบข้อผิดพลาด

ในส่วนของการทำงานของระบบที่มีการสนทนากับแชทบอทนั้น ผู้ใช้งานจะมองเห็นปุ่มสำหรับการเปิด/ปิดหน้าต่างสำหรับการสนทนา ซึ่งจะสามารถเปิดหรือปิดหน้าต่างนี้ได้ เพื่อความสะดวกในการปฏิบัติงาน ที่บางครั้งจะต้องดูภาพที่หน้าจออย่างชัดเจนโดยไม่มีหน้าต่างของการสนทนาบดบังวิสัยการทำงาน ภาพที่ 16 แสดงการใช้งานปุ่มสำหรับการเปิด/ปิดหน้าต่างสนทนาดังกล่าว



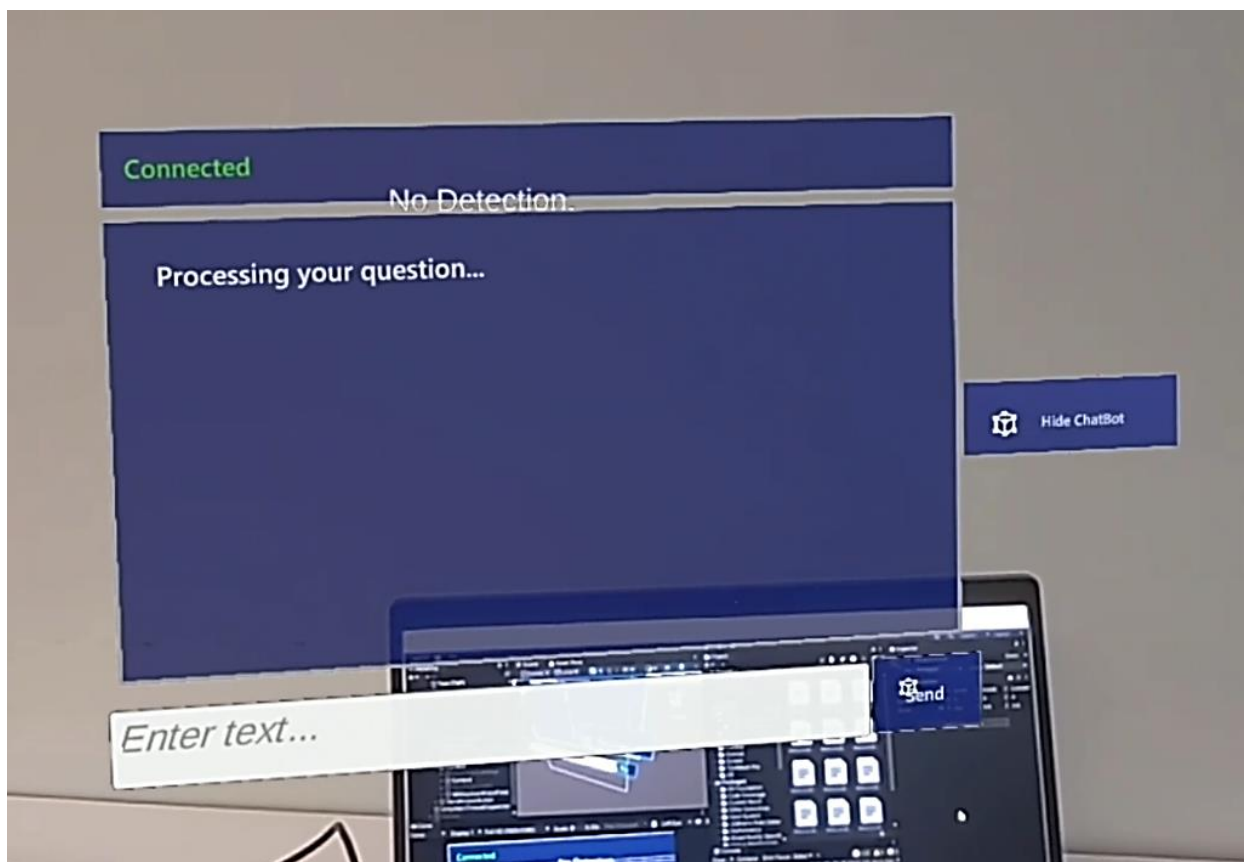
(ก)



(ข)

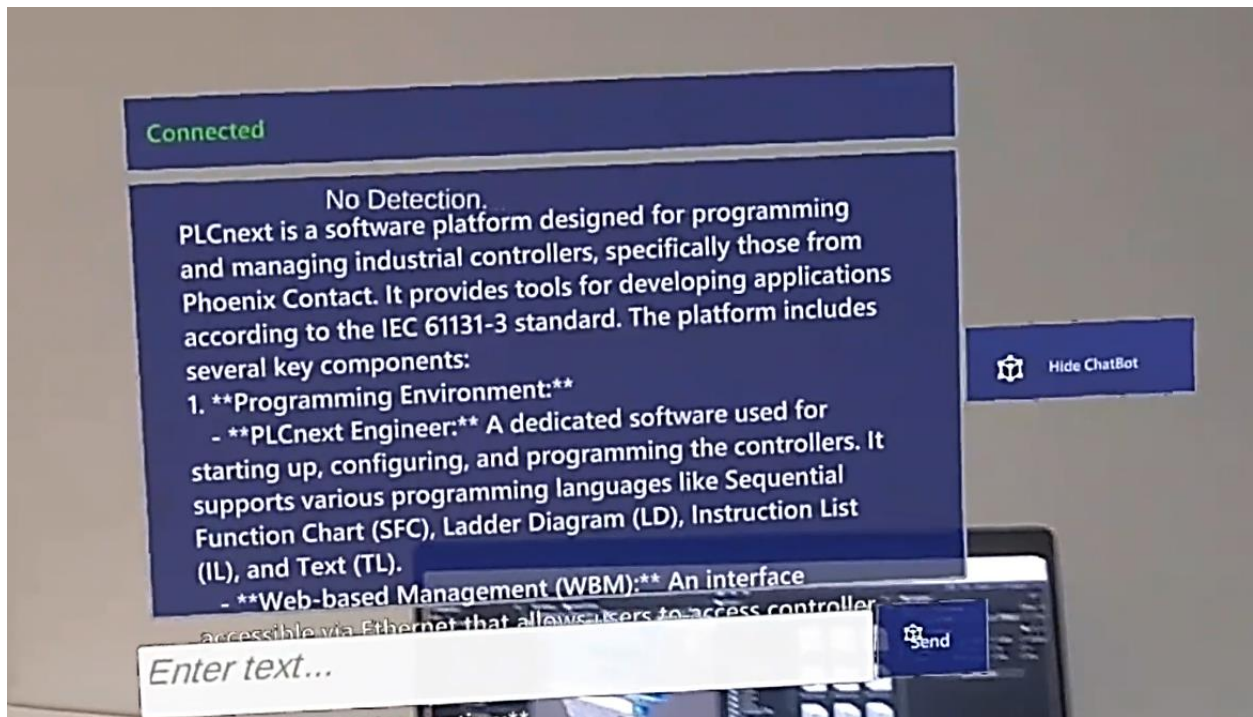
ภาพที่ 16 ปุ่มสำหรับการเปิด (ก)/ปิด (ข) หน้าต่างสนทนาของแชทบอท

เมื่อผู้ใช้งานกดปุ่มเปิดหน้าต่างสนทนากับแชทบอทขึ้นมาแล้ว จะปรากฏหน้าต่างสนทนา โดยผู้ใช้งานสามารถพิมพ์คำถามที่ต้องการลงไปในช่วงใส่คำถามที่อยู่ด้านล่างของหน้าต่าง และจะได้รับคำแนะนำที่ด้านบนของหน้าต่าง ดังแสดงในรูปที่ 17



ภาพที่ 17 ภาพหน้าต่างสนทนากับแชทบอท

เมื่อผู้ใช้งานใส่คำถามเข้าไปในช่องใส่คำถาม ก็จะมีการแสดง คำตอบที่เป็นข้อเสนอแนะในการแก้ปัญหาเฉพาะทางสำหรับการซ่อมบำรุงเครื่อง PLCnext โดยข้อมูลสามารถเพิ่มเติมได้สำหรับอุปกรณ์หรือเครื่องจักรชนิดอื่น ซึ่งจะต้องใช้กระบวนการ RAG ในการเพิ่มเติมข้อมูลเฉพาะทางเข้าไปในระบบการตอบคำถามของ LLM ด้วย ภาพที่ 18 แสดงการตอบคำถามจากแชทบอท



ภาพที่ 18 แสดงการตอบคำถามจากแชทบอท

จากภาพที่ 18 เมื่อโมเดล AI ได้รับข้อความจากผู้ใช้งาน จะมีการใช้งาน LLM ที่ได้ทำการทดสอบก่อนหน้านี้นี้ พร้อมทั้งการเทรนนิ่งกับข้อมูลเฉพาะทาง (RAG) เพื่อเพิ่มความสามารถเฉพาะด้านของโมเดล AI นี้ และแสดงคำตอบที่เกี่ยวข้องกับคำถามที่ผู้ใช้งานสอบถาม ซึ่งในการทำงานนี้ มีความสำคัญอย่างมาก เนื่องจากการซ่อมบำรุงนั้น จำเป็นต้องทำให้ถูกต้องและให้มีข้อผิดพลาดน้อยที่สุด เพื่อให้ระบบการผลิตนั้น ไม่สะดุดในการทำงาน ดังนั้น ในส่วนนี้ ยังมีพื้นที่สำหรับการพัฒนาอยู่มาก ซึ่งจะต้องมีการวัดประสิทธิภาพของการตอบคำถามกับเครื่องจักรหรืออุปกรณ์เฉพาะทางในระดับถัดไป

5 สรุปผล

5.1 สรุปผลการดำเนินงาน

ระบบผู้เชี่ยวชาญระยะไกลด้วย AI (AI-driven Remote Expert System) ที่นำเสนอในงานวิจัยนี้แสดงให้เห็นถึงศักยภาพในการเปลี่ยนแปลงของการผสมผสานเทคโนโลยีปัญญาประดิษฐ์ (AI) ความเป็นจริงเสริม/ผสม (AR/MR) และการประมวลผลภาษาธรรมชาติ (NLP) ในการปฏิบัติงานบำรุงรักษาในอุตสาหกรรม โดยใช้การรวมอัลกอริทึมการตรวจจับวัตถุของ YOLOv8s กับอุปกรณ์แว่นความเป็นจริงผสม Microsoft HoloLens 2 ซึ่งทำให้ระบบของเราช่วยในการตรวจสอบแบบเรียลไทม์และตรวจจับความผิดปกติของอุปกรณ์อุตสาหกรรมได้ เช่น ระบบ PLCnext ซึ่งการทำงานนี้สามารถดำเนินการได้โดยไม่ต้องมีผู้เชี่ยวชาญอยู่ที่หน้างานได้

ผลการทดสอบของเรายืนยันประสิทธิภาพของโมเดล YOLOv8s ในการตรวจจับไฟแสดงสถานะ LED โดยให้ผลลัพธ์ค่า mAP50 ที่ 0.993 และ mAP50-95 ที่ 0.844 ซึ่งโมเดลแสดงเมตริก recall และ precision ที่สูงมาก โดยเฉพาะอย่างยิ่งสำหรับสถานะที่แสดงข้อผิดพลาดของไฟกระพริบ BF_D_red_flash ซึ่งยืนยันความเหมาะสมสำหรับการใช้งานในอุตสาหกรรม การทดสอบภาคสนามที่ดำเนินการที่ระยะห่างต่าง ๆ กันได้สร้างความน่าเชื่อถือของระบบ โดยมีการตรวจจับไฟแสดงสถานะที่นิ่งได้แม่นยำมากกว่าไฟแสดงสถานะที่กะพริบเนื่องจากความล่าช้าและเวลาในการประมวลผลที่อาจจะไม่สอดคล้องกับจังหวะของการกระพริบของไฟแสดงสถานะ โดยระบบ AI-driven Remote Expert System แสดงให้เห็นว่า เทคโนโลยีที่เกิดขึ้นใหม่นี้สามารถจัดการกับความท้าทายด้านการบำรุงรักษาในอุตสาหกรรมอัตโนมัติอย่างมีประสิทธิภาพได้อย่างไร ด้วยการเปิดใช้งานความสามารถในการวินิจฉัยระบบจากระยะไกลนี้ จะเป็นการลดการพึ่งพาความเชี่ยวชาญและการใช้งานผู้เชี่ยวชาญหน้างาน ซึ่งมีราคาค่าใช้จ่ายที่ค่อนข้างสูงมาก นอกจากนี้ ระบบยังมีศักยภาพในการลดเวลาหยุดทำงานของเครื่องจักร เพิ่มประสิทธิภาพการดำเนินงาน และลดต้นทุนการบำรุงรักษาในภาพรวมได้อีกด้วย

5.2 ข้อค้นพบสำคัญ

1. **ประสิทธิภาพของโมเดล YOLOv8s** โมเดล YOLOv8s แสดงประสิทธิภาพที่โดดเด่นสำหรับการตรวจจับไฟแสดงสถานะ LED บนอุปกรณ์ PLCnext โดยให้ผลลัพธ์ค่า mAP50 ที่ 0.993 และ mAP50-95 ที่ 0.844 โดยมีค่า precision และ recall สูง ซึ่งแสดงให้เห็นถึงความน่าเชื่อถือของโมเดลในการระบุสถานะการทำงานและข้อผิดพลาดของเครื่องจักร

2. **การทำงานภายใต้ข้อจำกัดของฮาร์ดแวร์** แม้จะมีข้อจำกัดด้านการประมวลผลของอุปกรณ์แว่น HoloLens 2 แต่ระบบยังคงสามารถทำงานได้อย่างมีประสิทธิภาพโดยการใช้ CPU เฉลี่ยเพียง 3 - 4% มีการใช้งานแบตเตอรี่ของอุปกรณ์เพิ่มขึ้นในอัตรา 8% ต่อ 10 นาที ในขณะที่ใช้งานระบบอย่างเต็มรูปแบบ ซึ่งถือว่ายอมรับได้สำหรับการใช้งานในอุตสาหกรรมอัตโนมัติ

3. **ความล่าช้าของระบบและผลกระทบ** ระบบมีความล่าช้ารวมประมาณ 220 - 280 มิลลิวินาที ซึ่งส่งผลกระทบต่อประสิทธิภาพการตรวจจับไฟแสดงสถานะที่กะพริบ ความล่าช้านี้ส่งผลให้การตรวจจับไฟแสดงที่นิ่งมีความแม่นยำกว่าไฟแสดงสถานะที่กะพริบในการทดสอบภาคสนาม

4. **การผสมผสานเทคโนโลยี NLP** การรวมแชทบอท NLP โดยใช้แบบโมเดล Command-r7b กับเทคโนโลยี RAG ช่วยให้ระบบสามารถให้คำแนะนำในการแก้ไขปัญหาที่เกี่ยวข้องกับสถานการณ์ ณ ตอนนั้นได้ ซึ่งเป็นส่วนสำคัญของระบบผู้เชี่ยวชาญระยะไกลนี้

5. **ประสิทธิภาพที่ระยะต่าง ๆ** ระบบแสดงประสิทธิภาพการตรวจจับที่ดีกว่าที่ระยะใกล้ (ประมาณ 0.2 เมตร) เมื่อเทียบกับระยะไกล (ประมาณ 1 เมตร) สำหรับไฟแสดงสถานะที่นิ่ง แต่กลับมีการพัฒนาที่ดีขึ้นเล็กน้อยในการตรวจจับไฟแสดงที่กะพริบที่ระยะไกล ซึ่งอาจเป็นผลมาจากความซับซ้อนของการจำแนกภาพที่กะพริบและไม่กะพริบที่ลดลงในภาพระยะไกล

5.3 ปัญหา อุปสรรค และข้อจำกัด

1. **ความล่าช้าของระบบ** ความล่าช้ารวม 220 - 280 มิลลิวินาที ในระบบส่งผลให้เกิดความท้าทายในการตรวจจับสถานะไฟแสดงที่กะพริบ ความล่าช้านี้ส่งผลกระทบต่อความแม่นยำโดยรวมของระบบ โดยเฉพาะในสถานการณ์ที่ต้องการการวิเคราะห์แบบเรียลไทม์

2. **ข้อจำกัดของการใช้พลังงาน** การใช้พลังงานที่เพิ่มขึ้นในอัตรา 8% ต่อ 10 นาทีในขณะที่ใช้งานระบบเต็มรูปแบบ ทำให้เกิดข้อจำกัดในระยะเวลาการทำงานของอุปกรณ์ HoloLens 2 ซึ่งในสภาพแวดล้อมการทำงานจริง อุณหภูมิของอุปกรณ์ที่เพิ่มขึ้นเมื่อใช้งานเป็นเวลานานยังส่งผลให้การใช้พลังงานเพิ่มขึ้นอีกด้วย

3. **ขอบเขตการตรวจจับที่จำกัด** แม้ว่าโมเดล YOLOv8s จะมีประสิทธิภาพสูงในการตรวจจับสถานะไฟแสดง LED ที่กำหนดไว้ แต่ระบบยังคงถูกจำกัดให้ตรวจจับเฉพาะสถานะที่ได้รับการฝึกไว้ก่อนหน้านี้เท่านั้น ซึ่งอาจไม่ครอบคลุมสถานะข้อผิดพลาดและความผิดปกติทั้งหมดที่อาจเกิดขึ้นในอุปกรณ์ PLCnext

4. **การพึ่งพาเงื่อนไขของแสง** การทดสอบที่ดำเนินการภายใต้สภาพแสงที่ควบคุมได้อาจไม่แสดงถึงประสิทธิภาพของระบบในสภาพแวดล้อมอุตสาหกรรมจริงที่มีแสงไม่คงที่หรือไม่เพียงพอ

5. **ข้อจำกัดของโมดูล NLP** แม้ว่าแชทบอท NLP จะมีประสิทธิภาพดีเมื่อใช้กับเอกสาร PLCnext ที่มีอยู่ แต่ความสามารถในการให้คำแนะนำขึ้นอยู่กับความครอบคลุมและคุณภาพของเอกสารที่ใช้ในระบบ RAG ซึ่งทำให้มีข้อจำกัดในการแก้ไขปัญหาที่ซับซ้อนหรือกรณีปัญหาที่ไม่ได้ระบุไว้ในเอกสาร

5.4 ข้อเสนอแนะ

1. **การลดความล่าช้าของระบบ** ควรปรับปรุงไปป์ไลน์การประมวลผลเพื่อลดความล่าช้ารวมของระบบ เช่น การใช้เทคนิคการบีบอัดขั้นสูง การเพิ่มประสิทธิภาพการส่งข้อมูล และการนำการประมวลผลแบบ edge computing มาใช้ อาจช่วยลดความล่าช้าและปรับปรุงการตรวจจับไฟแสดงที่กะพริบได้
2. **การปรับปรุงประสิทธิภาพการใช้พลังงาน** ควรมีการปรับปรุงแอปพลิเคชันเพื่อให้ใช้พลังงานอย่างมีประสิทธิภาพมากขึ้น เช่น การลดความถี่ในการประมวลผลเฟรม การปรับลดความละเอียดของวิดีโอ หรือการใช้เทคนิคการหยุดการประมวลผลชั่วคราวเมื่อไม่มีการเปลี่ยนแปลงในวิดีโอ
3. **เพิ่มข้อมูลการฝึกที่หลากหลาย** ควรขยายชุดข้อมูลฝึกให้รวมถึงสภาพแสงที่แตกต่างกัน มุมมองที่ต่างกัน และระยะห่างที่มีหลายระยะ เพื่อปรับปรุงความทนทานของโมเดลในสภาพแวดล้อมอุตสาหกรรมที่หลากหลาย โดยเทคนิคการเพิ่มข้อมูลขั้นสูง เช่น GAN อาจช่วยสร้างข้อมูลสังเคราะห์ที่หลากหลายได้
4. **ปรับปรุงโมดูล NLP** ควรขยายฐานความรู้ของแชทบอท NLP ด้วยเอกสารที่มากขึ้น รวมถึงเพิ่มเอกสารรายงานการแก้ไขปัญหา บันทึกข้อผิดพลาด และแนวทางการแก้ไขปัญหา เพื่อปรับปรุงความสามารถในการให้คำแนะนำ หรืออาจพิจารณาใช้แบบจำลองภาษาที่ใหญ่ขึ้นหากทรัพยากรการประมวลผลเอื้ออำนวย
5. **การทดสอบภาคสนามที่ครอบคลุมมากขึ้น** ควรทำการทดสอบเพิ่มเติมในสภาพแวดล้อมอุตสาหกรรมจริงที่มีเงื่อนไขการทำงานและสภาพแสงที่แตกต่างกัน เพื่อประเมินประสิทธิภาพของระบบในสถานการณ์จริงและระบุพื้นที่ที่ต้องปรับปรุงเพิ่มเติม

5.5 แนวทางในการพัฒนาในอนาคต

ในอนาคต เราจะมุ่งเน้นใน 5 ด้าน ได้แก่ การเพิ่มความแม่นยำของโมเดล การลดความล่าช้า การนำไปใช้ในอุตสาหกรรม การขยายความสามารถการตรวจจับ และการบูรณาการกับระบบอุตสาหกรรม 4.0

1. **การเพิ่มความแม่นยำของโมเดล** แม้ว่าโมเดล YOLOv8s จะมีประสิทธิภาพดี แต่ยังคงต้องการการปรับปรุงสำหรับการตรวจจับไฟแสดงแบบกะพริบหรือมีการเคลื่อนไหวหรือเคลื่อนไหว ในการทำสิ่งนี้ต้องการข้อมูลการฝึกที่หลากหลายจากสภาพแวดล้อมอุตสาหกรรมต่าง ๆ ที่มีสภาพแสง มุมมอง และระยะห่างที่แตกต่างกัน การใช้เทคนิคการเพิ่มข้อมูลขั้นสูง เช่น การใช้ Generative Adversarial Networks (GANs) หรือ Variational Autoencoders (VAEs) จะช่วยสร้างข้อมูลสังเคราะห์ที่เหมาะสมสำหรับสถานการณ์หายากที่ยากต่อการจำลองในการดำเนินงานปกติได้
2. **การลดความล่าช้า** การปรับปรุงโปรโตคอลการส่งข้อมูลผ่านการบีบอัดขั้นสูง เครือข่ายที่มีความล่าช้าต่ำ และการประมวลผลแบบ edge computing จะช่วยลดความล่าช้าจากปลายทางถึงปลายทางได้ ควรมีการมุ่งเน้นที่การปรับโค้ดให้เหมาะสมสำหรับแพลตฟอร์ม HoloLens 2 เพื่อให้การประมวลผลในเครื่องมีประสิทธิภาพมากขึ้น โดยมีการถ่ายโอนข้อมูลบางส่วนไปยังระบบการประมวลผลระยะไกลด้วย

3. **การนำไปใช้ในอุตสาหกรรม** การทำงานร่วมกับสถานประกอบการในอุตสาหกรรมอัตโนมัติเพื่อทดสอบระบบในสภาพแวดล้อมการทำงานจริง รวบรวมข้อเสนอแนะจากช่างเทคนิคและผู้ควบคุมงาน และทำการปรับเปลี่ยนที่จำเป็นเพื่อเพิ่มการยอมรับของผู้ใช้ประโยชน์ในสภาพแวดล้อมการผลิตจริง ซึ่งการดำเนินโครงการนำร่องในอุตสาหกรรมที่หลากหลายจะช่วยให้สามารถประเมินผลกระทบเชิงปริมาณเกี่ยวกับเวลาหยุดทำงาน ความพร้อมใช้งานของอุปกรณ์ และการลดค่าใช้จ่ายในการบำรุงรักษาได้

4. **การขยายความสามารถการตรวจจับ** พัฒนาโมเดลให้สามารถตรวจจับความผิดปกติที่ซับซ้อนมากขึ้น เช่น รูปแบบการกะพริบที่ซับซ้อน การเปลี่ยนแปลงอุณหภูมิ หรือเสียงผิดปกติจากเครื่องจักร โดยอาจใช้เซ็นเซอร์เพิ่มเติมร่วมกับ HoloLens 2 เช่น กล้องความร้อนหรือไมโครโฟนเฉพาะทาง

5. **การเพิ่มประสิทธิภาพของแซทบอทอุตสาหกรรม** ขยายฐานข้อมูลและเพิ่มประสิทธิภาพของแซทบอทสำหรับงานอุตสาหกรรม โดยเฉพาะอุตสาหกรรมการผลิต โดยการเพิ่มข้อมูลที่เกี่ยวข้อง ข้อมูลจาก Data Sheets ของเครื่องจักรหรืออุปกรณ์ ข้อมูลที่สกัดจากเว็บฟอรัมหรือเว็บบอร์ดที่มีการถามตอบ เป็นต้น

6. **การบูรณาการกับระบบอุตสาหกรรม 4.0** เชื่อมต่อระบบ Ai-driven Remote Expert System เข้ากับโครงสร้างพื้นฐานอุตสาหกรรม 4.0 ที่มีอยู่ เช่น ระบบ SCADA, IoT platforms หรือ Digital Twins เพื่อใช้ประโยชน์จากข้อมูลที่มีอยู่แล้วและเพิ่มความสามารถในการคาดการณ์และการวิเคราะห์ของระบบ

กลยุทธ์การประเมินประสิทธิภาพของการซ่อมบำรุงที่ครอบคลุมนั้น เป็นสิ่งสำคัญเพื่อยืนยันประสิทธิภาพและความทนทานของระบบที่ทำงานร่วมกันในพื้นที่โรงงานอุตสาหกรรม แนวทางการทำงานอย่างเป็นระบบที่รวมถึงการปรับใช้เทคโนโลยี AR/MR, AI และ Automation (AAA) ที่ปรับปรุงและพัฒนาให้เข้ากับสถานการณ์ในอุตสาหกรรมที่หลากหลาย ครอบคลุมระดับการดำเนินงานที่แตกต่างกัน ความซับซ้อน และภาคส่วนต่าง ๆ ได้อย่างมีประสิทธิภาพ การพัฒนาและขยายขอบเขตของการใช้งานเทคโนโลยีเหล่านี้ให้ครอบคลุมการทำงานที่หลากหลายมากขึ้น จะช่วยในการยืนยันการทำงานของเทคโนโลยีเหล่านี้ในการแก้ปัญหาให้แก่ภาคอุตสาหกรรมได้

การประเมินประสิทธิภาพอย่างเข้มงวดก็เป็นสิ่งสำคัญยิ่ง ซึ่งไม่เพียงแต่จะมีการวัดความแม่นยำและความเร็วของอัลกอริทึมการตรวจจับวัตถุเท่านั้น แต่ยังรวมถึงการประเมินผลกระทบของระบบต่อประสิทธิภาพของการดำเนินงาน การลดเวลาหยุดทำงาน และการเพิ่มผลผลิตโดยรวมอีกด้วย ตัวชี้วัดความสำเร็จจำเป็นต้องสามารถวัดได้ในหลายมิติ ครอบคลุมทั้งด้านเชิงคุณภาพและเชิงปริมาณ เช่น การวัดประสบการณ์ของผู้ใช้และความเข้าใจง่ายของอินเทอร์เฟซ โดยเฉพาะเมื่อใช้กับอุปกรณ์อย่าง HoloLens 2 การวัดประสิทธิผลของการดำเนินการในอุตสาหกรรมจริง เป็นต้น

6 บรรณานุกรม

References

- Li, Y., Zhang, H., Guo, F., Chen, Y., Wang, Y. (2024). Integrating Attention Mechanisms into YOLOv8 for Improved Defect Detection in Acceptance Environments on HoloLens 2. In: 2024 3rd Asian Conference on Frontiers of Power and Energy (ACFPE), pp. 399–403.
- Lysakowski, M., żywanowski, K., Banaszczyk, A., Nowicki, M.R., Skrzypczyński, P., Tadeja, S.K. (2023). Real-time onboard object detection for augmented reality. Enhancing head-mounted display with yolov8. In: 2023 IEEE International Conference on Edge Computing and Communications (EDGE), pp. 364–371.
- Bahri, H., Krčmař, J. (2019). Accurate object detection system on hololens using yolo algorithm. In: 2019 International Conference on Control, Artificial Intelligence, Robotics & Optimization (ICCAIRO), pp. 219–224.
- Zhang, J. (2024). Classification and Comparison of Data Augmentation Techniques. Transactions on Computer Science and Intelligent Systems Research.
- Jebraeeli, V., Jiang, B., Krim, H., Cansever, D. (2024). Generative Expansion of Small Datasets. An Expansive Graph Approach. arXiv preprint arXiv:2406.17238.
- Ekwaro-Osire, H., Ponugupati, S.L., Al Noman, A., Bode, D., Thoben, K.-D. (2025). Data augmentation for numerical data from manufacturing processes. An overview of techniques and assessment of when which techniques work. Industrial Artificial Intelligence 3, 1–19.
- Wu, J., Shen, F., Ye, L. (2024). Data augmentation using time conditional variational autoencoder for soft sensor of industrial processes with limited data. IEEE Transactions on Instrumentation and Measurement.
- Kongon, B., Jantarakongkul, B., Jitngernmadan, P. (2024). Remote Expert AI System for Industrial Maintenance. A Technical Approach. In: 2024 8th International Conference on Information Technology (InCIT), pp. 669–674.
- PLCnext Community (2023, June 9). PLCnext Community Website. Retrieved from <https://www.plcnext-community.net/>.

7 ภาคผนวก

7.1 ตัวอย่างภาพจากชุดข้อมูล

ตัวอย่างภาพจากชุดข้อมูลในเฟรมที่แสดงให้เห็นถึงไฟ LED สีแดงที่กำลังดับจากกระบวนการกระพริบอย่างสม่ำเสมอในชุดข้อมูลระยะใกล้ และ ระยะไกล

7.1.1 ชุดข้อมูลระยะใกล้

เฟรมที่ 39



ภาพที่ 19 ภาพจากชุดข้อมูลระยะใกล้ในเฟรมที่ 39

เฟรมที่ 40



ภาพที่ 20 ภาพจากชุดข้อมูลระยะใกล้ในเฟรมที่ 40


7.1.2 ชุดข้อมูลระยะไกล

เฟรมที่ 9



ภาพที่ 21 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 9

เฟรมที่ 10




ภาพที่ 22 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 10

เฟรมที่ 11



ภาพที่ 23 ภาพจากชุดข้อมูลระยะไกลในเฟรมที่ 11

7.2 การรับรองจริยธรรมวิจัย



บันทึกข้อความ

คณะวิทยาการสารสนเทศ ม.บูรพา

รับที่ 0987

วันที่ 0 เม.ย. 2568

เวลา 16.54

ส่วนงาน กองบริหารการวิจัยและนวัตกรรม งานมาตรฐานและจริยธรรมในการวิจัย โทร. ๒๖๒๐
ที่ อว ๘๑๐๐/๐๓๔/๒๓ วันที่ ๑ เมษายน พ.ศ. ๒๕๖๘

เรื่อง ขอแจ้งรับรองโครงการวิจัยที่ส่งมาขอรับการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา

เรียน คณบดีคณะวิทยาการสารสนเทศ

ตามที่นักวิจัยในหน่วยงานของท่าน ได้ยื่นเอกสารคำร้องเพื่อขอรับการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา โครงการวิจัย เรื่อง การประยุกต์ใช้งานความเป็นจริงเสริมในงานด้านอุตสาหกรรมอัตโนมัติ (ระยะที่ ๒) โดยมี ผู้ช่วยศาสตราจารย์ ดร.ประจักษ์ จิตเงินมะดัน เป็นหัวหน้าโครงการวิจัย นั้น

บัดนี้ คณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา ชุดที่ ๑ (กลุ่มคลินิก/ วิทยาศาสตร์สุขภาพ/ วิทยาศาสตร์และเทคโนโลยี) ได้พิจารณาตามวิธีดำเนินการมาตรฐาน (Standard Operating Procedures, SOPs) ฉบับที่ ๒.๑ พ.ศ. ๒๕๖๖ ที่ได้ประกาศใช้เมื่อวันที่ ๑๒ กรกฎาคม พ.ศ. ๒๕๖๖ แล้วว่า โครงการวิจัยดังกล่าวไม่ได้ทำการศึกษาวิจัยในมนุษย์ จึงเห็นสมควรให้ดำเนินการวิจัยได้

จึงเรียนมาเพื่อโปรดแจ้งให้นักวิจัยทราบ จักขอบคุณยิ่ง

Just Ka

(รองศาสตราจารย์ ดร.วิฑูรย์ แจ่มเอี่ยม)

ประธานคณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยบูรพา
ชุดที่ ๑ (กลุ่มคลินิก/ วิทยาศาสตร์สุขภาพ/ วิทยาศาสตร์และเทคโนโลยี)

เรียน คณบดี

๑. เพื่อโปรดทราบ
๒. เห็นควรแจ้งรองคณบดี (ศร. ๐๖๓) เพื่อไปทราบบ
๓. เห็นควรแจ้งศร. ประจักษ์ จิตเงินมะดัน ทราบ
๔. เห็นควรแจ้งวงวิจัยทราบ และดำเนินการในส่วนที่เกี่ยวข้อง

Zlar
๑๐ เม.ย. ๖๘

คณบดี
คำณวณทวน ๑๖๐
๑๑ เม.ย. ๖๘

7.3 ผลงานวิจัยที่อยู่ระหว่างการตีพิมพ์และเผยแพร่

ผลงานนี้ได้รับการตีพิมพ์และเผยแพร่ที่ The 4th International Symposium on Industrial Engineering and Automation (ISIEA2025): Manufacturing 2030: A Perspective to Future Challenges in Industrial Production (<https://isiea.events.unibz.it/>)

AI-driven Remote Expert System Architecture Approach: An Integration of AI, MR, and NLP

Bhusana Kongon¹[0009-0009-9231-7518], Benchaporn Jantarakongkul¹[0009-0005-3307-9282],
Tanat Kanangnanon¹[0009-0009-4624-0185] and Prajaks Jitngernmadan¹[0009-0009-6138-4021]

¹ Burapha University, Faculty of Informatics, Chon Buri 20131, Thailand
66910080@go.buu.ac.th, benchapo@go.buu.ac.th,
66910081@go.buu.ac.th, prajaks@buu.ac.th

Abstract. This study introduces an AI-driven Remote Expert System that transforms industrial maintenance through the integration of artificial intelligence (AI), mixed reality (MR), and natural language processing (NLP) technologies. Our implementation utilizes YOLOv8s on Microsoft HoloLens 2 for real-time object recognition and LED status indicator detection on PLCnext controllers, enabling on-site operators to receive immediate diagnostic information. Experimental validation and field trials demonstrate robust system performance with an mAP50 of 0.993 and mAP50-95 of 0.844, while optimizing CPU utilization and battery consumption during video streaming operations. The system automatically generates NLP-based maintenance recommendations corresponding to identified issues. This innovative approach establishes a new paradigm for industrial maintenance that significantly reduces equipment downtime, enhances operational efficiency, and minimizes maintenance costs.

Keywords: Remote Expert System, Artificial Intelligence, Mixed Reality, Industrial Maintenance, YOLOv8s.

1 Introduction

In Industry 4.0, growing machine and industrial process sophistication has transformed maintenance efficiency into a key driver of business continuity and downtime reduction. The more complex a plant, the more difficult of the maintenance. Conventional maintenance methods require the physical presence of subject-matter experts, which typically result in delays due to limited availability or travel requirements. This can lead to the loss of productivity and additional expenses.

The primary goal of this research is to develop a state-of-the-art remote expert system that utilizes the power of artificial intelligence. This AI-based system will integrate innovative technologies, e.g., computer vision, mixed reality (MR), and natural language processing (NLP) together. This setting should be interpreted as an expert who can guide the technician to do the maintenance tasks. To detect the given machine accurately, an Object Detection system is modelled and implemented. This will be performed through the vision of a HoloLens 2 device, where MR information can be superimposed in the view. For specific questions or problems, a trained NLP-based model

2

can be acquired to suggest answers or recommendations that are the most suitable for that situation. Furthermore, the system will allow visualization in real time. Thus, it will provide contextual advice and assistance to technicians. The advice will come through a smart chatbot that improves human-computer interaction.

Effective implementation of such a system can significantly reduce repair and diagnostic time, decrease machine downtime, enhance overall equipment effectiveness (OEE), and optimize resource usage by leveraging remote expertise. This approach reduces travel costs, improves maintenance scalability, and potentially leads to broader applications of AI and MR technologies across industrial domains, fostering innovation in the Industry 4.0 landscape.

2 Related Technologies

2.1 Integration of YOLOv8s and HoloLens 2 for Industrial Applications

Recent developments in Augmented Reality (AR), Mixed Reality (MR), and object identification algorithms have opened up new industrial application possibilities. According to Li et al. [1], adding attention mechanisms to YOLOv8 greatly increases power substation monitoring speed and precision while allowing for real-time feedback for quick defect correction. In industrial settings with limited connectivity, Łysakowski et al. [2] successfully deployed YOLOv8 directly on HoloLens 2 without relying on the cloud, removing network latency problems and enhancing system responsiveness and dependability. In order to improve user experience and operational efficiency in dynamic industrial situations, Bahri et al. [3] enhanced YOLOv8 for the detection of thousands of objects with accurate bounding boxes in milliseconds.

Our study combines these techniques into a single solution for applications in industrial maintenance. We used Łysakowski et al.'s on-device processing strategy to provide low-latency feedback with seamless MR interaction, adapted Li et al.'s method to increase the accuracy of LED status indicator detection, and applied Bahri et al.'s optimization approaches for responsive machinery monitoring.

2.2 Data Augmentation Techniques for Limited Industrial Datasets

Collecting quality annotated data in industrial vision poses significant challenges due to production constraints and rare fault conditions. Data augmentation addresses this limitation by expanding training datasets while preserving critical attributes. Different augmentation strategies offer varying benefits for industrial applications.

Geometric transformations form the foundation of industrial image augmentation. Zhang [4] showed these transformations maintain semantic integrity while creating positional variance—essential for machine vision systems that must recognize equipment from multiple angles. By applying rotations and flips to limited samples, models develop better generalization to varying inspection perspectives in real-world settings.

For more sophisticated data expansion, Jebraeli et al. [5] demonstrated feature interpolation and expander graph mappings to generate diverse samples from limited

datasets. These techniques preserve both data distributions and feature relationships, making them valuable for industries where comprehensive fault data collection is impractical or prohibitively expensive.

Advanced generative methods provide even greater capabilities for creating realistic data. Ekwaro-Osire et al. [6] showed Generative Adversarial Networks (GANs) that can produce high-quality synthetic samples for industrial vision applications, particularly with non-time-series data and correlated machine features. Similarly, Wu et al. [7] proved Variational Autoencoders (VAEs) effectively generate virtual samples from time-series data that match real operational data distributions, enabling simulation of rare fault scenarios difficult to reproduce in normal operations.

We combined these techniques with our studied datasets, especially the datasets for images and the NLP training, where problem solving information has to be provided. In normal cases, the errors will not occur. Our relative small data relies on typical errors or standard errors from the data sheets or documentations.

3 Methodology

3.1 System Architecture

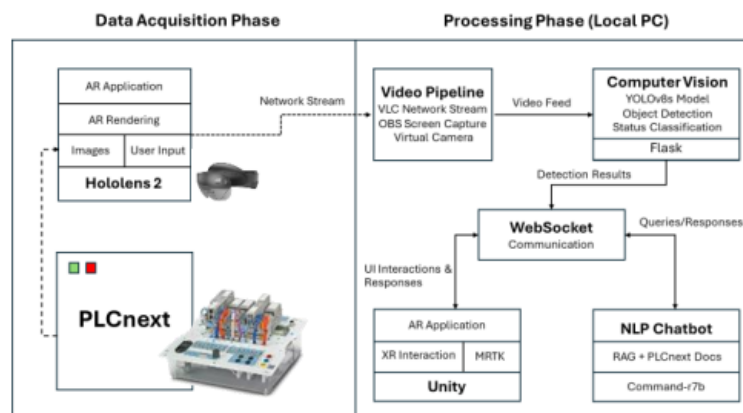


Fig. 1. System architecture of the AI-driven Remote Expert System.

This AI-driven Remote Expert System is an integration of artificial intelligence, natural language processing, mixed reality, and computer vision technologies to create a maintenance system. The end-to-end system makes it possible for on-site diagnosis of machinery in real-time as well as for a remote diagnosis, doing away with a major part of the necessity of in-site visits of expert experts in case of machinery breakdown.

The system is designed in a strategic structure in two primary levels of functions, which is illustrated in Figure 1. The figure illustrates end-to-end system structure, highlighting data movement and communication among primary entities in each of these levels.

4

Data Acquisition Phase. The Data Acquisition Phase is integrated within the industrial space and serves as the system's sensor interface. It is implemented on a Microsoft HoloLens 2 device, which is worn by an on-premise operator and captures video of PLCnext devices (as a machinery). The HoloLens 2 executes an MR Application with rendering functionality that processes images and interprets user input. The HoloLens mixed reality headset operates hands-free, allowing the operator to simultaneously view the physical devices while receiving augmented reality overlays displaying diagnostic information. The video stream from the HoloLens 2 is transmitted via a network connection to the processing layer, establishing the initial data pipeline for the system.

Processing Phase (Local PC). The Processing Phase is implemented within a local PC and comprises multiple expert modules that work collaboratively to analyze equipment condition and provide specialized guidance:

Video Pipeline Module. The system receives the HoloLens 2 video stream through VLC Network Stream protocol. Preprocessing operations are performed using OBS Screen Capture, which converts the incoming stream into a Virtual Camera format compatible with downstream system components. This preprocessing stage ensures the video data is properly formatted to facilitate subsequent analytical processes.

WebSocket Communication Module. The central component of the system is a bidirectional communication channel that facilitates real-time data exchange between all system modules. It transmits detection results to both the Unity Application and the NLP Chatbot, while simultaneously distributing user inquiries and interface commands throughout the system architecture.

NLP Chatbot Module. The AI chatbot provides expert-level troubleshooting recommendations based on the diagnosed conditions. Utilizing Retrieval-Augmented Generation (RAG) technology that incorporates PLCnext documentation and is powered by the Command-r7b language model, the chatbot delivers comprehensive diagnostic analyses and sequential maintenance instructions following fault identification.

Computer Vision Module. The computer vision module implements the YOLOv8s model to perform real-time object detection and status classification of LED indicators on PLCnext devices. The model has been specifically trained to identify various operational states and fault conditions through visual observation. All detection results are processed and distributed through a Flask application framework.

Unity Application Module. This module powers the mixed-reality visualization and interface displayed within the HoloLens 2 device. It employs XR Interaction Toolkits and MRTK (Mixed Reality Toolkit) components to create an interactive environment. Detection results are superimposed onto the physical device within the operator's field of vision, while simultaneously providing an interactive interface with the NLP chatbot. This integration creates a seamless mixed-reality experience for the operator.

The system functions through a continuous operational cycle where the operator's visual field video is captured, processed to identify status indicators, analyzed to determine potential faults, and enhanced with appropriate guidance and visual information. This real-time closed-loop feedback mechanism enables immediate response to equipment anomalies without requiring an expert technician's physical presence. This approach significantly reduces downtime and enhances maintenance efficiency within industrial environments.

3.2 Data Collection and Preparation

Video Capture. The video data acquisition process began with structured recording sessions focused on capturing the PLCnext device. The LED indicator section is emphasized particularly. To document the full range of operational states, we conducted two 5-second video recordings. These were captured at 30 frames per second (30 fps) to ensure sufficient temporal resolution for distinguishing between both steady and flashing LED states. All experiments were performed under controlled lighting conditions, with careful attention to camera positioning to optimize the visibility of all status indicators. This methodical approach to data collection yielded high-quality visual data suitable for subsequent processing stages.

Frame Extraction. The next methodological step involved extracting individual frames from the video recordings. Each 5-second video, captured at 30 frames per second, yielded approximately 150 frames per video, resulting in a total of 300 frames from the two recordings. The frame extraction was performed using specialized software capable of segmenting video content into discrete images while maintaining image integrity throughout the process. Each extracted frame was saved in an appropriate file format optimized for subsequent processing requirements. Quality assurance procedures were implemented to verify that all LED status indicators remained clearly visible in each frame, which was essential for the subsequent annotation process.

Data Annotation. During the annotation phase, the extracted frames underwent a comprehensive labeling process to categorize and tag the visible LED states. Four distinct classification categories were established: RUN_green_steady, D_green_steady, BF_D_red_flash, and PLC. This addresses both chromatic attributes (green/red) and temporal characteristics (steady/flashing) of the LED indicators. Bounding rectangles were precisely drawn around each LED indicator, with the appropriate class label assigned according to the observed state in the annotation. This process demanded attention to detail to accurately define the boundaries of the indicators and correctly classify their operational states, particularly when capturing frames depicting transitional moments in flashing sequences.

Data Augmentation. To enhance the robustness and generalizability of the model, data augmentation techniques were applied to the labeled image set. The primary

6

augmentation method employed was rotation; leftward and rightward. This technique produced two additional variations for each original image, expanding the dataset from 300 to approximately 900 images. The augmentation process was designed specifically to improve the model's ability to recognize LED states from slightly different perspectives—a critical capability when implementing the system in operational environments where camera positioning may vary.

3.3 Model Development

YOLOv8s Implementation. The AI-driven Remote Expert system implements YOLOv8s as its core object detection model for identifying LED status indicators on PLCnext devices. This model selection was informed by our previous research demonstrating the efficacy of YOLO algorithms in industrial applications, particularly for anomaly detection in manufacturing environments [8]. The YOLO-based models integrated with HoloLens 2 demonstrate significant potential for enhancing predictive maintenance protocols and reducing equipment downtime in industrial settings. YOLOv8s provides an optimal balance between detection accuracy and processing speed, making it exceptionally suitable for real-time deployment on computationally limited hardware platforms such as the HoloLens 2. The model architecture enables sophisticated multi-class object detection capabilities—an essential requirement for simultaneously identifying and classifying various LED states.

Model Training Process. The training process utilized transfer learning from pre-trained weights to optimize training duration and model performance on our relatively limited dataset. The model was trained using 900 images containing annotated bounding boxes for each LED state classification category. Training parameters were configured as follows: 300 epochs, batch size of 16, input image dimensions of 640×640 pixels, and optimizer momentum of 0.937. To enhance the model's generalization capabilities, various data augmentation techniques were employed, including random horizontal flips, translation, scaling, and random erasing. Mixed precision training was enabled to maximize memory efficiency and accelerate the training process. Model validation was conducted using an independent validation dataset, with performance primarily evaluated using mean Average Precision (mAP) at an Intersection over Union (IoU) threshold of 0.7.

Detection Classes and Parameters. The model was architected to classify and identify four distinct categories: 1) steady green RUN indicators signifying normal operation, 2) steady green D indicators denoting proper data communication, 3) flashing red BF_D indicators indicating errors or faults, and 4) the overall PLCnext device serving as a spatial reference point. This classification system extends our previous research in industrial equipment status monitoring by incorporating temporal state detection capabilities [8]. For real-time inference operations, the model was configured with a confidence threshold of 0.25, IoU 0.7, and 300 maximum detections per frame. The detection of flashing states presented a particular challenge, necessitating temporal analysis of

sequential frames combined with specialized filtering algorithms to accurately differentiate between steady and flashing indicators.

3.4 Natural Language Processing Integration

The proposed system incorporates a natural language processing (NLP) module for offering intelligent troubleshooting support using an AI chatbot. The chatbot offers context-sensitive information and support to operators by drawing on PLCnext device-specific documentation.

For the chatbot knowledge base, we implemented the Retrieval-Augmented Generation (RAG) methodology, which combines pre-trained language models with relevant documentation to generate responses. Our assessment included two large language models (LLMs): deepseek-r1 and command-r7b, both featuring 7 billion parameters.

The PLCnext documentation incorporated into the RAG system contains essential information correlating LED indicator patterns with specific device statuses and their interpretations. By integrating this technical documentation into the LLMs, the chatbot can accurately interpret the captured LED states and provide relevant troubleshooting recommendations to operators in real time.

Our comprehensive testing revealed that the command-r7b model consistently outperformed deepseek-r1 when implemented within the RAG framework utilizing PLCnext documentation. The command-r7b model demonstrated superior capabilities in generating factually accurate and contextually appropriate responses, while also exhibiting more favorable response times during operational testing.

4 Results and Discussion

4.1 Model Performance Metrics

The YOLOv8s model developed for our proposed system has demonstrated exceptional detection performance across all target classification categories. Following 300 epochs of training, the model achieved remarkable overall performance metrics, with particularly high recall and precision values—characteristics that are essential for reliable industrial monitoring systems.

Table 1. YOLOv8s Model Performance Metrics by Class

Class	Images	Instances	Precision	Recall	mAP50	mAP50-95
RUN_green_steady	178	178	1.0	0.966	0.994	0.795
D_green_steady	178	178	1.0	0.965	0.988	0.773
BF_D_red_flash	85	85	0.993	1.0	0.995	0.814
PLC	178	178	0.995	1.0	0.995	0.995
Overall	178	619	0.997	0.983	0.993	0.844

8

As shown in Table 1, the model achieved a mean Average Precision (mAP50) of 0.993 across all classes, indicating exceptional detection precision at the standard 50% Intersection over Union (IoU) threshold. The mAP50-95 value of 0.844 further confirms robust performance across multiple IoU thresholds. Notably, the BF_D_red_flash class attained a perfect recall score despite having fewer training instances. This performance characteristic is particularly significant since this class represents error conditions that require immediate attention in industrial monitoring environments.

Table 2. Classification Accuracy of YOLOv8s Model by Class

Class	Classification Accuracy	Misclassified as Background
RUN_green_steady	0.96	0.04
D_green_steady	0.95	0.05
BF_D_red_flash	0.99	0.01
PLC	1.00	0.00

Table 2 presents the classification accuracy of the model across all target classes. The high accuracy values (0.95-1.00) demonstrate exceptional classification performance with negligible misclassifications. The PLC class achieves perfect classification accuracy (1.00), while the LED indicators exhibit strong performance with minimal misclassifications (0.01-0.05) relative to background detections.




Fig. 2. Precision-Recall curves for all classes.

Figure 2 shows the Precision-Recall curves for all classification categories, demonstrating the model's ability to maintain high precision values even at elevated recall levels. The near-rectangular profile of these curves, particularly evident in the PLC class (red line), indicates that the model consistently maintains high precision across the entire spectrum of recall values. This performance characteristic is critically important in industrial applications where both false positive and false negative detections could potentially result in inappropriate maintenance interventions.

4.2 Real-time detection accuracy (Field Test)

We evaluated the model's performance via the HoloLens 2 at two operational distances from the PLCnext device: near distance (approximately 0.2 meters) and far distance (approximately 1 meter). The system underwent testing for detection of three critical LED status indicators: RUN_green_steady, D_green_steady, and BF_D_red_flash. These indicators represent normal operational states and fault conditions. Figure 3 shows the system operation testing where an operator wears a HoloLens 2 device and looks at the PLCnext device for detecting errors.




Fig. 3. AI-driven Remote Expert System in operation.

Detection Performance under Two Distances. At near distance (as shown in Table 3), the model demonstrated flawless detection capabilities (100% accuracy) for both steady green indicators (RUN and D status). The flashing red indicator proved more challenging to detect consistently, achieving only 59% accuracy. This performance discrepancy likely stems from the temporal characteristics of the flashing indicator, which inherently complicates frame-by-frame detection processes.

The detection performance measured at greater distances shows in Table 4. The accuracy of RUN_green_steady decreased to 85.7%, while D_green_steady detection accuracy declined to 76.7%. In contrast, detection of BF_D_red_flash showed modest improvement to 62.0% at the farther distance. This unexpected performance variation may be attributable to reduced visual complexity in distant frames or alterations in the visual characteristics of the flashing pattern at a distance.

Table 3. Near Distance Detection Confusion Matrix

Status Indicator	True Negative	False Positive	False Negative	True Positive	Accuracy
RUN_green_steady	0	0	0	300	100%
D_green_steady	0	0	0	300	100%
BF_D_red_flash	85	68	55	92	59%

Table 4. Far Distance Detection Confusion Matrix

Status Indicator	True Negative	False Positive	False Negative	True Positive	Accuracy
RUN_green_steady	0	0	43	257	85.7%
D_green_steady	0	0	70	230	76.7%
BF_D_red_flash	100	46	68	86	62%

10

Effect of System Latency on Detection Performance. Cumulative latency throughout the entire system represents a significant factor affecting real-time detection quality. The seven-stage pipeline from HoloLens 2 capture to augmented reality rendering overlay results a cumulative system latency of 220-280ms. While this delay remains acceptable for typical augmented reality applications, it significantly reduces detection quality in dynamic scenarios involving flashing indicators, as frames captured at specific moments may not accurately correspond to the actual LED states. This latency factor explains why stable indicators consistently outperformed flashing indicators across all experimental scenarios—stable indicators maintain consistent states that allow for reliable detection regardless of minor timing discrepancies in the processing pipeline.

4.3 Hardware Performance Analysis

HoloLens 2 Battery Consumption. During experimental trials of the proposed system, we observed significant differences in power consumption when comparing standalone video streaming versus full system operation on the HoloLens 2. When operating the complete system, power consumption increased at a rate of approximately 8% per 10 minutes of continuous use. In contrast, when utilizing only the video streaming functionality, power consumption increased at a lower rate of approximately 6% per 10 minutes. Our investigation revealed a correlation between operational duration, device temperature, and power consumption. As the HoloLens 2 operated for extended periods, the device temperature increased, which corresponded with elevated power consumption rates.

CPU utilization metrics



Fig. 4. CPU usage of the HoloLens 2 over a 5-minute period.

Figure 4 illustrates the CPU usage of the HoloLens 2 during a 5-minute operational period while running the complete AI-driven Remote Expert System. The CPU utilization exhibits considerable volatility throughout this interval, reaching a maximum of slightly above 5.5% at certain points. Average CPU utilization remains predominantly within the 3-4% range, indicating a moderate processing load on the HoloLens 2 hardware. The observed peaks in CPU utilization can be attributed to instances of intensive computational activity, particularly when the computer vision module actively processes data to recognize and identify the operational status of the PLCnext device.

Memory utilization metrics

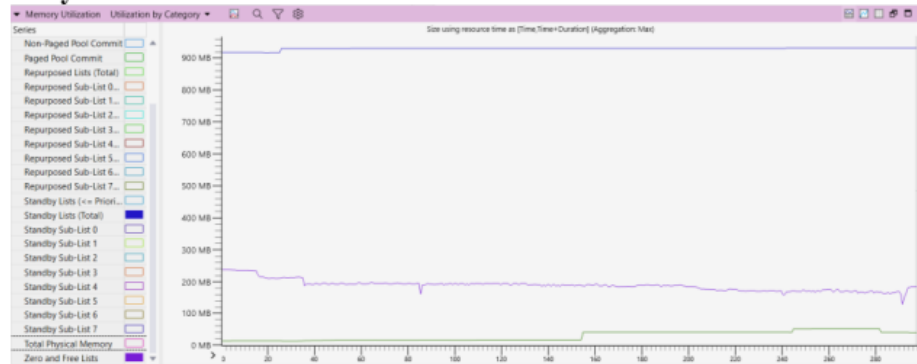


Fig. 5. Memory utilization of the HoloLens 2 over a 5-minute period.

Figure 5 presents the memory usage profile of the HoloLens 2. The memory allocation remains remarkably stable, with "Non-Paged Pool Commit" consistently maintained just below 950 MB and "Standby Lists (Total)" slightly below 300 MB. The "Total Physical Memory" exhibits steady consumption throughout the testing period. This analysis indicates that our AI-driven Remote Expert application utilizes a substantial but effectively managed portion of the available memory. The hardware utilization assessment demonstrates an increased battery consumption rate when operating the complete system, while maintaining moderate CPU utilization during video streaming operations. Memory usage, though significant, remains proportionate to the device's capacity specifications. These findings confirm the viability of our AI-powered support solution on the HoloLens 2 platform, though opportunities exist for optimization in the areas of power consumption efficiency and computational overhead reduction.

5 Conclusion and Future Work

The AI-driven Remote Expert System presented in this work demonstrates the transformative potential of integrating artificial intelligence (AI), mixed reality (MR), and natural language processing (NLP) technologies in industrial maintenance operations. By combining the YOLOv8s object detection algorithm with Microsoft HoloLens 2 mixed reality headsets, our system enables real-time inspection and malfunction detection of industrial equipment, such as PLCnext systems, without requiring on-site expertise.

Our experimental results validate the effectiveness of the YOLOv8s model in detecting LED status indicators, achieving a global mAP50 of 0.993 and mAP50-95 of 0.844. The model demonstrates high recall and precision metrics, particularly for the BF_D_red_flash error state, confirming its suitability for industrial applications. Field tests conducted at varying distances establish system reliability, with steady indicators being detected more accurately than flashing indicators due to processing latency considerations. This AI-driven Remote Expert System emphasizes how emerging technologies can address maintenance challenges in industrial environments. By enabling remote diagnostic capabilities and reducing reliance on on-site expertise, the system has

12

the potential to minimize equipment downtime, enhance operational efficiency, and reduce maintenance costs.

In the future, we will concentrate on three areas, including model accuracy enhancement, latency reduction, and industrial implementation. Despite the effectiveness of the YOLOv8s model, it needs refinement for detecting dynamic indicators. This requires diverse training data from various industrial settings with different lighting conditions, angles, and distances. Optimizing data transmission protocols through advanced compression, low-latency networks, and edge computing would reduce end-to-end delays. Finally, the work should be partnered with industrial facilities to test the system in operational environments, collecting feedback from technicians and supervisors.

Acknowledgment

This research was conducted at the Digital Media and Interaction Research Laboratory (DMI), Faculty of Informatics, Burapha University. We express our sincere gratitude for the grant and the support provided.

References

1. Li, Y., Zhang, H., Guo, F., Chen, Y., Wang, Y.: Integrating Attention Mechanisms into YOLOv8 for Improved Defect Detection in Acceptance Environments on HoloLens 2. In: 2024 3rd Asian Conference on Frontiers of Power and Energy (ACFPE), pp. 399–403 (2024)
2. Lysakowski, M., Żywanowski, K., Banaszczyk, A., Nowicki, M.R., Skrzypczyński, P., Tadeja, S.K.: Real-time onboard object detection for augmented reality. Enhancing head-mounted display with yolov8. In: 2023 IEEE International Conference on Edge Computing and Communications (EDGE), pp. 364–371 (2023)
3. Bahri, H., Krčmař, J.: Accurate object detection system on hololens using yolo algorithm. In: 2019 International Conference on Control, Artificial Intelligence, Robotics & Optimization (ICCAIRO), pp. 219–224 (2019)
4. Zhang, J.: Classification and Comparison of Data Augmentation Techniques. *Transactions on Computer Science and Intelligent Systems Research* (2024)
5. Jebraeeli, V., Jiang, B., Krim, H., Cansever, D.: Generative Expansion of Small Datasets. An Expansive Graph Approach. arXiv preprint arXiv:2406.17238 (2024)
6. Ekwaro-Osire, H., Ponugupati, S.L., Al Noman, A., Bode, D., Thoben, K.-D.: Data augmentation for numerical data from manufacturing processes. An overview of techniques and assessment of when which techniques work. *Industrial Artificial Intelligence* 3, 1–19 (2025)
7. Wu, J., Shen, F., Ye, L.: Data augmentation using time conditional variational autoencoder for soft sensor of industrial processes with limited data. *IEEE Transactions on Instrumentation and Measurement* (2024)
8. Kongon, B., Jantarakongkul, B., Jitngermadan, P.: Remote Expert AI System for Industrial Maintenance. A Technical Approach. In: 2024 8th International Conference on Information Technology (InCIT), pp. 669–674 (2024)