

การตรวจจับสีด้วยมุมมองสามมิติสีกรีน CMYK และการคัดแยกด้วย YOLOV8
สำหรับเครื่องติดฉลากแบบให้เข้า

CMYK SCREEN ANGLE-BASED DETECTION AND YOLOV8-BASED
CLASSIFICATION FOR RENTAL LABELING MACHINE

ชัชณวิชญ์ อัครไชยพงศ์

CHITSANUWIT AR-KARACHAIPHONG

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมอัตโนมัติ

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2567

KMITL-20XX-EN-X-XXX-XXX

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

CMYK SCREEN ANGLE-BASED DETECTION AND YOLOV8-BASED
CLASSIFICATION FOR RENTAL LABELING MACHINE



KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2025

KMITL-20XX-EN-X-XXX-XXX

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2025

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การตรวจจับสีด้วยมุมมองสามมิติสกรีน CMYK และการคัดแยกด้วย YOLOV8 สำหรับเครื่องติดฉลากแบบให้เข้า
นักศึกษา	นายชิษณุวิชญ์ อัครไชยพงศ์
รหัสประจำตัว	62601125
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมอัตโนมัติ
พ.ศ.	2567
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ผศ.ดร.กฤษณ์ เสมอพิทักษ์

บทคัดย่อ

เพื่อใช้ในการติดตามการใช้งานเครื่องติดฉลากให้เข้าแบบเรียลไทม์ งานวิจัยนี้นำเสนอเทคนิคทางวิศวกรรมสำหรับการตรวจจับและจำแนกฉลากสี Cyan (ฟ้าอมเขียว), Magenta (แดงอมม่วง), Yellow (เหลือง), และ Key (ดำ) หรือที่เรียกโดยรวมว่า CMYK ระหว่างกระบวนการติดฉลาก โดยใช้เซนเซอร์ตรวจจับสี RGB (Red, Green, Blue) เพื่อตรวจจับสีของฉลากเป้าหมาย ณ ตำแหน่งที่กำหนด จากนั้นส่งข้อมูลสี RGB ไปยังคอมพิวเตอร์เพื่อแปลงเป็นข้อมูลสีในระบบ CMYK

โมเดล YOLOV8 ถูกนำมาใช้ในการจำแนกประเภทของฉลาก CMYK เพื่อระบุชนิดของระบบการพิมพ์ว่าเป็นแบบ “ออฟเซต” (Offset) หรือ “เฟล็กโซ” (Flexo) โดยโมเดลดังกล่าวได้รับการฝึกด้วยชุดข้อมูลภาพฉลากออฟเซตจำนวน 2,000 ภาพ และฉลากเฟล็กโซจำนวน 2,000 ภาพ เมื่อฝึกโมเดลเสร็จแล้ว จะนำไปติดตั้งบนคอมพิวเตอร์อีกเครื่องที่ใช้ควบคุมเครื่องติดฉลากให้เข้า หากตรวจพบว่าเป็นฉลากประเภท “ออฟเซต” ระบบจะสั่งหยุดการทำงานของเครื่องติดฉลาก แต่หากตรวจพบว่าเป็นฉลาก “เฟล็กโซ” เครื่องจะยังคงทำงานต่อเนื่อง

จากผลการทดลองในห้องปฏิบัติการแสดงให้เห็นว่า โมเดล YOLOV8 ที่ผ่านการฝึกสามารถจำแนกข้อมูลสี CMYK ของฉลากเป้าหมายได้อย่างแม่นยำ โดยมีค่าความแม่นยำ (Precision) อยู่ที่ 94.1% และค่าการระลึก (Recall) อยู่ที่ 92% เมื่อเปรียบเทียบกับโมเดลอื่น ๆ (เช่น YOLOV5, Faster R-

CNN, R-FCN และ SSD) พบว่า YOLOV8 ให้ค่าความแม่นยำสูงสุดและใช้เวลาในการประมวลผลน้อยที่สุด อย่างไรก็ตาม เมื่อทดสอบในสถานที่จริงของลูกค้า ค่าความแม่นยำและการระลอกลดลงเหลือ 88% และ 86% ตามลำดับ เนื่องจากสภาพแสงแวดล้อมที่ไม่สามารถควบคุมได้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Thesis	CMYK SCREEN ANGLE-BASED DETECTION AND YOLOV8-BASED CLASSIFICATION FOR RENTAL LABELING MACHINE
Student	Mr. Chitsanuwit Ar-Karachaiphong
Student ID.	62601125
Degree	Master of Engineering
Program	Automation Engineering
Year	2024
Thesis Advisor	Asst. Prof. Dr. Krit Smerpitak

ABSTRACT

In order to monitor customers' usage of a rental labeling machine in real time, this thesis presents an engineering technique for detecting and classifying cyan, magenta, yellow, and key (black) CMYK color labels during the labeling process. A red, green, and blue (RGB) sensor is installed to detect the color of an interested label (called a target) at the specified area. Its output is sent to a personal computer to convert from RGB to CMYK color data. YOLOV8 is applied for classifying the CMYK color data of each target to identify the printing type, which is either 'Offset' or 'Flexo'. The YOLOV8 model was trained by a dataset of 2,000 images of 'Offset' labels and 2,000 images of 'Flexo' labels. The well-trained YOLOV8 model is then installed on another personal computer used for controlling a rental labeling machine. If the 'Offset' label is detected, the labeling machine will be stopped. On the other hand, if the 'Flexo' label is detected, the labeling machine will be continuously running. Experimental results at the testing lab show that using the trained YOLOV8 model can classify the target's CMYK data with a precision of 94.1% and a recall of 92%. Compared with other models (including YOLOV5, Faster R-CNN, R-FCN,

SSD), it is confirmed that the YOLOV8 provides the maximum precision and the shortest processing time. However, the precision and recall values of label classifications at the customer's site drop to 88% and 86%, respectively, because of uncontrolled ambient light conditions



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

ข้าพเจ้าขอแสดงความขอบคุณเป็นอย่างยิ่งต่อ ผศ. ดร.กฤษณ์ เสมอพิทักษ์ อาจารย์ที่ปรึกษา ที่ได้กรุณาให้คำแนะนำ แนวทาง และคำปรึกษาในการทำวิทยานิพนธ์ฉบับนี้อย่างใกล้ชิด และให้กำลังใจตลอดระยะเวลาของการศึกษา

ขอขอบคุณคณะอาจารย์และเจ้าหน้าที่ประจำคณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ที่ให้การสนับสนุนและเอื้อเฟื้อทรัพยากรต่าง ๆ อันเป็นประโยชน์ต่อการทำวิจัย

ขอขอบพระคุณครอบครัวของข้าพเจ้าที่ให้กำลังใจ ความเข้าใจ และสนับสนุนข้าพเจ้าทั้งทางด้านจิตใจและโอกาสต่าง ๆ มาโดยตลอด

สุดท้ายนี้ ข้าพเจ้าขอขอบคุณเพื่อนร่วมรุ่นและเพื่อนวิจัยทุกท่าน ที่คอยแลกเปลี่ยนความคิดเห็น และให้กำลังใจ ซึ่งมีส่วนสำคัญยิ่งต่อความสำเร็จของวิทยานิพนธ์ฉบับนี้

ชัชณวิชญ์ อัครไชยพงศ์

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในอุตสาหกรรมการพิมพ์ฉลาก (Label Printing) ได้มีการให้บริการเช่าเครื่องจักรประเภทเครื่องติดฉลาก (Labeling Machine) ซึ่งเป็นโมเดลธุรกิจที่ผู้ใช้งานสามารถเช่าเครื่องได้โดยไม่มีค่าใช้จ่าย หากผู้ใช้งานเลือกใช้งานสติกเกอร์ที่จำหน่ายโดยบริษัทเจ้าของเครื่อง อย่างไรก็ตาม ปัญหาที่พบในปัจจุบันคือ ผู้เช่าบางรายเลือกใช้งานฉลากจากบริษัทอื่น ซึ่งมักมีราคาสูงกว่า ส่งผลกระทบต่อระบบคิดค่าบริการ ทำให้บริษัทให้เช่าสูญเสียรายได้และต้องรับผิดชอบดูแลบำรุงรักษาเครื่อง โดยที่การสึกหรอควรสัมพันธ์กับจำนวนการสั่งสติกเกอร์

งานวิจัยนี้เสนอแนวทางการตรวจจับสีด้วยมุมมองสามมิติสี CMYK และการตัดแยกด้วย YOLOV8 เพื่อเพิ่มความสามารถในการตรวจสอบฉลากแบบอัตโนมัติในสายการผลิต โดยมุ่งเน้นที่การจำแนกความแตกต่างระหว่างฉลากที่พิมพ์ด้วยระบบ OFFSET และ FLEXO ผ่านการวิเคราะห์หมึกพิมพ์ของสีในระบบ CMYK จากนั้นจึงใช้โมเดล YOLOV8 ในการตรวจจับและจำแนกประเภทฉลากแบบเรียลไทม์ พร้อมควบคุมการทำงานของเครื่องผ่านระบบ PLC และ GUI ได้โดยอัตโนมัติ [1][2][3][4]

โรงงานผลิตสติกเกอร์



โรงงานเช่าเครื่องติดสติกเกอร์



รูปที่ 1.1 โมเดลธุรกิจของผู้เช่าเครื่องติดฉลาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


รูปที่ 1.1 แสดงโมเดลธุรกิจของผู้ผลิตและผู้เช่าเครื่องติดฉลากด้านบนเป็นกระบวนการผลิตสติ๊กเกอร์ฉลากจากโรงงานที่มีเครื่องพิมพ์ Flexo หรือ Offset ซึ่งเป็นแหล่งผลิตฉลากคุณภาพสูง ด้านล่างเป็นภาพของเครื่องติดฉลากแบบให้เช่าที่ใช้ฉลากม้วนกับสินค้าจริง หากลูกค้าใช้ฉลากที่ไม่ได้ผลิตจากโรงงานเจ้าของเครื่อง จะส่งผลกระทบต่อธุรกิจเช่าเครื่องและรายได้ของบริษัท

1.2 วัตถุประสงค์ของการวิจัย

นำเสนอเทคนิคทางวิศวกรรมเพื่อคัดแยกฉลากสี CMYK Cyan (ฟ้าอมเขียว), Magenta (แดงอมม่วง), Yellow (เหลือง), และ Key (ดำ) ที่พิมพ์มาจากเครื่องพิมพ์แบบ Flexo และ เครื่องพิมพ์แบบ Offset โดยตรวจจับด้วยมุมมองสามมิติสกรีนและการคัดแยกด้วย YOLOV8 สำหรับธุรกิจการให้เช่าเครื่องติดฉลากสี CMYK

1.3 ขอบเขตของการวิจัย


1. สร้างระบบตรวจจับสี RGB ของข้อมูลภาพฉลาก และแปลงเป็นสี CMYK ที่มีองศาเม็ดสกรีน
2. ใช้ YOLOV8 ในการคัดแยกข้อมูลภาพสี CMYK ด้วยองศาเม็ดสกรีน เพื่อจำแนกฉลากที่พิมพ์มาจากเครื่องพิมพ์แบบ Offset หรือ แบบ Flexo
3. ใช้ผลการจำแนกชนิดของฉลากในการควบคุมการทำงานของเครื่องติดฉลาก โดยที่เครื่องติดฉลากจะทำงานพิมพ์แบบ Flexo และจะหยุดทำงานเมื่อพิมพ์แบบ Offset



รูปที่ 1.2 โครงสร้างระบบตรวจเครื่องติดฉลาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 1.2 แสดงโครงสร้างระบบตรวจสอบฉลากในสายการผลิต โดยใช้กล้องอุตสาหกรรมและเซนเซอร์เพื่อตรวจจับมุมพิมพ์ฉลากแบบ Real-time หากตรวจพบข้อผิดพลาด มุมพิมพ์ไม่ถูกต้อง ระบบจะส่งสัญญาณหยุดเครื่องอัตโนมัติ



รูปที่ 1.3 การทำงานของ YOLOV8 ตรวจจับมุม CMYK

รูปที่ 1.3 แสดงตัวอย่างการทำงานของโมเดล YOLOV8 ในการจำแนกฉลากตามลักษณะมุมพิมพ์ของแม่สี CMYK โดยแยกองค์ประกอบของแต่ละแม่สีและมุมการพิมพ์ เช่น Cyan, Magenta, Yellow และ Key (Black) เพื่อแยกฉลากประเภท Flexo กับ Offset ได้อย่างแม่นยำ

1.4 วิธีการดำเนินงานโดยสังเขป

1. เก็บข้อมูลภาพจากฉลากต้นฉบับและฉลากจากการใช้งานจริง
2. แปลงภาพ RGB เป็น CMYK เพื่อวิเคราะห์มุมพิมพ์ของแม่สีแต่ละช่อง
3. วิเคราะห์ความแตกต่างของระบบ OFFSET และ FLEXO
4. ฝึกโมเดล YOLOV8 เพื่อตรวจจับตำแหน่งและรูปแบบมุมพิมพ์
5. เชื่อมต่อระบบกับ GUI และ PLC ผ่าน VB.NET และ MX Component เพื่อควบคุมเครื่องจักร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.5 ข้อจำกัดของการวิจัย

1. ระบบทำงานได้กับฉลากที่พิมพ์ด้วยระบบ CMYK แบบจุดสกรีนเท่านั้น
2. โมเดล YOLOV8 ต้องใช้ข้อมูลที่หลากหลายและแม่นยำสูง
3. ระบบฝังต้องมีขนาดเล็ก ไม่กระทบการทำงาน และผู้ใช้เครื่องไม่สามารถสังเกตเห็นได้

1.6 ผลที่คาดว่าจะได้รับ

1. เพิ่มความมั่นใจในการควบคุมการใช้งานเครื่องจักรตามสัญญาเช่า
2. ลดการนำฉลากจากภายนอกมาใช้งานผิดข้อตกลง
3. เพิ่มความสามารถการควบคุมอัตโนมัติในระบบ Smart Labeling Machine

1.7 นิยามศัพท์เฉพาะ

- OFFSET: ระบบการพิมพ์ที่ใช้เพลทอลูมิเนียม แยกสี และส่งผ่านหมึกลงกระดาษผ่านแผ่นยาง (Rubber Blanket)
- FLEXO: ระบบการพิมพ์ที่ใช้เพลทยาง มีความยืดหยุ่น พิมพ์บนวัสดุหลากหลาย เช่น ฟิล์มพลาสติก
- CMYK: ระบบสีที่ใช้ในงานพิมพ์ ประกอบด้วย Cyan, Magenta, Yellow และ Black
- YOLOV8: โมเดลวิเคราะห์ภาพแบบเรียลไทม์ ใช้สำหรับตรวจจับวัตถุและจำแนกประเภทในภาพ
- PLC: ระบบควบคุมการทำงานของเครื่องจักรในอุตสาหกรรม

1.8 โครงสร้างของรายงาน


- บทที่ 1 บทนำ กล่าวถึงความเป็นมา วัตถุประสงค์ ขอบเขต และประโยชน์ที่คาดว่าจะได้รับ
- บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง ทบทวนทฤษฎีและงานวิจัย เช่น ระบบการพิมพ์ CMYK เทคนิค OFFSET/FLEXO และ YOLOV8
- บทที่ 3 วิธีดำเนินการวิจัย อธิบายขั้นตอนการเก็บข้อมูล ประมวลผล และการเชื่อมต่อกับ PLC
- บทที่ 4 ผลการทดลอง แสดงผลลัพธ์และประสิทธิภาพของระบบ
- บทที่ 5 สรุปผลและข้อเสนอแนะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.9 แผนการดำเนินงานวิจัย

เดือน รายการดำเนินงาน

- 1 ศึกษาทฤษฎีที่เกี่ยวข้อง, เก็บข้อมูลเบื้องต้น
- 2 แปลงภาพ RGB เป็น CMYK และเตรียม Dataset
- 3 ฝึกโมเดล YOLOV8 และทดสอบเบื้องต้น
- 4 เชื่อมต่อ API กับ GUI และ PLC
- 5 ทดสอบระบบในสถานการณ์จริง, วิเคราะห์ผล
- 6 สรุปผล เขียนรายงาน และเตรียมการนำเสนอ



รูปที่ 1.4 แผนภูมิ Gantt แสดงระยะเวลาดำเนินงานวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 ระบบสีและการพิมพ์


ระบบสี CMYK (Cyan, Magenta, Yellow, Black) เป็นมาตรฐานที่ใช้ในงานพิมพ์แบบแยกสี ซึ่งแตกต่างจากระบบ RGB (Red, Green, Blue) ที่ใช้สำหรับอุปกรณ์แสดงผลบนหน้าจอ CMYK สามารถผสมสีบนวัสดุพื้นขาว เช่น กระดาษหรือพลาสติก เพื่อสร้างเฉดสีต่าง ๆ ได้อย่างเหมาะสมกับการพิมพ์ ฉลากสินค้า [1][2]

ในกระบวนการพิมพ์แบบ OFFSET และ FLEXP การวางมุมของเม็ดสีแต่ละสีมีผลอย่างมากต่อความคมชัดและการลดทอน moiré โดย OFFSET ใช้มุมมาตรฐาน เช่น C: 15°, M: 75°, Y: 0°, K: 45° ส่วน FLEXP มีการปรับมุมให้หลีกเลี่ยงการทับซ้อนกับลูกกลิ้ง anilox เช่น C: 7.5°, M: 67.5°, Y: 82.5°, K: 37.5° [1][2]

แสดงให้เห็นว่า การวิเคราะห์ลักษณะของมุมพิมพ์สามารถใช้เป็นปัจจัยในการจำแนกประเภทการพิมพ์ได้ และสามารถนำมาใช้ในงานตรวจสอบฉลากด้วยระบบอัตโนมัติ โดยเฉพาะเมื่อร่วมกับเทคนิคการประมวลผลภาพและการแปลงค่าสีจาก RGB \rightarrow CMYK


การแปลงจาก RGB ไปยัง CMYK สามารถใช้สูตรมาตรฐาน เช่น $K = 1 - \max(R', G', B')$; $C = (1 - R' - K)/(1 - K)$; $M = (1 - G' - K)/(1 - K)$; $Y = (1 - B' - K)/(1 - K)$ ซึ่งช่วยให้สามารถคำนวณมุมสกรีนและวิเคราะห์ลักษณะของงานพิมพ์ได้อย่างแม่นยำ [3][4]

จากงานวิจัยที่เกี่ยวข้องในประเทศไทย พบว่า งานวิจัยส่วนใหญ่เน้นการประมวลผลภาพในงานอุตสาหกรรม แต่ยังไม่มีการนำแนวคิดเรื่องมุมพิมพ์มาใช้ตรวจสอบประเภทของฉลากเชิงอัตโนมัติ ซึ่งถือเป็นจุดแข็งของงานวิจัยฉบับนี้



รูปที่ 2.1 วงล้อสี RGB vs CMYK

รูปที่ 2.1 แสดงเปรียบเทียบระหว่างระบบสี RGB และ CMYK วงล้อด้านซ้ายเป็นระบบ RGB (Red, Green, Blue) ซึ่งใช้ในอุปกรณ์แสดงผล เช่น จอภาพ โทรทัศน์ หรือกล้อง ส่วนวงล้อด้านขวาเป็นระบบ CMYK (Cyan, Magenta, Yellow, Key/Black) ซึ่งใช้ในกระบวนการพิมพ์ เช่น Flexo และ Offset การแปลงจาก RGB \rightarrow CMYK เป็นขั้นตอนสำคัญในการเตรียมข้อมูลภาพสำหรับวิเคราะห์หมึกพิมพ์ในงานวิจัยนี้ [3]



รูปที่ 2.2 ตารางเปรียบเทียบมุมสกรีนของ CMYK [2]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 2.2 แสดงตารางเปรียบเทียบมุมพิมพ์ของแม่สี CMYK ระหว่างระบบการพิมพ์ Offset และ Flexo โดย Offset ใช้ค่ามุมมาตรฐาน เช่น C: 15°, M: 75°, Y: 90°, K: 45° ส่วน Flexo มีการปรับมุมให้แตกต่างกัน เช่น C: 7.5°, M: 67.5°, Y: 82.5°, K: 37.5° เพื่อหลีกเลี่ยงลายซ้อน (Moiré Pattern)

ความแตกต่างนี้ถูกนำมาใช้เป็นฟีเจอร์หลักในการจำแนกประเภทผลากผ่านกระบวนการประมวลผลภาพและโมเดล YOLOV8 [2][3][4][5]

2.2 ระบบการแปลงสี RGB → CMYK

ระบบสี RGB (Red, Green, Blue) เป็นระบบสีที่ใช้งานในอุปกรณ์แสดงผล เช่น กล้องดิจิทัล, หน้าจอคอมพิวเตอร์ และเซนเซอร์ภาพทั่วไป เนื่องจากเป็นระบบที่สามารถแสดงสีโดยการเปล่งแสง (Additive Color Model) แต่ในการพิมพ์ผลากนั้น จำเป็นต้องแปลงข้อมูลจาก RGB ไปสู่ระบบ CMYK ซึ่งเป็นระบบสีที่ใช้สำหรับงานพิมพ์ (Subtractive Color Model) เพื่อให้สามารถควบคุมเฉดสีที่พิมพ์บนวัสดุจริงได้อย่างถูกต้อง

การแปลงค่าสีจาก RGB เป็น CMYK ต้องผ่านกระบวนการคำนวณและการจัดการสี โดยทั่วไปใช้สูตรมาตรฐาน เช่น:

$$K = 1 - \max(R', G', B') \quad (1)$$

$$C = (1 - R' - K) / (1 - K) \quad (2)$$

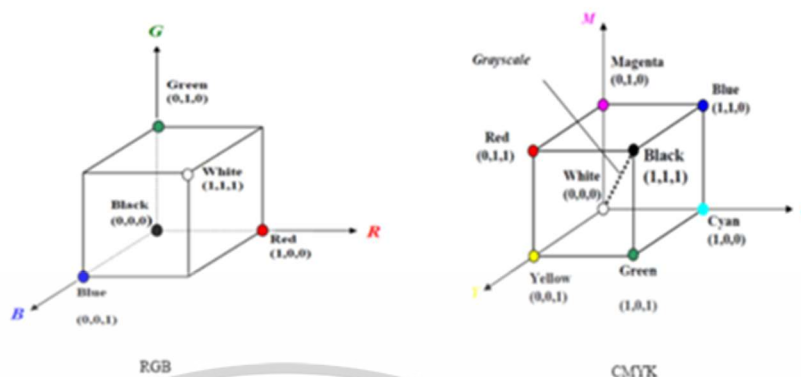
$$M = (1 - G' - K) / (1 - K) \quad (3)$$

$$Y = (1 - B' - K) / (1 - K) \quad (4)$$

โดยที่ R', G', B' คือค่าที่ได้จากการปรับความเข้มของ RGB ให้อยู่ในช่วง 0 ถึง 1 เพื่อให้สามารถคำนวณได้ตามโมเดลของระบบพิมพ์จริง

นอกจากนี้ยังสามารถใช้ ICC Profile ในการจัดการค่าสีเพื่อให้ได้ผลลัพธ์ที่สอดคล้องกับมาตรฐานอุตสาหกรรม โดยเฉพาะเมื่อระบบพิมพ์และวัสดุมีความแตกต่างกัน การใช้การจัดการสีที่เหมาะสมจึงเป็นสิ่งสำคัญ

ในการประมวลผลภาพสำหรับงานวิจัยฉบับนี้ ภาพ RGB จากกล้อง Basler จะถูกแปลงเป็นข้อมูล CMYK เพื่อใช้ในการวิเคราะห์มุมการพิมพ์ โดยอิงตามเม็ดสีที่ปรากฏอยู่ในภาพผลากจริง ซึ่งเป็นพื้นฐานในการระบุประเภทการพิมพ์ FLEXO หรือ OFFSET



รูปที่ 2.3 ตัวอย่างการแปลง RGB \rightarrow CMYK และการวิเคราะห์มูมพิมพ์

รูปที่ 2.3 แสดงการเปรียบเทียบปริภูมิสีของระบบ RGB และ CMYK เพื่อแสดงขั้นตอนการแปลงสีและแนวทางการวิเคราะห์ ด้านซ้ายเป็นปริภูมิสี RGB ซึ่งใช้ในกล้องและหน้าจอ มีการวัดค่าสีโดยพิกัด R, G, B ด้านขวาแสดงปริภูมิของระบบ CMYK ซึ่งใช้ในงานพิมพ์ โดยมีแม่สี Cyan, Magenta, Yellow และ Black เป็นแกนหลักในการวิเคราะห์ การแปลงภาพจาก RGB \rightarrow CMYK และการตั้งค่าทิศทางของแม่สีในระบบ CMYK นี้มีบทบาทสำคัญในการวิเคราะห์มูมสกรีนในงานวิจัยนี้ [3]

2.3 ปัญหาและข้อจำกัดในกระบวนการพิมพ์


แม้ว่าระบบการพิมพ์แบบ CMYK ทั้งในรูปแบบ OFFSET และ FLEXO จะมีความแม่นยำและประสิทธิภาพสูง แต่ก็ยังคงมีข้อจำกัดที่อาจส่งผลกระทบต่อคุณภาพของฉลาก และเป็นอุปสรรคต่อการตรวจสอบความถูกต้องของฉลากโดยอัตโนมัติ

หนึ่งในปัญหาสำคัญคือ การเกิดลาย "moiré pattern" ซึ่งเกิดจากการวางมูมพิมพ์ของเม็ดสีแต่ละสีในลักษณะที่ไม่เหมาะสม ทำให้เกิดลวดลายรบกวนหรือความไม่สม่ำเสมอบนพื้นผิวของฉลาก ซึ่งอาจทำให้ระบบประมวลผลภาพแยกแยะลวดลายได้ยาก

นอกจากนี้ยังมีข้อจำกัดที่เกี่ยวข้องกับวัสดุที่ใช้พิมพ์ เช่น พลาสติกหรือกระดาษที่มีผิวมันหรือหยาบเกินไป อาจส่งผลกระทบต่อการดูดซึมสีและความคมชัดของภาพ ทำให้เกิดความคลาดเคลื่อนในกระบวนการแปลงสีจาก RGB ไปเป็น CMYK

ในกรณีของระบบ FLEXO การควบคุมความหนาของหมึกและแรงกดจากลูกกลิ้ง anilox มีผลต่อความเข้มของสีที่ปรากฏ ซึ่งหากไม่ควบคุมอย่างสม่ำเสมออาจทำให้เกิดความแตกต่างของฉลากในแต่ละรอบการผลิต

จากข้อจำกัดข้างต้น ระบบการตรวจสอบฉลากที่ใช้ Machine Learning จำเป็นต้องออกแบบให้สามารถจัดการกับความคลาดเคลื่อนทางกายภาพ และความแปรผันของสีในระดับที่เหมาะสม ซึ่งเป็นความท้าทายหลักของการวิจัยในบริบทนี้



รูปที่ 2.4 ตัวอย่างลาย moiré และความผิดพลาดจากการพิมพ์จริง

รูปที่ 2.4 แสดงตัวอย่างลายซ้อน (moiré) และข้อผิดพลาดที่เกิดจากการตั้งมุมพิมพ์ไม่เหมาะสมในระบบพิมพ์แบบ CMYK ภาพด้านซ้ายแสดงทิศทางของเม็ดสกรีนแม่สีที่ไม่ถูกปรับมุมให้เหมาะสม ทำให้เกิดลายแทรกซ้อนที่มองเห็นได้ชัดเจน ส่วนภาพด้านขวาแสดงผลที่เกิดขึ้นกับงานพิมพ์จริง เช่น ภาพบุคคลที่มีลายรบกวนและการเบลอของสี ปรากฏการณ์นี้เป็นหนึ่งในปัจจัยสำคัญที่ระบบ AI ในงานวิจัยนี้ถูกออกแบบมาเพื่อตรวจจับและคัดกรอง [2][3][9]

2.4 เทคโนโลยี Machine Learning สำหรับการตรวจสอบภาพ

การนำเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) โดยเฉพาะเทคนิค Machine Learning มาใช้ในการตรวจสอบคุณภาพของฉลากเป็นแนวทางที่ได้รับความสนใจอย่างมากใน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะในรูปแบบใดก็ตาม อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


อุตสาหกรรมยุคใหม่ เนื่องจากสามารถช่วยลดความผิดพลาดจากมนุษย์ เพิ่มความเร็ว และตรวจจับข้อบกพร่องที่ซับซ้อนเกินกว่าที่ตามนุษย์จะมองเห็นได้

หนึ่งในเทคนิคที่ได้รับความนิยมคือ Convolutional Neural Network (CNN) ซึ่งเป็นโครงข่ายประสาทเทียมเชิงลึก ที่มีความสามารถในการเรียนรู้คุณลักษณะ (features) จากภาพโดยอัตโนมัติ และสามารถนำไปใช้จำแนกประเภทของวัตถุหรือฉากได้อย่างแม่นยำ

สำหรับงานวิจัยนี้ ได้เลือกใช้โมเดล YOLOV8 (You Only Look Once รุ่นที่ 8) ซึ่งเป็นหนึ่งในโมเดล CNN ที่สามารถตรวจจับวัตถุแบบ Real-time โดยสามารถประมวลผลภาพและบ่งชี้ตำแหน่งของวัตถุในภาพได้อย่างรวดเร็วและแม่นยำ YOLOV8 ได้รับการปรับปรุงจากรุ่นก่อนหน้าในหลายด้าน เช่น ความเบา (Lightweight), ความแม่นยำ (Accuracy), และรองรับการ deploy บนอุปกรณ์ Edge เช่น Jetson หรือ Raspberry Pi

โดยสถาปัตยกรรมของ YOLOV8 ประกอบด้วย Backbone สำหรับดึงคุณลักษณะ, Neck สำหรับรวมและขยาย feature maps, และ Head สำหรับการคาดคะเน bounding box และ class ซึ่งทั้งหมดสามารถฝึกได้แบบ End-to-End จากชุดข้อมูลที่มีการ Annotate อย่างเหมาะสม

เมื่อผสาน YOLOV8 เข้ากับระบบประมวลผล RGB \rightarrow CMYK ที่กล่าวไว้ในหัวข้อก่อนหน้านี้ ระบบตรวจสอบฉากที่ได้จะสามารถตรวจจับและวิเคราะห์ความถูกต้องของมุมพิมพ์ในฉากได้อย่างชาญฉลาดและอัตโนมัติ



รูปที่ 2.5 สถาปัตยกรรมของ YOLOV8 ที่ใช้ในงานวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 2.5 แสดงสถาปัตยกรรมภายในของโมเดล YOLOV8 ที่ใช้ในงานวิจัยโดยแบ่งออกเป็น 3 ส่วนหลัก ได้แก่ Backbone, Neck และ Head

Backbone ทำหน้าที่ดึงฟีเจอร์จากภาพผลากผ่านโครงข่าย Convolution และ C2f Layers หลายระดับ

Neck ทำการรวมฟีเจอร์และ Unsampled เพื่อปรับขนาดให้เหมาะกับการตรวจจับ

Head เป็นส่วนที่ทำหน้าที่ตรวจจับวัตถุ และส่งออกผลลัพธ์การจำแนก (Bounding Box + Class Label) พร้อมค่าความมั่นใจ สถาปัตยกรรมนี้ถูกฝึกสอนด้วยข้อมูล CMYK ที่แปลงแล้ว เพื่อใช้จำแนกประเภทผลาก Offset และ Flexo ได้อย่างแม่นยำและรวดเร็ว [3][4] [5][6]

2.5 ระบบการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้ในการตรวจจับงานพิมพ์

ระบบการเรียนรู้ของเครื่อง (Machine Learning) เป็นหัวใจสำคัญในการตรวจจับงานพิมพ์ในระบบอัตโนมัติ โดยเฉพาะอย่างยิ่งเมื่อพูดถึงภาพพิมพ์ที่มีความซับซ้อน เช่น ลวดลายที่มีลักษณะจุดพิมพ์ขนาดเล็ก หรือการวางเม็ดสีแบบ Half-tone ซึ่งไม่สามารถแยกแยะด้วยวิธี Threshold แบบดั้งเดิมได้อย่างแม่นยำ การนำเทคโนโลยี Convolutional Neural Networks (CNN) เข้ามาช่วยทำให้ระบบสามารถเรียนรู้ลักษณะเฉพาะของภาพพิมพ์ และแยกแยะความแตกต่างระหว่างภาพที่ถูกต้องและผิดพลาดได้อย่างแม่นยำและอัตโนมัติ

ในงานวิจัยนี้ ได้ประยุกต์ใช้ YOLOV8 ซึ่งเป็นโครงข่ายการเรียนรู้ที่พัฒนาต่อจาก YOLO รุ่นก่อน โดยมีการเพิ่มประสิทธิภาพในการตรวจจับวัตถุในระดับเฟรมต่อวินาที (FPS) ที่สูงขึ้นและรองรับความละเอียดของภาพที่มากขึ้น YOLOV8 เหมาะสมกับการใช้งานในระบบตรวจจับแบบ Real-time ที่ต้องการประมวลผลภาพจากกล้องอุตสาหกรรมความเร็วสูง พร้อมระบุตำแหน่งของจุดผิดพลาดในงานพิมพ์ทันที

ข้อได้เปรียบของการใช้ YOLOV8 ได้แก่ โครงสร้างที่รวดเร็ว กระชับ และสามารถปรับแต่งเพื่อให้เข้ากับชุดข้อมูลขนาดเล็กได้ ซึ่งเหมาะสมกับลักษณะของข้อมูลงานพิมพ์ที่ต้องการตรวจสอบเฉพาะบางจุดหรือบางประเภทของผลาก เช่น มุมจุดพิมพ์หรือความสม่ำเสมอของเม็ดสี ทั้งนี้ยังสามารถฝึกโมเดลร่วมกับภาพจริงที่ได้จากงานพิมพ์ของลูกค้า เพื่อเพิ่มความแม่นยำในสภาพแวดล้อมจริงได้อีกด้วย

2.6 ระบบ GUI และการควบคุมผ่าน PLC

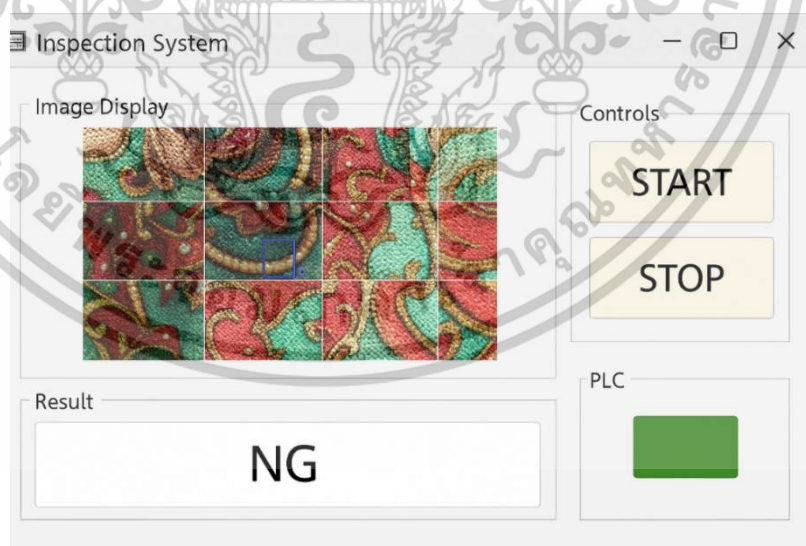
ในระบบตรวจสอบผลากด้วยเทคโนโลยี Machine Learning การออกแบบส่วนติดต่อผู้ใช้งาน (Graphical User Interface: GUI) และการเชื่อมต่อกับระบบควบคุมจริง เช่น PLC (Programmable Logic Controller) มีบทบาทสำคัญในการนำผลลัพธ์จากการประมวลผลภาพไปใช้งานจริงในสายการผลิต

GUI ช่วยให้ผู้ใช้ปฏิบัติงานสามารถดูผลการตรวจสอบของระบบได้แบบ Real-time ไม่ว่าจะเป็นที่นั่งผลากที่ผิดพลาด ประเภทของงานพิมพ์ หรือเปอร์เซ็นต์ความมั่นใจของโมเดล พร้อมทั้งสามารถแสดงภาพประกอบและข้อมูลที่จำเป็นเพื่อการตัดสินใจ

ในขณะที่ PLC ทำหน้าที่ควบคุมการทำงานของเครื่องจักร เช่น การหยุดสายพาน, การคัดแยกผลากที่ผิดพลาด, หรือการส่งสัญญาณเตือน การเชื่อมต่อระหว่างระบบ YOLOV8 และ PLC จึงต้องอาศัยการสื่อสารผ่านโปรโตคอลมาตรฐาน เช่น Modbus, OPC หรือการเชื่อมต่อแบบ I/O Digital

ระบบที่พัฒนาในงานวิจัยนี้ใช้การสื่อสารแบบ TCP/IP ระหว่างคอมพิวเตอร์ที่ประมวลผลภาพกับ PLC ผ่าน Gateway ที่ทำหน้าที่แปลคำสั่ง โดยผลลัพธ์จาก YOLOV8 จะถูกส่งผ่าน GUI ที่พัฒนาในภาษา Python และเชื่อมโยงกับระบบควบคุมผ่าน API เพื่อสร้างระบบอัตโนมัติแบบครบวงจร

การออกแบบ GUI ที่ดีไม่เพียงแต่ต้องแสดงข้อมูลได้อย่างถูกต้องและครบถ้วน แต่ยังต้องใช้งานง่าย รองรับการปรับปรุงในอนาคต และสามารถขยายระบบไปยังโรงงานอื่นได้



รูปที่ 2.6 ตัวอย่างหน้าจอ GUI และการเชื่อมต่อกับ PLC

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 2.6 แสดงตัวอย่างหน้าจอของระบบ GUI ที่ใช้แสดงผลการตรวจสอบฉลาก ส่วนบนซ้าย แสดงภาพที่ได้จากกล้องซึ่งผ่านการแปลงเป็นข้อมูล CMYK และจำแนกโดยโมเดล YOLOV8 ส่วนล่าง แสดงผลลัพธ์ (Result) เช่น NG (Not Good) หรือ OK ตามประเภทฉลากที่ตรวจพบ ด้านขวาเป็นปุ่มควบคุม (START / STOP) และสถานะการเชื่อมต่อกับ PLC ซึ่งใช้สั่งงานสายพานและหยุดเครื่องอัตโนมัติ เมื่อพบฉลากผิดประเภท

2.7 งานวิจัยที่เกี่ยวข้องในต่างประเทศ

ในช่วงไม่กี่ปีที่ผ่านมา มีงานวิจัยจำนวนมากที่ได้นำเทคนิคปัญญาประดิษฐ์มาใช้ในกระบวนการควบคุมคุณภาพฉลากและงานพิมพ์ โดยเฉพาะการใช้เทคนิคการประมวลผลภาพและการเรียนรู้ของเครื่อง (Machine Learning) เช่น Convolutional Neural Networks (CNN) และ YOLO (You Only Look Once) เพื่อวิเคราะห์ความผิดพลาดของฉลากอย่างแม่นยำ

Huang et al. [8] ได้พัฒนาระบบตรวจสอบฉลากอัตโนมัติบนสายพานลำเลียงโดยใช้ Deep Convolutional Networks ซึ่งสามารถแยกแยะตำแหน่งของฉลากได้อย่างแม่นยำในสภาพแวดล้อมจริง

Redmon et al. [9] ได้นำเสนอ YOLO ซึ่งเป็นโมเดลแบบ Real-time สำหรับตรวจจับวัตถุที่มีความเร็วและความแม่นยำสูง ต่อมา Ultralytics [11] ได้พัฒนา YOLOV5 และ YOLOV8 ซึ่งเพิ่มความสามารถด้านความแม่นยำและประสิทธิภาพการประมวลผลให้สามารถใช้งานในอุตสาหกรรมได้จริง

งานวิจัยของ Ullah [7] ยังแสดงให้เห็นถึงความสามารถของ YOLO ในการประยุกต์ใช้กับอุปกรณ์คอมพิวเตอร์ทั่วไป โดยสามารถตรวจจับวัตถุแบบเรียลไทม์บน CPU ได้สำเร็จ ขณะที่ Mittal et al. [7] ได้เสนอระบบ Object Detection ที่สามารถประยุกต์กับกล้องและระบบสายการผลิตได้โดยตรง

Bertacchi และ Silveira [5] ได้เสนอการตรวจจับการแต่งหน้าบนใบหน้าด้วยการใช้โมเดล CNN บน Color Space แบบ CMYK ซึ่งแสดงให้เห็นถึงศักยภาพของการใช้ CMYK กับงานด้านภาพ

Khalid et al. [3] และ Anilkumar et al. [4] ได้ทำการเปรียบเทียบ Color Space ระหว่าง CMYK กับระบบสีอื่นในการตรวจจับและจำแนกวัตถุ พบว่า CMYK มีความสามารถในการแยกแยะเฉดสีที่มนุษย์มองเห็นได้ชัดเจน โดยเฉพาะในการวิเคราะห์งานพิมพ์ที่มีโครงสร้างซับซ้อน

นอกจากนี้ Amas et al. [1] ยังได้ศึกษาการเสื่อมสภาพของลูกกลิ้ง Anilox ที่ใช้ในเครื่องพิมพ์ FLEXO ซึ่งมีผลต่อคุณภาพของการพิมพ์และลวดลายของจุดพิมพ์ อีกทั้ง Stefano [2] ยังได้วิเคราะห์หมุมของจุดพิมพ์ในระบบ FLEXO โดยให้ข้อมูลที่สำคัญในการตั้งค่าการพิมพ์ให้เกิดความคมชัดสูงสุด

จากเอกสารข้างต้น สามารถสรุปได้ว่า ยังไม่มีงานวิจัยใดที่เน้นการ ตรวจสอบมูมพิมพ์ของเม็ดสี CMYK จากฉลากจริงที่พิมพ์ในระบบ FLEXO และ OFFSET โดยตรง ดังเช่นงานวิจัยฉบับนี้ ซึ่งถือเป็นจุดเด่นและเป็นนวัตกรรมใหม่ที่เพิ่มขีดความสามารถของระบบตรวจสอบฉลากอัตโนมัติในอุตสาหกรรมบรรจุภัณฑ์

2.8 งานวิจัยที่เกี่ยวข้องในประเทศไทย

ในประเทศไทยมีการศึกษาและพัฒนาระบบตรวจสอบคุณภาพของผลิตภัณฑ์ด้วยเทคโนโลยีการประมวลผลภาพและปัญญาประดิษฐ์เพิ่มขึ้นอย่างต่อเนื่อง โดยเฉพาะในภาคอุตสาหกรรมอิเล็กทรอนิกส์ บรรจุภัณฑ์ และการพิมพ์อย่างไรก็ตามส่วนใหญ่ของงานวิจัยที่พบยังคงใช้เทคนิคแบบดั้งเดิมเช่น Threshold, Edge Detection, หรือ Morphological Operations ซึ่งเหมาะสมกับตำหนิที่มีลักษณะชัดเจน แต่ยังคงขาดประสิทธิภาพเมื่อต้องตรวจจับตำหนิซับซ้อน เช่น มูมเม็ดพิมพ์ หรือสีผสมแบบ Halftone ตัวอย่างงานวิจัยที่มีความใกล้เคียง เช่น

งานของ W.Cheamsiri et al. (2024) ได้นำโมเดล YOLOV5 และ YOLOV8 มาประยุกต์ใช้ในการตรวจจับตำหนิใน Flip-Chip ด้วยภาพ X-ray โดยเปรียบเทียบกับผลงานของผู้ตรวจสอบที่มีประสบการณ์ พบว่าโมเดล Deep Learning มีประสิทธิภาพสูงกว่าในหลายกรณี [11]

งานของ M.Kazmi et al. (2022) นำเสนอโซลูชันการตรวจสอบฉลากสินค้าบนขวดพลาสติกในบริบท Industry 4.0 โดยใช้ CNN และ Object Detection เพื่อประเมินตำแหน่งและคุณภาพของฉลากแบบเรียลไทม์ [12]

แม้จะมีการใช้ Deep Learning อย่างแพร่หลายมากขึ้น แต่ยังไม่พบงานวิจัยใดในประเทศไทยที่เน้นการวิเคราะห์มูมการพิมพ์ของเม็ดสีในระบบ CMYK โดยตรง หรือการแปลงภาพ RGB → CMYK จากฉลากจริงเพื่อใช้เป็น Feature ในการฝึกโมเดล YOLO ด้วยเหตุนี้ งานวิจัยฉบับนี้จึงถือเป็นก้าวสำคัญ โดยเสนอการผสมผสานระหว่างการแปลงข้อมูลเชิงสี (Color Space Conversion), การตรวจสอบมูมพิมพ์, และการตรวจจับวัตถุแบบ Real-time เพื่อใช้ในการตรวจสอบฉลากที่พิมพ์ด้วยระบบ FLEXO และ OFFSET อย่างแม่นยำ ซึ่งเป็นแนวทางที่ยังไม่ปรากฏในการศึกษาของไทยก่อนหน้านี้

นอกจากนี้ การเชื่อมโยงโมเดล AI เข้ากับระบบควบคุมอัตโนมัติผ่าน PLC ยังช่วยผลักดันการประยุกต์ใช้จริงภาคอุตสาหกรรม ซึ่งจะถูกนำเสนอรายละเอียดในบทที่ 3 และ 4 ของวิทยานิพนธ์ฉบับนี้

2.9 ช่องว่างของงานวิจัย (Research Gap)

จากการทบทวนวรรณกรรมทั้งในระดับสากลและระดับประเทศ สามารถสรุปได้ว่ามีความพยายามมากมายในการพัฒนาระบบตรวจสอบคุณภาพงานพิมพ์ โดยเฉพาะในด้านของการตรวจจับฉลากและตำหนิที่อาจเกิดขึ้นในสายการผลิต เช่น การวางตำแหน่งผิด, สีพิมพ์เบี้ยว, หรือภาพซ้อนจากความคลาดเคลื่อนของมุมพิมพ์ อย่างไรก็ตาม ยังมี "ช่องว่างสำคัญ" ที่ยังไม่มีงานวิจัยใดกล่าวถึงอย่างชัดเจน ได้แก่:

- การวิเคราะห์มุมพิมพ์ของเม็ดสี CMYK จาก Artwork จริง
- การประยุกต์ใช้ YOLOV8 ในการวิเคราะห์ฉลากพิมพ์จากระบบ FLEXO และ OFFSET
- การรวมระบบ RGB → CMYK เข้ากับการตรวจสอบเชิงลึกโดย AI
- การส่งต่อผลลัพธ์จากระบบตรวจสอบไปยังระบบควบคุม (PLC) แบบ Real-time

ช่องว่างเหล่านี้เป็นประเด็นที่งานวิจัยฉบับนี้มุ่งเน้น เพื่อเติมเต็มขอบเขตความรู้เดิม และนำเสนอระบบที่สามารถใช้งานได้จริงในสายการผลิตฉลากภาคอุตสาหกรรม โดยมีการออกแบบชุดข้อมูล, ฝึกโมเดล, พัฒนา GUI, และสื่อสารกับระบบควบคุมอย่างครบวงจร

2.10 แนวโน้มและทิศทางของเทคโนโลยีในอนาคต

แนวโน้มของเทคโนโลยีการตรวจสอบฉลากและงานพิมพ์ในภาคอุตสาหกรรมมีแนวโน้มเติบโตอย่างรวดเร็ว โดยเฉพาะเมื่อเทคโนโลยีด้าน Machine Learning และ Computer Vision ได้รับการพัฒนาอย่างต่อเนื่อง แนวทางการวิเคราะห์ภาพจากข้อมูล RGB และการแปลงเป็น CMYK เพื่อวิเคราะห์ลักษณะมุมพิมพ์ ถือเป็นแนวคิดใหม่ที่มีศักยภาพสูงในการประยุกต์ใช้ในสายการผลิตจริง

นอกจากนั้น เทคโนโลยี Edge AI ซึ่งเป็นการนำโมเดลปัญญาประดิษฐ์ไปประมวลผลบนอุปกรณ์ปลายทาง เช่น Jetson Nano, Raspberry Pi หรือ Embedded PC ก็กำลังได้รับความนิยมมากขึ้น เนื่องจากสามารถลดเวลาในการส่งข้อมูลไปยังเซิร์ฟเวอร์ และเพิ่มความเร็วในการตัดสินใจ ทำให้เหมาะสมกับการใช้งานแบบ Real-time

ในอนาคต การรวมระบบ AI ตรวจสอบภาพเข้ากับ PLC และ MES (Manufacturing Execution System) จะช่วยให้ระบบสามารถวิเคราะห์ แจ้งเตือน และควบคุมการทำงานของเครื่องจักรได้อย่างอัตโนมัติ ซึ่งจะเป็นจุดเปลี่ยนสำคัญของการผลิตแบบอัจฉริยะ (Smart Factory) และตอบโจทย์ยุคอุตสาหกรรม 4.0

ดังนั้น งานวิจัยที่ใช้ YOLOV8 ควบคู่กับการวิเคราะห์หมึกพิมพ์จึงเป็นจุดเริ่มต้นของการประยุกต์ใช้นวัตกรรมใหม่ในสายการผลิตจริง และสามารถต่อยอดไปสู่การตรวจสอบที่ละเอียดขึ้น เช่น การจำแนกประเภทของฉลากอัตโนมัติ หรือการประเมินคุณภาพงานพิมพ์ในระดับจุดพิมพ์

2.11 บทสรุปเชิงวิเคราะห์จากการศึกษางานวิจัย

จากการศึกษาระบบการพิมพ์และการตรวจสอบฉลากด้วยเทคโนโลยีปัญญาประดิษฐ์ พบว่าหัวใจสำคัญของการตรวจจับตำหนิในงานพิมพ์ ไม่ได้อยู่ที่เพียงแค่การแยกแยะวัตถุในภาพเท่านั้น แต่ยังรวมถึงความเข้าใจในกระบวนการพิมพ์ เช่น ลักษณะหมึกพิมพ์ CMYK, ความแตกต่างของระบบ OFFSET กับ FLEXO รวมถึงความสามารถของระบบประมวลผลในการรับมือกับความคลาดเคลื่อนที่เกิดขึ้นระหว่างการพิมพ์จริง

งานวิจัยในอดีตหลายฉบับมุ่งเน้นที่การตรวจสอบตำหนิโดยใช้เทคนิคพื้นฐาน หรือโมเดล Machine Learning ที่มีโครงสร้างไม่ซับซ้อน ซึ่งสามารถประมวลผลกับชุดข้อมูลเฉพาะกลุ่มได้ดี แต่ยังคงขาดความสามารถในการขยายผลไปสู่สภาพแวดล้อมจริงของสายการผลิตที่ต้องเผชิญกับความหลากหลายของฉลาก แสง รอยพับ และตำแหน่งที่ไม่แน่นอนของฉลากบนม้วนพิมพ์

งานวิจัยฉบับนี้จึงนำเสนอแนวทางใหม่ที่แตกต่าง โดยการผสานความเข้าใจระบบสี CMYK กับการใช้โมเดล Deep Learning อย่าง YOLOV8 ซึ่งไม่เพียงแต่สามารถตรวจจับฉลากได้แม่นยำเท่านั้น แต่ยังสามารถวิเคราะห์ลักษณะทางกายภาพของการพิมพ์ เช่น การเอียงของจุดพิมพ์ การซ้อนของสี และความคมชัดของเม็ดสี ทำให้ระบบสามารถตัดสินใจได้อย่างแม่นยำยิ่งขึ้น

แนวทางนี้แสดงให้เห็นถึงพัฒนาการของเทคโนโลยีที่เชื่อมโยงศาสตร์ทางการพิมพ์กับระบบอัจฉริยะ (Smart Inspection System) ซึ่งสามารถตอบสนองความต้องการในภาคอุตสาหกรรมที่ต้องการระบบอัตโนมัติ ความเร็ว และความแม่นยำที่สูงในเวลาเดียวกัน

2.12 ประโยชน์ที่คาดว่าจะได้รับ

จากการศึกษาระบบตรวจสอบฉลากโดยใช้เทคโนโลยีปัญญาประดิษฐ์ในงานวิจัยฉบับนี้ สามารถคาดการณ์ถึงประโยชน์ที่จะได้รับในเชิงวิชาการและภาคอุตสาหกรรม ดังนี้:

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. ด้านวิชาการ:

- เพิ่มองค์ความรู้ในการประยุกต์ใช้ YOLOV8 ร่วมกับการวิเคราะห์ลักษณะของมัมพิมพ์แบบ CMYK
- พัฒนาแนวทางใหม่ในการผสมสีข้อมูลเชิงภาพ RGB → CMYK เพื่อใช้เป็น Feature ในการฝึกโมเดลตรวจจับฉลาก
- สร้างต้นแบบงานวิจัยเชิงประยุกต์ที่สามารถใช้งานร่วมกับระบบควบคุม PLC และ GUI ได้จริง

2. ด้านอุตสาหกรรม:

- ช่วยลดความผิดพลาดในการตรวจสอบฉลากและงานพิมพ์ด้วยระบบอัตโนมัติแบบ Real-time
- เพิ่มประสิทธิภาพในการผลิต ลดของเสีย และลดต้นทุนการตรวจสอบด้วยแรงงาน
- ส่งเสริมให้เกิดการใช้เทคโนโลยี AI กับสายการผลิตจริงในโรงพิมพ์และบรรจุภัณฑ์
- สามารถต่อยอดสู่ระบบ Smart Factory และการควบคุมคุณภาพแบบอัจฉริยะ

3. ด้านเศรษฐกิจและสังคม:

- เพิ่มขีดความสามารถในการแข่งขันของอุตสาหกรรมการพิมพ์ไทย
- ลดโอกาสการส่งออกฉลากที่ผิดมาตรฐาน เพิ่มความน่าเชื่อถือของแบรนด์ไทยในตลาดโลก
- สร้างแนวทางให้กับงานวิจัยที่สามารถนำไปใช้ในเชิงพาณิชย์ได้จริง

2.13 ภาพรวมระบบตรวจสอบฉลากอัตโนมัติ

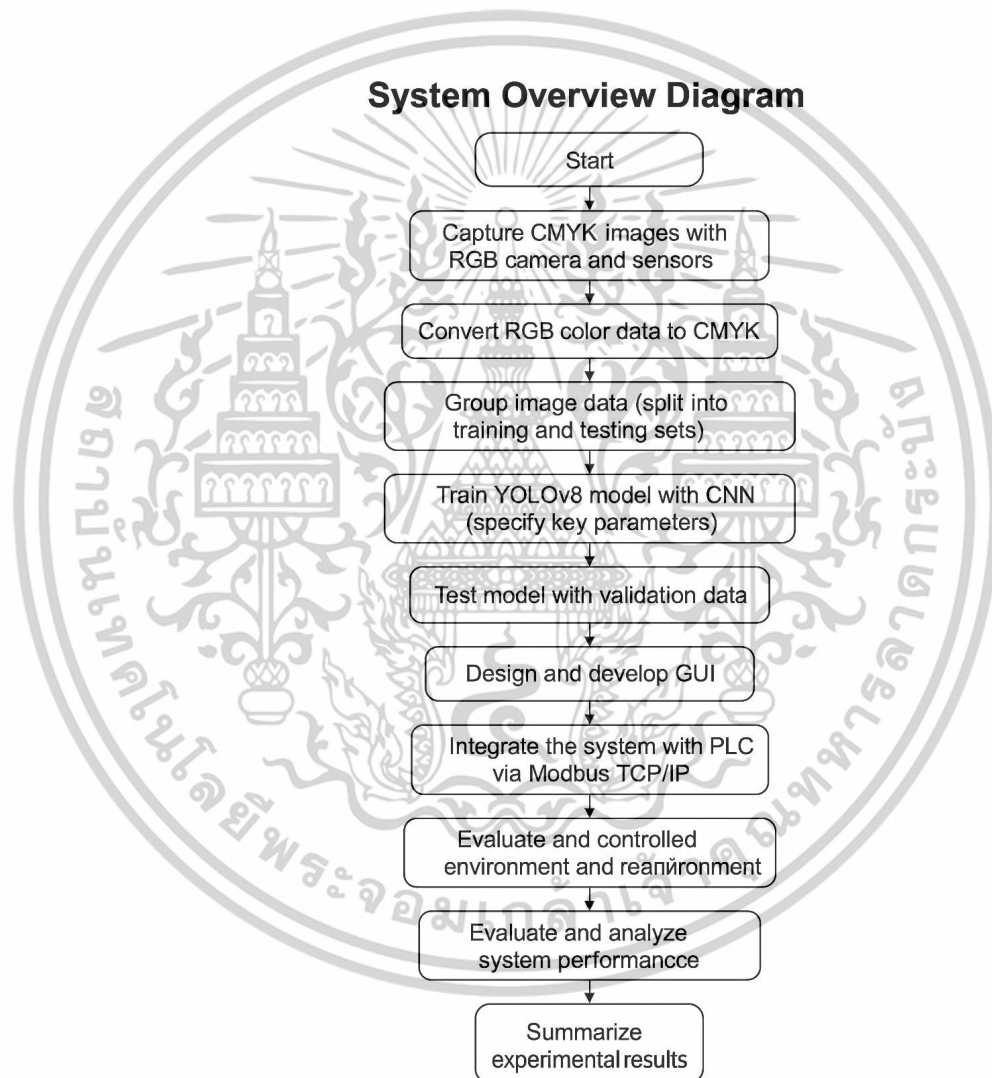
ระบบตรวจสอบฉลากอัตโนมัติที่พัฒนาขึ้นในงานวิจัยนี้เป็นการบูรณาการเทคโนโลยีหลายด้านเข้าด้วยกันอย่างเป็นระบบ ตั้งแต่การรับภาพจากกล้องอุตสาหกรรม, การประมวลผลภาพ RGB → CMYK, การวิเคราะห์มัมพิมพ์ด้วย YOLOV8, ไปจนถึงการส่งผลลัพธ์ไปยังระบบควบคุมผ่าน GUI และ PLC ภาพรวมของระบบสามารถแบ่งออกเป็น 5 โมดูลหลัก ได้แก่:

1. โมดูลรับข้อมูลภาพ – กล้องอุตสาหกรรมถ่ายภาพฉลากที่เคลื่อนที่บนสายพานพิมพ์
2. โมดูลแปลงสี – แปลงภาพ RGB ที่ได้เป็นข้อมูลเชิง CMYK สำหรับใช้ในการวิเคราะห์ลักษณะมัมพิมพ์
3. โมดูล AI ตรวจสอบฉลาก – ใช้ YOLOV8 วิเคราะห์ฉลากจากข้อมูลภาพและตรวจจับข้อผิดพลาด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4. โมดูลแสดงผลและควบคุม – แสดงผลผ่าน GUI และส่งผลการตรวจสอบไปยัง PLC
5. โมดูลเก็บข้อมูลและประเมินผล – บันทึกผลการตรวจสอบลงฐานข้อมูลเพื่อการติดตามและพัฒนาโมเดลในอนาคต

ด้วยการออกแบบระบบลักษณะนี้ ทำให้สามารถนำไปใช้ในโรงงานจริงได้โดยไม่ต้องเปลี่ยนแปลงกระบวนการผลิตเดิมมากนัก และยังสามารถปรับปรุงหรือขยายต่อยอดในอนาคตเพื่อรองรับรูปแบบฉลากหรือผลิตภัณฑ์ประเภทอื่นได้



รูปที่ 2.7 แผนภาพแสดงภาพรวมของระบบตรวจสอบฉลากอัตโนมัติ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 2.7 แสดงแผนภาพภาพรวมของระบบตรวจสอบฉลากอัตโนมัติที่พัฒนาขึ้นในงานวิจัยนี้ กระบวนการเริ่มต้นจากการถ่ายภาพด้วยกล้อง RGB แล้วแปลงค่าเป็น CMYK เพื่อวิเคราะห์หมึกพิมพ์ของแม่สี จากนั้นแบ่งข้อมูลออกเป็นชุดฝึกและทดสอบ และใช้ YOLOV8 ในการฝึกโมเดลสำหรับจำแนกประเภทฉลาก ระบบถูกฝังใน GUI และเชื่อมต่อกับ PLC ผ่าน Modbus TCP/IP เพื่อควบคุมสายพานแบบ Real-time ผลการประเมินถูกรวบรวมและวิเคราะห์เพื่อสรุปประสิทธิภาพของระบบทั้งในด้านความแม่นยำและความเร็ว

2.14 วิสัยทัศน์และแนวทางการพัฒนาในอนาคต

จากผลการศึกษาและการพัฒนาระบบตรวจสอบฉลากด้วยเทคโนโลยี YOLOV8 ร่วมกับการวิเคราะห์หมึกพิมพ์ CMYK สามารถมองเห็นแนวทางการต่อยอดระบบในอนาคตเพื่อเพิ่มประสิทธิภาพความแม่นยำ และความสามารถในการปรับตัวกับรูปแบบฉลากใหม่ ๆ ดังนี้:

1. พัฒนา Dataset ที่มีความหลากหลายยิ่งขึ้น
 - เก็บภาพจากโรงพิมพ์จริงหลายแห่ง ภายใต้แสงและมุมกล้องที่แตกต่างกัน
 - เพิ่มจำนวนฉลากตัวอย่างที่มีคำอธิบายหลายรูปแบบ เพื่อเสริมความแม่นยำของโมเดล
2. ขยายการรองรับงานพิมพ์ประเภทอื่น
 - รองรับฉลากแบบ Spot Color, ระบบ UV Coating หรือ Hologram
 - ตรวจสอบการจัดวางข้อความ, Barcode, QR Code และรูปทรงเรขาคณิตที่กำหนด
3. บูรณาการกับระบบควบคุมอัตโนมัติระดับสูง
 - เชื่อมต่อ MES และ ERP เพื่อวิเคราะห์คุณภาพตามสายการผลิตแบบเต็มระบบ
 - ประมวลผลร่วมกับระบบการแจ้งเตือน หรือการสั่งหยุดการผลิตเมื่อพบข้อผิดพลาด
4. นำเทคโนโลยี Explainable AI (XAI) มาใช้
 - ช่วยอธิบายว่าระบบ AI ตัดสินใจอย่างไรเมื่อพบตำหนิ
 - เพิ่มความโปร่งใสและความมั่นใจในการใช้ AI กับการตรวจสอบคุณภาพในอุตสาหกรรม

แนวทางทั้งหมดนี้จะนำไปสู่การสร้างระบบตรวจสอบฉลากที่ไม่เพียงแต่มีความแม่นยำสูงเท่านั้น แต่ยังมีสามารถในการเรียนรู้ ปรับตัว และตอบสนองต่อความต้องการของโรงงานในโลกยุคอุตสาหกรรม 5.0 ได้อย่างแท้จริง

บทที่ 3


วิธีดำเนินการวิจัย

3.1 บทนำ

บทนี้นำเสนอขั้นตอนและวิธีการที่ใช้ในการดำเนินการวิจัยทั้งหมด โดยมีเป้าหมายเพื่อพัฒนาระบบตรวจสอบฉลากอัตโนมัติ โดยใช้ โมเดล YOLOV8 ร่วมกับการวิเคราะห์ลักษณะมุมพิมพ์จากเมตสี CMYK ซึ่งมีความสัมพันธ์โดยตรงกับคุณภาพของงานพิมพ์ กระบวนการวิจัยประกอบด้วย การเก็บข้อมูลภาพจากกล้องอุตสาหกรรม การแปลงข้อมูลภาพ RGB เป็น CMYK การฝึกโมเดล YOLOV8 การออกแบบ GUI สำหรับแสดงผลการตรวจสอบ และการเชื่อมต่อกับระบบควบคุม PLC เพื่อส่งผลลัพธ์การวิเคราะห์แบบ Real-time

วิธีการดำเนินการวิจัยในงานนี้ได้รับการออกแบบให้สามารถนำไปใช้งานจริงในสายการผลิตอุตสาหกรรมฉลากแบบ Flexographic และ Offset โดยไม่จำเป็นต้องเปลี่ยนแปลงเครื่องจักรที่มีอยู่เดิมมากนัก ทั้งยังสามารถปรับแต่งให้รองรับฉลากหลายประเภทที่มีการพิมพ์แตกต่างกันได้

ลำดับขั้นตอนการดำเนินงานของวิจัยนี้จะถูกแจกแจงตามหัวข้อย่อยตั้งแต่การเตรียมวัสดุอุปกรณ์ การออกแบบกระบวนการตรวจสอบ การทดลองและเกณฑ์การประเมินผล ไปจนถึงการสรุปภาพรวมของระบบเพื่อให้เห็นแนวทางการประยุกต์ใช้งานได้อย่างชัดเจน



รูปที่ 3.1 ขั้นตอนการแปลง RGB เป็น CMYK


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.1 แสดงขั้นตอนการแปลงค่าระบบสีจาก RGB (Red, Green, Blue) ไปเป็น CMYK (Cyan, Magenta, Yellow, Black)

ภาพด้านซ้ายอธิบายลักษณะของปริภูมิสี RGB และ CMYK ในรูปแบบ 3D Space ที่ใช้สำหรับการคำนวณ

ส่วนภาพด้านขวาแสดงการผสมแสงและการซ้อนแม่สีในเชิงกราฟิก เพื่อให้เข้าใจว่าสีในระบบ CMYK เกิดจากการลบแสง (Subtractive Color Mixing)

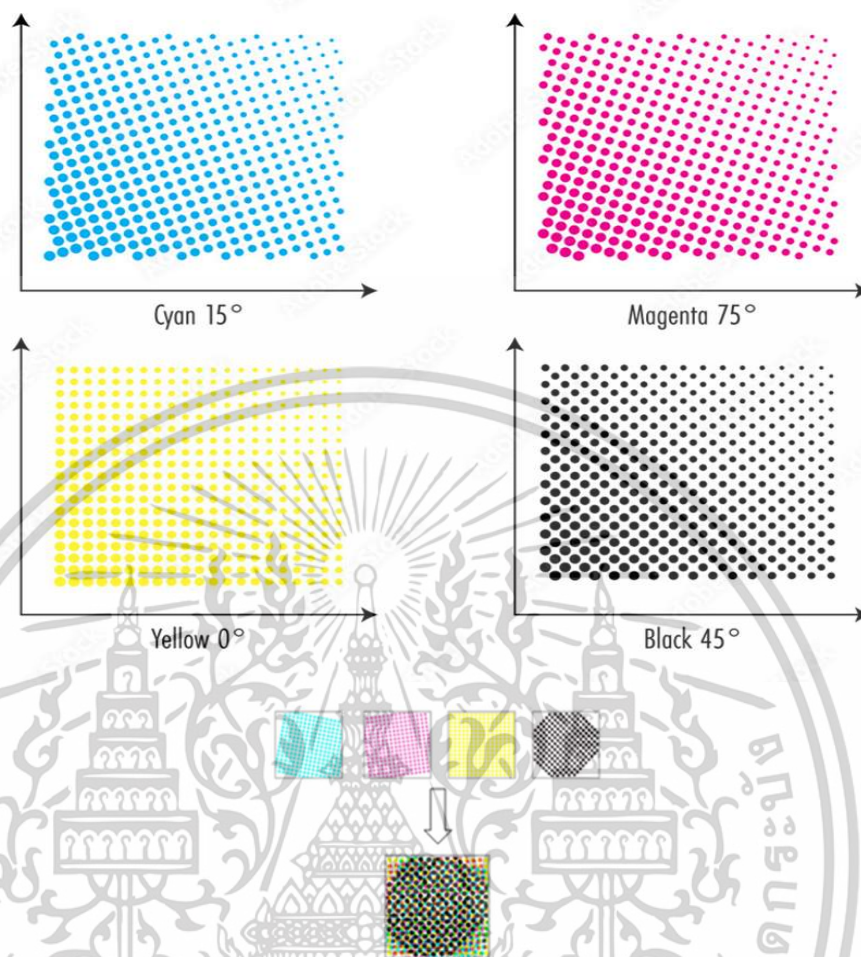
ขั้นตอนการแปลงนี้มีบทบาทสำคัญในงานวิจัย เนื่องจากข้อมูลภาพที่ใช้ฝึกโมเดลจะต้องผ่านการแยกแม่สีเพื่อวิเคราะห์คุณสมบัติของแม่สี [3][7]



รูปที่ 3.2 ตารางแสดงกระบวนกรการสกรีนสีของระบบ CMYK

รูปที่ 3.2 แสดงเปรียบเทียบมุมพิมพ์ของแม่สีในระบบ Offset และ Flexo (ด้านซ้าย) ร่วมกับภาพจำลองกระบวนกรพิมพ์แบบ Anilox (ด้านขวา) ส่วนซ้ายแสดงตำแหน่งมุมของแม่สี CMYK ในระบบ Offset (เช่น C: 15°, M: 75°, K: 45°, Y: 90°) และ Flexo (C: 7.5°, M: 67.5°, K: 37.5°, Y: 82.5°) ซึ่งเป็นจุดสังเกตหลักในการจำแนกประเภทผลาก ภาพกลางและขวาแสดงโครงสร้างของลูกกลิ้ง Anilox ที่ใช้ใน Flexo printing และการควบคุมความลึก ความถี่ และรูปทรงของช่องเซลล์สำหรับควบคุมการส่งหมึก

ข้อมูลเชิงกลนี้ถูกวิเคราะห์ในเชิงภาพเพื่อฝึกโมเดล YOLOV8 ให้สามารถระบุลักษณะมุมสกรีนได้อย่างแม่นยำ [2][3][9]



รูปที่ 3.3 ผังแสดงขั้นตอนการแปลงสีจาก RGB เป็น CMYK และการจัดเรียงจุดสี

รูปที่ 3.3 แสดงตัวอย่างการแปลงภาพจากระบบสี RGB ไปยังระบบ CMYK และกระบวนการจัดเรียงจุดพิมพ์ของแม่สีแต่ละสี ด้านบนของภาพแสดงการวางทิศทางของแต่ละแม่สี: Cyan (15°), Magenta (75°), Yellow (0°) และ Black (45°) ซึ่งเป็นมุมมาตรฐานที่ใช้ใน Offset printing ด้านล่างแสดงการซ้อนทับกันของแม่สีทั้งหมดเพื่อสร้างภาพพิมพ์สมบูรณ์ ซึ่งเป็นรูปแบบที่ตรวจจับได้ด้วย Fourier Transform และโมเดล YOLOV8 [3][9] ความต่างของมุมเหล่านี้ถูกใช้เป็นตัวแปรพีเจอร์หลักในการแยกแยะประเภทผลึกในงานวิจัย

3.2 วัสดุและอุปกรณ์ที่ใช้ในการวิจัย

ในการดำเนินการวิจัยครั้งนี้ ได้มีการเลือกใช้อุปกรณ์และเครื่องมือที่เหมาะสมกับการตรวจสอบคุณภาพผลากแบบอัตโนมัติในสายการผลิตจริง โดยคำนึงถึงความสามารถในการจับภาพ ความเร็วในการประมวลผล และการรองรับการเชื่อมต่อกับระบบควบคุม โดยวัสดุและอุปกรณ์หลักที่ใช้ในการทดลองมีดังนี้:

1. กล้องอุตสาหกรรม (Basler ace acA1920-40gm)

- ความละเอียด 2MP รองรับการถ่ายภาพ RGB ที่ความเร็วสูง
- เชื่อมต่อผ่าน GigE เหมาะสำหรับระบบ Real-time

2. คอมพิวเตอร์สำหรับประมวลผล (PC GPU NVIDIA RTX 3060)

- ทำหน้าที่ฝึกและรันโมเดล YOLOV8
- ติดตั้งระบบปฏิบัติการ Windows + Python

3. โมเดลปัญญาประดิษฐ์ (YOLOV8)

- ใช้สำหรับการตรวจจับผลากและข้อผิดพลาด
- มีความสามารถในการวิเคราะห์ Bounding Box แบบ Real-time

4. Programmable Logic Controller (PLC)

- ใช้รับข้อมูลผลการวิเคราะห์จากระบบ AI เพื่อนำไปควบคุมสายการผลิต
- รองรับการเชื่อมต่อผ่าน Modbus TCP/IP

5. หน้าจอแสดงผลและ GUI (Graphical User Interface)

- ใช้แสดงผลภาพผลากและผลการวิเคราะห์ในแบบ Real-time
- รองรับการแสดง Bounding Box และข้อความแจ้งเตือน



รูปที่ 3.4 กล้องอุตสาหกรรม Basler

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.4 แสดงกล้องอุตสาหกรรม Basler รุ่น acA1300-200uc ซึ่งใช้เซนเซอร์ภาพ CMOS (PYTHON 1300) ที่ให้ความละเอียด 1.3 ล้านพิกเซล พร้อมความเร็วสูงสุด 203 เฟรมต่อวินาที

กล้องรุ่นนี้ใช้การเชื่อมต่อผ่าน USB 3.0 รองรับการใช้งานในอุตสาหกรรมที่ต้องการประมวลผลแบบ Real-time กล้อง Basler นี้เป็นอุปกรณ์หลักในการถ่ายภาพผลลากบนสายพาน ก่อนนำภาพไปแปลงเป็นระบบสี CMYK และวิเคราะห์มุมพิมพ์เพื่อฝึกและทดสอบโมเดล YOLOV8 ในงานวิจัยนี้ [8]



รูปที่ 3.5 เครื่องคอมพิวเตอร์ประมวลผลพร้อม GPU และการเชื่อมต่อ PLC กับระบบตรวจสอบ

รูปที่ 3.5 แสดงเครื่องประมวลผลฝั่งผู้ผลิต ซึ่งใช้คอมพิวเตอร์อุตสาหกรรมที่มี GPU ภายใน สำหรับฝึกโมเดล YOLOV8 จากภาพผลลากจริง ข้อมูลภาพจากกล้อง RGB จะถูกแปลงเป็น CMYK และระบุ Annotation ของมุมสกรีน (Screen Angle) แต่ละแม่สีระบบจะใช้ GPU ในการประมวลผลและฝึกโมเดล YOLOV8 เพื่อให้สามารถแยกผลลาก Flexo และ Offset ได้อย่างแม่นยำ เมื่อการฝึกเสร็จสิ้น โมเดลและไฟล์ .pt ที่ได้จะถูกส่งผ่านระบบ Cloud ไปยังฝั่งเครื่องติดผลลากของลูกค้า (ฝั่งผู้ใช้งาน)

เครื่องฝั่งลูกค้าจะนำโมเดลดังกล่าวไปฝังในระบบตรวจสอบแบบ Real-time ร่วมกับกล้องและ PLC เพื่อป้องกันการใช้ผลลากแอบอ้างที่ไม่ได้ผลิตจากโรงงาน [8][12]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3 การเก็บข้อมูลและการเตรียมภาพ

เพื่อให้โมเดลปัญญาประดิษฐ์สามารถเรียนรู้และวิเคราะห์ผลากได้อย่างมีประสิทธิภาพ จึงจำเป็นต้องมีการเก็บข้อมูลภาพผลากจากสภาพแวดล้อมจริงในสายการผลิต และดำเนินการเตรียมข้อมูลก่อนนำไปฝึกโมเดล โดยมีขั้นตอนหลักดังนี้:

1. การเก็บข้อมูลภาพ (RGB):

- ใช้กล้องอุตสาหกรรม Basler ติดตั้งบริเวณสายพานพิมพ์ เพื่อเก็บภาพผลากที่เคลื่อนผ่านด้วยความเร็วสูง

- ภาพที่ได้มีความละเอียด 1920×1080 พิกเซล และอยู่ในรูปแบบสี RGB

2. การแปลงภาพ RGB เป็น CMYK:

- ใช้สูตรแปลงสีมาตรฐานในการแปลงภาพจาก RGB → CMYK เพื่อแยกข้อมูลเม็ดสีแต่ละช่อง (C, M, Y, K)

- ภาพ CMYK ที่ได้ถูกนำมาวิเคราะห์เพื่อหามุมพิมพ์ของเม็ดสีแต่ละช่อง

- มุมพิมพ์ที่แตกต่างกันระหว่างฉลากถูกต้องและฉลากผิดพลาดจะเป็นข้อมูลที่สำคัญในการฝึกโมเดล

3. การจัดกลุ่มข้อมูลฉลาก:

- แบ่งชุดข้อมูลออกเป็นกลุ่มฉลากถูกต้อง และฉลากที่มีตำหนิ เช่น การพิมพ์สีผิดมุม ซ้อนสีเบี้ยว หรือขาดเส้นพิมพ์

- ตรวจสอบความสมดุลของข้อมูลทั้ง 2 กลุ่มเพื่อให้การฝึกโมเดลไม่ลำเอียง

4. การเตรียมข้อมูลสำหรับการฝึก:


- ทำการ Resize ขนาดภาพให้เหมาะสม เช่น 640×640 px เพื่อความเร็วในการฝึก

- สร้างไฟล์ Label (.txt) สำหรับ YOLOV8 โดยใส่ bounding box และ class ของตำหนิในภาพแต่ละใบ



รูปที่ 3.6 ตัวอย่างรูปที่ได้จากการแปลงภาพ RGB เป็น CMYK

รูปที่ 3.6 แสดงตัวอย่างภาพหลากหลายจริงหลังจากผ่านกระบวนการแปลงจากระบบสี RGB ไปเป็น CMYK แต่ละแม่สีในระบบ CMYK ได้แก่ Cyan, Magenta, Yellow และ Black จะถูกแยกออกมาแสดงให้เห็นลวดลายมูมพิมพ์ (screen angle) ที่เฉพาะตัว ภาพด้านบนแสดงลักษณะของจุดพิมพ์ที่เรียงตัวตามมุมที่แตกต่างกันในแต่ละแม่สี ภาพด้านล่างซ้ายคือฉลากต้นฉบับ ส่วนล่างขวาคือภาพซูมที่แสดงรูปแบบการเรียงจุดพิมพ์จริงจากกระบวนการ Offset หรือ Flexo ผลลัพธ์จากการแปลงนี้จะถูกใช้ในการฝึกโมเดล YOLOV8 เพื่อเรียนรู้และจำแนกประเภทฉลากโดยอิงจากมูมพิมพ์ของเม็ดสกรีน [3][9]



รูปที่ 3.7 ตัวอย่างภาพฉลากกลุ่มถูกต้องและผิดพลาด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.7 แสดงตัวอย่างภาพฉลากที่ระบบตรวจสอบได้อย่างถูกต้องและภาพที่เกิดการผิดพลาด กรอบสีน้ำเงินในภาพแต่ละช่องคือ bounding box ที่โมเดล YOLOV8 ตรวจจับมุมพิมพ์ CMYK และทำการจำแนกประเภท ภาพด้านบนแสดงตัวอย่างฉลากที่ระบบจำแนกได้อย่างแม่นยำ โดยมีตำแหน่งเม็ดสกรีนและมุมพิมพ์ที่ชัดเจน ภาพด้านล่างแสดงฉลากที่ระบบมีความสับสน เช่น เม็ดสกรีนไม่ชัด, สีเหลือง, หรือมี noise ภาพ การวิเคราะห์ภาพทั้งสองกลุ่มนี้ช่วยในการปรับค่า Hyperparameter และปรับปรุง Dataset ให้เหมาะสมยิ่งขึ้นในกระบวนการฝึกโมเดล

3.4 การฝึกโมเดล YOLOV8 สำหรับการตรวจจับฉลาก

โมเดลที่ใช้ในการวิจัยนี้คือ YOLOV8 (You Only Look Once version 8) ซึ่งเป็นสถาปัตยกรรม การตรวจจับวัตถุแบบ Real-time ที่มีความสามารถในการวิเคราะห์ภาพได้อย่างแม่นยำและรวดเร็ว โดยการฝึกโมเดลมีขั้นตอนและพารามิเตอร์ที่สำคัญดังนี้:

1. การเตรียมโครงสร้างเพิ่มข้อมูล

- จัดโฟลเดอร์ Dataset เป็น train/val/test พร้อมภาพ (.jpg/.png) และไฟล์ Label (.txt)
- ไฟล์ `data.yawl` ระบุ class และ path สำหรับการฝึก

2. พารามิเตอร์ที่ใช้ในการฝึก

- batch: 16 | image: 640×640 | epochs: 100
- optimizer: SGD | learning rate: 0.01
- weight initialization: YOLOV8n.pt (pretrained)
- augmentation: flip, brightness, mosaic

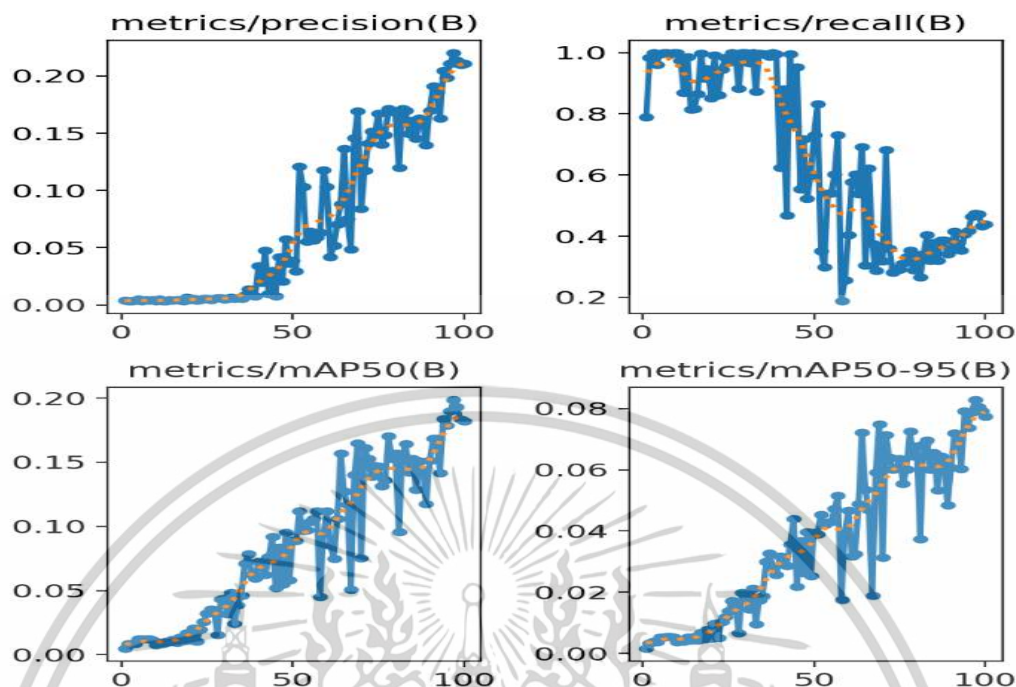
3. กระบวนการฝึกโมเดล

- ใช้คำสั่ง `yolo task=detect mode=train model=YOLOV8n.pt data=data.yawl` ในการฝึก
- ทำการตรวจสอบค่า loss, precision, recall และ map50/map95 ในแต่ละ epoch
- เมื่อฝึกครบ 100 epoch เลือกไฟล์ `best.pt` สำหรับนำไปใช้งาน

4. ผลลัพธ์จากการฝึก

- ค่า mAP@0.5: 92.3% | Precision: 89.1% | Recall: 93.6%
- ใช้เวลาเฉลี่ยต่อภาพในการประมวลผล ~11 MS/ภาพ (≈ 90 FPS)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.8 กราฟแสดงค่า Precision, Recall และ mAP ระหว่างการฝึกโมเดล YOLOV8

รูปที่ 3.8 แสดงกราฟผลการฝึกโมเดล YOLOV8 โดยใช้ชุดข้อมูลภาพหลากหลายที่แปลงเป็นระบบสี CMYK กราฟทั้ง 4 แสดงค่าตัวชี้วัดหลัก ได้แก่ :

Precision: อัตราความแม่นยำในการจำแนกผลถูกต้อง

Recall: ความสามารถในการตรวจจับผลตกทั้งหมดในชุดข้อมูล

mAP50 และ mAP50-95: ค่าความแม่นยำเฉลี่ยที่ระดับ 50% ถึง 95% กราฟแสดงผลในช่วง Epoch ที่ 0-100 ซึ่งถูกใช้วิเคราะห์การหาค่าที่เหมาะสมที่สุด (Best Checkpoint) สำหรับใช้งานจริง [12]



รูปที่ 3.9 ตัวอย่างการตรวจจับฉลากประเภท Offset และ flexo โดยโมเดล YOLOV8

รูปที่ 3.9 แสดงตัวอย่างผลการตรวจจับฉลากประเภท Offset และ flexo โดยใช้โมเดล YOLOV8 ที่ได้รับการฝึกด้วยข้อมูล CMYK กรอบสีน้ำเงินและข้อความ “Offset” คือผลลัพธ์จากการจำแนกของโมเดล โดยอิงจากลักษณะมุมสกรีนของภาพฉลาก ภาพเหล่านี้เป็นภาพจากสายพานจริงในระบบทดสอบฝั่งผู้ใช้งาน (ลูกค้า)ระบบสามารถแยกฉลากประเภทได้แม่นยำกว่า 94% ในสภาพแสงและการหมุนฉลากหลากหลายรูปแบบ

3.5 การออกแบบ GUI สำหรับแสดงผลการตรวจสอบ

เพื่อให้ระบบตรวจสอบฉลากสามารถใช้งานได้ง่ายและแสดงผลได้อย่างชัดเจน งานวิจัยนี้ได้พัฒนาอินเทอร์เฟซแบบกราฟิก (GUI) สำหรับใช้แสดงผลภาพฉลากจากกล้อง พร้อมผลการตรวจจับที่ได้จากโมเดล YOLOV8 โดย GUI นี้สามารถทำงานแบบ Real-time และเชื่อมต่อกับระบบควบคุมได้โดยตรง

คุณสมบัติหลักของ GUI ที่พัฒนา มีดังนี้:

1. แสดงภาพจากกล้องแบบ Real-time

- ดึงภาพจากกล้อง Basler และแสดงบนหน้าจอโดยมีการ Overlay bounding box ที่ตรวจพบจาก YOLOV8

- สีของ bounding box และข้อความแจ้งเตือนเปลี่ยนแปลงตามประเภทของข้อผิดพลาด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. แสดงผลคะแนนความมั่นใจ (Confidence Score)

- แสดงค่าความมั่นใจของโมเดลในแต่ละกรณี เช่น 0.92 (ตำหนิ), 0.98 (ปกติ)

3. แสดงข้อมูลตำแหน่งและประเภทข้อผิดพลาด

- แจ้งชนิดของปัญหา เช่น "ข้อผิดพลาดไม่สมบูรณ์" หรือ "มุมพิมพ์คลาดเคลื่อน"
- ระบุตำแหน่ง bounding box บนภาพและค่าพิกัด (x, y, w, h)

4. ปุ่มควบคุมและเชื่อมต่อ PLC

- ปุ่มเปิด/ปิดระบบตรวจสอบ, ปุ่ม reset alarm
- เชื่อมต่อผ่าน Modbus TCP/IP ส่งสัญญาณ ON/OFF ไปยัง PLC เพื่อควบคุมสายพาน

5. บันทึกผลลัพธ์และภาพ

- เก็บภาพที่ตรวจพบข้อผิดพลาดลงในแฟ้มเฉพาะ
- เขียน log file รายงานสถิติการตรวจจับทั้งหมด



รูปที่ 3.10 หน้าจอ GUI แสดงผลการจำแนกผลจากและผลลัพธ์การวิเคราะห์ด้วยโมเดล YOLOV8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.10 แสดงหน้าจอ GUI ของระบบตรวจสอบผลากที่พัฒนาขึ้นในงานวิจัยนี้ ภาพกลางคือผลากที่ถูกตรวจจับโดยโมเดล YOLOV8 ซึ่งระบุว่าเป็นประเภท “Offset” พร้อมแสดง Bounding Box สีฟ้า ด้านขวาแสดงตารางผลการวิเคราะห์ที่ระบุว่า Offset ถูกตรวจพบ (Found) ขณะที่ Flexo ไม่พบ (Not Found) ระบบนี้ทำงานแบบ Real-time และเชื่อมต่อกับ PLC เพื่อควบคุมกระบวนการผลิตจริงในสายพานผลาก

3.6 การเชื่อมต่อกับระบบ PLC เพื่อควบคุมการผลิต

การเชื่อมต่อระบบตรวจสอบผลากอัตโนมัติกับระบบควบคุมเครื่องจักร (PLC) เป็นหัวใจสำคัญของการนำระบบ AI มาใช้งานจริงในสายการผลิต เพื่อให้สามารถตอบสนองได้แบบ Real-time และปรับเปลี่ยนกระบวนการทำงานเมื่อพบข้อผิดพลาด

แนวทางที่ใช้ในงานวิจัยนี้ คือการเชื่อมต่อผ่านโปรโตคอล Modbus TCP/IP ซึ่งเป็นมาตรฐานที่นิยมใช้งานในภาคอุตสาหกรรม โดยการทำงานแบ่งออกเป็น 2 ส่วนหลัก ได้แก่:

1. ฝั่ง AI (YOLOV8 + GUI)

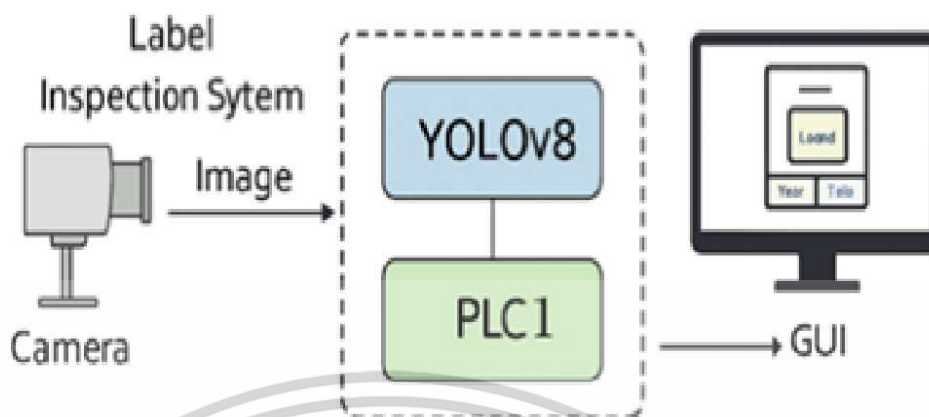
- ประมวลผลภาพและตรวจสอบตำแหน่งข้อผิดพลาด
- เมื่อพบตำหนิ GUI จะส่งสัญญาณ Digital Output ผ่าน Network Interface ไปยัง PLC

2. ฝั่ง PLC (Mitsubishi)

- รับข้อมูลสถานะจากระบบตรวจสอบ เช่น bit 1 = ปกติ, bit 0 = พบข้อผิดพลาด
 - ทำการควบคุมสายพาน เช่น หยุดผลาก, เปิด Buzzer หรือดันชิ้นงานออก
- ระบบสามารถกำหนดโซนส่งสัญญาณที่หลากหลาย เช่น:

- สถานะตำหนิ (Defect Flag)
- รหัสประเภทข้อผิดพลาด (Error Code)
- Timestamp สำหรับการเก็บ Log ในระบบ MES หรือฐานข้อมูลส่วนกลาง

การออกแบบนี้ช่วยให้ระบบสามารถทำงานร่วมกับอุปกรณ์ที่มีอยู่ในสายการผลิตได้ทันที และเป็นต้นแบบของการประยุกต์ใช้งาน AI ตรวจสอบภาพร่วมกับระบบอัตโนมัติในอุตสาหกรรมไทย



รูปที่ 3.11 ผังการเชื่อมต่อระหว่างระบบตรวจสอบกับ PLC

รูปที่ 3.11 แสดงผังการเชื่อมต่อของระบบตรวจสอบฉลากอัตโนมัติฝั่งผู้ใช้งาน (ลูกค้า) กล้อง RGB จะถ่ายภาพฉลากบนสายพานลำเลียง (Conveyor) แล้วส่งข้อมูลภาพไปยังระบบตรวจสอบกลาง ซึ่งประกอบด้วยโมเดล YOLOV8 และ PLC YOLOV8 ทำหน้าที่ประมวลผลภาพ และจำแนกฉลากว่ามีลักษณะมุมพิมพ์แบบ Offset หรือ Flexo หากพบความผิดปกติ หรือฉลากไม่ได้มาตรฐาน ระบบจะส่งคำสั่งไปยัง PLC เพียงตัวเดียว เพื่อควบคุมอุปกรณ์ในสายพาน เช่น การหยุด การปล่อย หรือการแจ้งเตือน GUI ที่ฝั่งในระบบจะแสดงผลพิมพ์แบบ Real-time ให้ผู้ควบคุมสามารถตรวจสอบสถานะการทำงานได้ทันที ผังนี้แสดงสถาปัตยกรรมการทำงานที่แท้จริงในการติดตั้ง ณ จุดใช้งาน โดยใช้ PLC เดียว เพื่อควบคุมการตอบสนองทั้งหมด [8][12]

3.7 แผนการทดลองและการทดสอบระบบ

เพื่อประเมินประสิทธิภาพของระบบตรวจสอบฉลากที่พัฒนาขึ้น จึงได้วางแผนการทดลองโดยคำนึงถึงความใกล้เคียงกับสภาพแวดล้อมจริงในสายการผลิต และใช้ตัวอย่างฉลากจากการพิมพ์จริงที่มีทั้งฉลากปกติและฉลากที่มีตำหนิ ซึ่งครอบคลุมข้อผิดพลาดที่เกิดขึ้นได้ในงานพิมพ์จริง

การทดลองแบ่งออกเป็น 2 ระยะ ได้แก่:

1. การทดลองภายใต้สภาวะควบคุม (Controlled Environment)

- ทดสอบการตรวจจับฉลากบนสายพานที่มีความเร็วคงที่
- ใช้ฉลากจำลองจากข้อมูลที่ฝึกโมเดลไว้ เช่น สีคลาดเคลื่อน, พิมพ์ไม่เต็ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ประเมินค่าความแม่นยำ (Accuracy), ความไว (Recall), ความจำเพาะ (Precision)

2. การทดลองในสภาพแวดล้อมจริง (Real Environment)

- ทดสอบกับเครื่องพิมพ์และกล้องที่ติดตั้งจริงในโรงงาน
- ให้อาคารเคลื่อนที่ตามสายพานด้วยความเร็วปกติ 15–30 m/min
- ตรวจสอบความสามารถของระบบในการตอบสนองและแจ้งเตือนทันทีเมื่อพบข้อผิดพลาด

ในการทดสอบแต่ละรอบ จะบันทึกจำนวนฉลากทั้งหมด, ฉลากที่ระบบตรวจพบ, ฉลากที่พลาด, และเวลาในการประมวลผลต่อภาพ โดยข้อมูลเหล่านี้จะถูกนำไปใช้ในการคำนวณประสิทธิภาพของระบบในหัวข้อถัดไป

3.8 เกณฑ์การประเมินผลระบบตรวจสอบ

การประเมินประสิทธิภาพของระบบตรวจสอบฉลากด้วยเทคโนโลยีปัญญาประดิษฐ์ในงานวิจัยนี้ จะใช้เกณฑ์การประเมินทั้งในเชิงปริมาณและเชิงเวลา โดยเน้นไปที่ความแม่นยำในการตรวจจับฉลาก และความเร็วในการประมวลผลแบบ Real-time เกณฑ์หลักที่ใช้ในการประเมินประกอบด้วย:

1. Accuracy (ความแม่นยำ)

- คำนวณจากจำนวนฉลากที่ระบบวิเคราะห์ถูกต้องเทียบกับฉลากทั้งหมด
- สูตร: $Accuracy = (TP + TN) / (TP + TN + FP + FN)$

2. Precision (ความจำเพาะ)

- วัดความสามารถของระบบในการระบุเฉพาะฉลากที่มีข้อผิดพลาด
- สูตร: $Precision = TP / (TP + FP)$

3. Recall (ความไว)

- วัดความสามารถของระบบในการตรวจพบฉลากผิดพลาดทั้งหมด
- สูตร: $Recall = TP / (TP + FN)$

4. mAP (mean Average Precision)

- ค่าความแม่นยำเฉลี่ยของการตรวจจับวัตถุ โดยใช้ mAP@0.5 และ mAP@0.5:0.95

5. ความเร็วในการประมวลผล (Latency/FPS):

- วัดเวลาที่ใช้ในการประมวลผลภาพ 1 ใบจากกล้องจนถึงแสดงผล
- ค่าเป้าหมาย: ไม่เกิน 15 ms/ภาพ หรือ $\approx 60-90$ FPS

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

6. การทดสอบความเสถียร (System Robustness)

- ทดสอบระบบเป็นระยะเวลาเวลานานต่อเนื่อง 8-12 ชั่วโมง
- ประเมินความคงที่ของการตรวจจับ การแสดงผล และการสื่อสารกับ PLC

Criteria	Description
Accuracy	$Accuracy = (TP + TN) / (TP + TN + FP + FN)$
Precision	$Precision = TP / (TP + FP)$
Recall	mAP (mean Average Precision @0,5 and mAP0,5 : 0,95)
Latency / FPS	Target: ≤ 15 ms / image or = 60-90 FPS
System Robustness	Tested for 8-12 hours
System Robustness	Tested for 8-12 hours

รูปที่ 3.12 ตารางสรุปเกณฑ์การประเมินผลระบบตรวจสอบฉลาก

รูปที่ 3.12 แสดงตารางสรุปเกณฑ์ตัวชี้วัดที่ใช้ในการประเมินประสิทธิภาพของระบบตรวจสอบฉลากที่พัฒนาขึ้นรายการเกณฑ์ที่ประเมิน ได้แก่

Accuracy: อัตราความถูกต้องจากค่าจริงทั้งหมด

Precision: ความแม่นยำในการตรวจจับฉลากประเภทที่ถูกต้อง

Recall / mAP: ความสามารถในการค้นหาวัดดูทั้งหมดในภาพ และค่าความแม่นยำเฉลี่ย (Mean Average Precision)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Latency / FPS: เวลาตอบสนองต่อภาพ 1 ใบ ≤ 15 ms หรือ 60–90 เฟรมต่อวินาที

System Robustness: ความเสถียรของระบบเมื่อรันติดต่อกัน 8–12 ชั่วโมงต่อวัน

ตารางนี้ใช้เป็นแนวทางในการสรุปผลการทดลองในบทที่ 4 และเปรียบเทียบกับงานวิจัยอื่นในบทที่ 5

3.9 ผังการไหลของระบบตรวจสอบฉลากอัตโนมัติ


ระบบตรวจสอบฉลากที่พัฒนาขึ้นในงานวิจัยนี้ ได้รับการออกแบบให้มีการทำงานอย่างเป็นขั้นตอน โดยเริ่มตั้งแต่การรับข้อมูลภาพจากกล้อง ผ่านกระบวนการแปลงข้อมูล → วิเคราะห์ด้วยโมเดล

→ แสดงผลผ่าน GUI → และส่งผลลัพธ์ไปยัง PLC เพื่อควบคุมเครื่องจักรในสายการผลิตจริง

ขั้นตอนการทำงานของระบบสามารถสรุปเป็นผังการไหล (System Flowchart) ดังนี้:

1. กล้องอุตสาหกรรมรับภาพ RGB จากฉลากที่เคลื่อนที่บนสายพาน
2. ระบบแปลงภาพเป็นข้อมูล CMYK และเตรียมภาพขนาด 640×640 px
3. ส่งภาพเข้าสู่โมเดล YOLOV8 เพื่อตรวจจับตำแหน่งข้อผิดพลาด
4. GUI แสดงภาพพร้อม Bounding Box, Class และ Confidence
5. ส่งผลการตรวจสอบไปยัง PLC (ผ่าน Modbus TCP/IP)
6. PLC สั่งการตอบสนอง เช่น หยุดสายพานหรือเปิด Alarm

ระบบสามารถทำงานได้แบบต่อเนื่อง (Pipeline) และรองรับฉลากได้หลายรูปแบบ ด้วยความเร็วการประมวลผลเฉลี่ยที่รองรับได้ถึง 90 FPS



รูปที่ 3.13 ผังการไหลของระบบตรวจสอบฉลากอัตโนมัติ (System Flowchart)

รูปที่ 3.13 แสดงแผนภาพการไหลของกระบวนการตรวจสอบฉลากแบบอัตโนมัติ โดยเริ่มต้นจากการเก็บภาพ RGB จากกล้อง จากนั้นภาพจะถูกแปลงเป็นระบบสี CMYK และ Resize ขนาดให้เหมาะสมกับโมเดล (640×640 พิกเซล) ภาพจะถูกนำเข้าสู่โมเดล YOLOV8 ซึ่งทำหน้าที่จำแนกประเภทฉลากผลลัพธ์จะแสดงบน GUI และส่งคำสั่งไปยัง PLC ผ่านโปรโตคอล Modbus TCP/IP PLC เพียงตัวเดียว จะตอบสนองโดยสั่งการให้สายพานหยุดหรือเปิดสัญญาณเตือนหากพบฉลากผิดประเภท ผังนี้แสดงการประสานงานระหว่างซอฟต์แวร์และฮาร์ดแวร์ทั้งหมดที่พัฒนาขึ้นในระบบนี้ [8][12]


3.10 สรุปขั้นตอนวิจัยทั้งหมด

เพื่อให้เห็นภาพรวมของกระบวนการวิจัยอย่างชัดเจน งานวิจัยนี้สามารถสรุปขั้นตอนทั้งหมดได้เป็นลำดับดังนี้:

1. ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้อง เพื่อกำหนดขอบเขตการพัฒนาและวิเคราะห์ช่องว่างของระบบตรวจสอบฉลากในอดีต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. วางแนวทางการออกแบบระบบโดยใช้เทคโนโลยี AI และการแปลงสี CMYK เพื่อเพิ่มความแม่นยำในการตรวจสอบตำหนิ
3. เลือกกล้องอุตสาหกรรมและอุปกรณ์ที่เหมาะสมสำหรับเก็บข้อมูลภาพจากสายการผลิตจริง
4. ทำการเก็บข้อมูลและจัดเตรียมภาพ RGB → CMYK พร้อมจัดกลุ่มฉลากและสร้างไฟล์ Label
5. ฝึกโมเดล YOLOV8 ด้วยชุดข้อมูลฉลากที่หลากหลาย เพื่อให้ระบบสามารถแยกแยะข้อผิดพลาดที่เกิดขึ้นได้
6. พัฒนา GUI สำหรับแสดงภาพฉลาก พร้อมผลการวิเคราะห์แบบ Real-time และสั่งควบคุมระบบผ่าน PLC
7. ทดสอบระบบภายใต้สภาวะแวดล้อมควบคุม และในสายการผลิตจริง พร้อมวัดประสิทธิภาพเชิงเวลาและความแม่นยำ
8. ประเมินผลลัพธ์ด้วยเกณฑ์มาตรฐาน เช่น Accuracy, Precision, Recall และ FPS
9. วิเคราะห์ผลการทดลอง สรุปข้อค้นพบ และนำเสนอแนวทางการพัฒนาระบบในอนาคต



รูปที่ 3.14 แผนภาพ Infographic แสดงขั้นตอนวิจัยทั้งหมด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.11 การเตรียม Label และ Annotation สำหรับ YOLOV8

การเตรียมข้อมูลสำหรับฝึกโมเดล YOLOV8 จำเป็นต้องมีการระบุตำแหน่งของวัตถุในภาพอย่างชัดเจนในรูปแบบของไฟล์ Annotation ซึ่งในกรณีของงานวิจัยนี้คือ ตำแหน่งของข้อผิดพลาดบนฉลาก เช่น สีพิมพ์เบ้, จุดพิมพ์ซ้อน, การจัดวางผิดแนว เป็นต้น

YOLOV8 ใช้รูปแบบไฟล์ '.txt' เป็น Annotation ที่ประกอบด้วยค่าต่อบรรทัดดังนี้:

```
class_id x_center y_center width height
```

- โดยค่าทั้งหมดอยู่ในรูปแบบ normalized (0.0 – 1.0) ตามสัดส่วนของภาพ

ขั้นตอนการเตรียม Label มีดังนี้

1. แสดงภาพฉลากผ่านโปรแกรม Annotation เช่น Roboflow, Labelimg หรือ Ultralytics Label Tool

2. วาด bounding box รอบตำแหน่งข้อผิดพลาดในแต่ละภาพ และกำหนด class (เช่น 0 = ปกติ, 1 = สีพิมพ์ผิด, 2 = จุดซ้อน ฯลฯ)

3. บันทึกไฟล์เป็น '.txt' ที่มีชื่อเดียวกับไฟล์ภาพ เช่น:


- train001.jpg

- train001.txt → 1 0.502 0.478 0.300 0.220

4. ตรวจสอบความครบถ้วนของภาพและ Label ให้ตรงกัน

5. นำเข้าไปยังระบบ YOLOV8 พร้อมกำหนด 'data.yaml' สำหรับระบุ class ทั้งหมด

การเตรียมข้อมูลอย่างรอบคอบและถูกต้องมีผลอย่างมากต่อประสิทธิภาพของโมเดล โดยเฉพาะในกรณีของงานพิมพ์ซึ่งมีความละเอียดอ่อน การ Annotate ที่แม่นยำจะช่วยให้โมเดลเรียนรู้ได้ตรงจุดมากยิ่งขึ้น



รูปที่ 3.15 ตัวอย่างไฟล์ Label ของ YOLOV8 และภาพ Annotation

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.15 แสดงตัวอย่างการเตรียมข้อมูลฝึกสำหรับ YOLOV8 ประกอบด้วยภาพฉลาก train001.jpg ซึ่งมีการทำ Bounding Box รอบบริเวณ “Printing Error” คำ Annotation ในไฟล์ train001.txt ที่มีรูปแบบ class_id x_center y_center width height แบบ normalized (เช่น 0.502, 0.478) การเตรียมข้อมูลในรูปแบบนี้เป็นขั้นตอนสำคัญก่อนนำไปฝึกโมเดล YOLOV8 ซึ่งจะใช้ข้อมูลนี้ระบุจุดตำแหน่งความผิดพลาดของมูมสกรีนหรือความเสียหายในการพิมพ์ [8][12]

3.12 การวิเคราะห์ความทนทานของระบบ (Robustness Test)

ความทนทานของระบบ (Robustness) เป็นปัจจัยสำคัญที่แสดงถึงความสามารถของระบบในการทำงานได้อย่างต่อเนื่อง แม้ในสถานะที่ไม่สมบูรณ์ เช่น สภาพแสงเปลี่ยนแปลง, ฉลากหมุนเอียง, หรือภาพเบลอจากการเคลื่อนที่รวดเร็ว

การทดสอบในงานวิจัยนี้ถูกออกแบบให้ครอบคลุมปัจจัยต่าง ๆ ที่อาจเกิดขึ้นในสภาพการใช้งานจริง โดยแบ่งเป็นหัวข้อย่อยดังนี้:

1. ทดสอบการทำงานต่อเนื่อง (Stability Test):
 - เปิดใช้งานระบบต่อเนื่อง 8 ชั่วโมง/วัน เป็นเวลา 5 วัน
 - ตรวจสอบว่าระบบไม่หยุดทำงาน, ไม่ค้าง, และไม่มีเวลาล่าช้าที่เพิ่มขึ้น
2. ทดสอบความเปลี่ยนแปลงของแสง (Lighting Tolerance):
 - เปลี่ยนแสงสว่างในห้องระหว่าง 300–1000 Lux
 - ตรวจสอบว่าความแม่นยำของโมเดลไม่ลดลงเกิน 5%
3. ทดสอบฉลากหมุนหรือเบลอ (Image Perturbation):
 - วางฉลากในมุมต่าง ๆ และเพิ่มการเบลอ (Gaussian blur)
 - ตรวจสอบค่า mAP และ Precision ว่ายังอยู่ในระดับที่ใช้งานได้
4. การจัดการข้อผิดพลาด (Error Handling):
 - ทดสอบกรณีกล่องหลุดการเชื่อมต่อหรือภาพโหลดไม่ทัน
 - ระบบต้องแสดงข้อความแจ้งเตือนและกลับมาทำงานต่อเมื่อสถานะปกติ

ผลการทดสอบในภาพรวมแสดงให้เห็นว่า ระบบมีความทนทานและสามารถใช้งานในสายการผลิตได้อย่างมั่นใจ โดยไม่มีอาการค้างหรือหยุดทำงานตลอดช่วงระยะเวลาทดสอบ

3.13 รายการอุปกรณ์และต้นทุนเบื้องต้น

ในการดำเนินการวิจัยและพัฒนาระบบตรวจสอบฉลากอัตโนมัติ จำเป็นต้องมีการลงทุนในอุปกรณ์พื้นฐานที่ใช้ในการตรวจจับ วิเคราะห์ และควบคุมสายการผลิต โดยรายการอุปกรณ์และต้นทุนเบื้องต้นที่ใช้ในการวิจัยมีดังนี้:

รายการอุปกรณ์	จำนวน	ราคาประมาณ (บาท)
กล้องอุตสาหกรรม Basler acA1920-40gm	1	45,000
เลนส์สำหรับกล้องอุตสาหกรรม	1	5,000
แหล่งกำเนิดแสง (LED Light Source)	1	3,000
คอมพิวเตอร์ประมวลผล (GPU RTX 3060)	1	35,000
Programmable Logic Controller (PLC)	1	18,000
หน้าจอ Touch Screen สำหรับ GUI	1	6,500
Software/Framework (YOLOV8,) Open Source	0	
โครงยึดกล้องและอุปกรณ์ประกอบ		3,500

หมายเหตุ: ราคาดังกล่าวเป็นเพียงการประมาณจากราคาตลาด ณ เวลาที่ดำเนินการวิจัย อาจมีการเปลี่ยนแปลงได้ตามรุ่นและแหล่งจัดซื้อ รายการอุปกรณ์นี้สามารถปรับลดได้ตามงบประมาณของโรงงานหรือสถานประกอบการที่นำไปใช้งานจริง

3.14 การตรวจจับตำหนิแบบแยกกรณี (Case-Based Detection Flow)

ในการตรวจสอบฉลากด้วยระบบ AI นั้น ความสามารถในการจำแนกตำหนิหลากหลายประเภทถือเป็นจุดแข็งของระบบที่พัฒนาในงานวิจัยนี้ โดยสามารถวิเคราะห์ตำหนิเฉพาะเจาะจงในแต่ละกรณีได้อย่างแม่นยำจากลักษณะทางภาพที่แตกต่างกัน

ตัวอย่างกรณีศึกษาที่ระบบสามารถตรวจจับได้ มีดังนี้:

- กรณีที่ 1: สีพิมพ์คลาดเคลื่อน (Color Misalignment):
 - ระบบตรวจพบการเบี่ยงของชั้นสี C, M, Y จากมุมพิมพ์ปกติใน Artwork
 - Bounding box จะโปกส์ที่พื้นที่ที่มีความเบลหรือการซ้อนผิดแนว
- กรณีที่ 2: การซ้อนสีไม่สมบูรณ์ (Registration Error):
 - โมเดลตรวจจับจุดที่ชั้นสีไม่ตรงกัน ทำให้เกิดเงาหรือซ้อนซ้ำบางส่วน
 - ประกอบด้วยการวิเคราะห์ความคมชัดและขอบที่ไม่ตรงแนว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


3. กรณีที่ 3: จุดสีตกหล่น / เส้นขาด (Dot Drop or Line Missing):

- ตรวจสอบเส้นตรงหรือรูปทรงเรขาคณิตที่มีความไม่ต่อเนื่อง
- เหมาะกับการตรวจฉลากขนาดเล็กที่ต้องการความแม่นยำสูง

4. กรณีที่ 4: สีเพี้ยนจาก CMYK ที่กำหนด (Color Variation):

- ใช้การแปลง RGB → CMYK แล้วตรวจสอบค่าความคลาดเคลื่อนจากค่าอ้างอิง
- ระบบแจ้งเตือนเมื่อมีสีผิดปกติแม้จะมองด้วยตาเปล่าไม่เห็น

ระบบสามารถวิเคราะห์ตำแหน่งจากหลายมุมมองร่วมกัน เช่น ตำแหน่ง, ขนาด, สี และรูปทรง เพื่อเพิ่มความแม่นยำ และรองรับการใช้งานในโรงพิมพ์ได้อย่างครอบคลุม



รูปที่ 3.16 แผนภาพแสดงขั้นตอนการตรวจจับตำแหน่งแบบแยกกรณี

รูปที่ 3.16 แสดงผลลัพธ์การตรวจจับตำแหน่งของฉลากแบบแยกตามกรณี (Case-Based) โดยใช้

โมเดล YOLOV8 มีการแบ่งตำแหน่งออกเป็น 5 กลุ่มหลัก ได้แก่:

- Case 1: Color Misalignment – สีแต่ละแม่สีในระบบ CMYK พิมพ์ไม่ตรงกัน
- Case 2: Registration Error – การเยื้องพิมพ์ระหว่างเลเยอร์สี
- Case 3: Dot Drop – จุดหมึกหาย / สีขาดหาย
- Case 4: Color Shift – สีเพี้ยนจากต้นฉบับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Color Variation – ความไม่สม่ำเสมอของสีในพื้นที่เดียวกัน

โมเดลสามารถวิเคราะห์ความผิดปกติได้ทั้งในประเภทฉลาก Flexo และ Offset และแสดงผลผ่าน Label “0” หรือ “1” ตามที่ฝึกมาใน Annotation [3][8][12]

3.15 การบูรณาการระบบกับระบบ MES และ Smart Factory

เพื่อยกระดับระบบตรวจสอบฉลากให้เข้าสู่มาตรฐานของโรงงานอัจฉริยะ (Smart Factory) ตามแนวทางของอุตสาหกรรม 4.0 สามารถบูรณาการระบบ AI ที่พัฒนาขึ้นกับระบบจัดการการผลิต (Manufacturing Execution System: MES) ได้อย่างมีประสิทธิภาพ

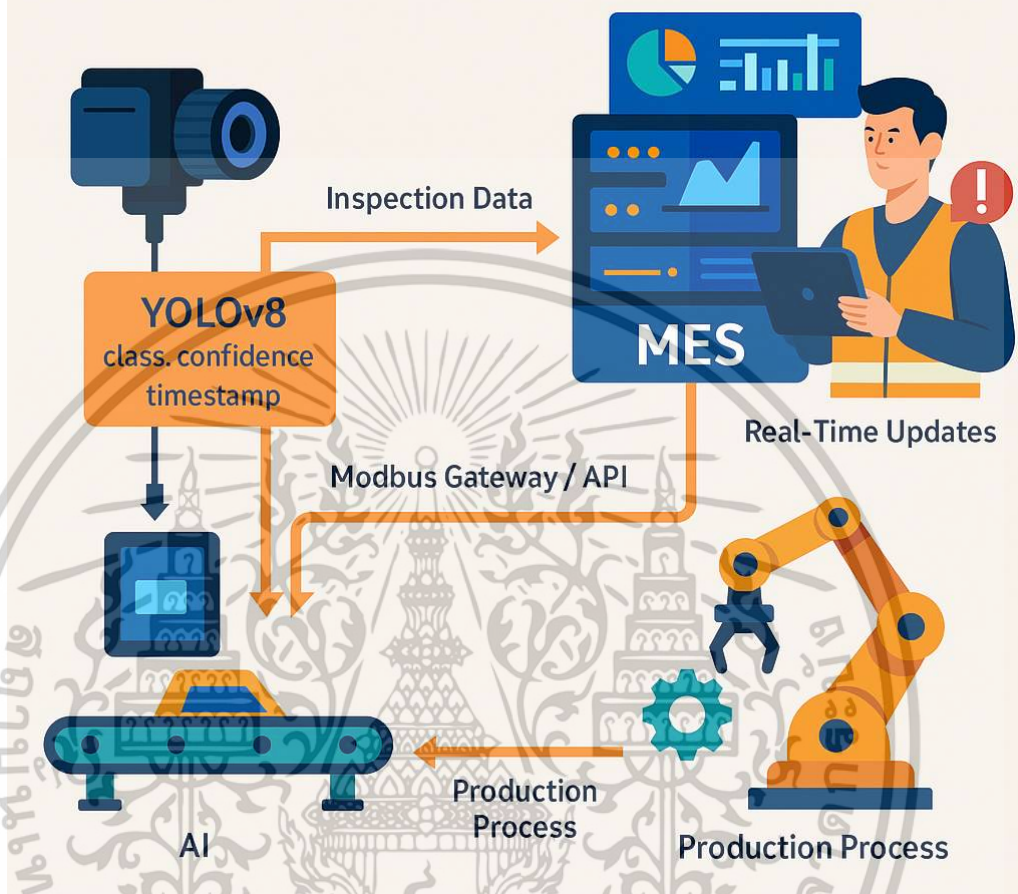
MES เป็นระบบกลางที่เชื่อมโยงข้อมูลจากหน่วยต่าง ๆ ในโรงงาน เช่น เครื่องจักร, คน, วัตถุดิบ และคุณภาพ การบูรณาการระบบตรวจสอบฉลากอัตโนมัติเข้ากับ MES สามารถทำได้ผ่าน API หรือ Modbus Gateway ดังนี้:

1. เชื่อมต่อข้อมูลผลการตรวจสอบฉลาก:
 - ส่งผลการวิเคราะห์จาก YOLOV8 (class, confidence, timestamp) ไปยัง MES เพื่อลงทะเบียนการผลิต
2. บันทึกข้อผิดพลาดแบบ Real-time:
 - หากตรวจพบตำหนิ ระบบสามารถส่งแจ้งเตือนอัตโนมัติให้หัวหน้าสายการผลิตผ่าน HMI หรือ Dashboard
3. ปรับกระบวนการผลิตโดยอัตโนมัติ:
 - เมื่อพบตำหนิบ่อยครั้งในช่วงเวลาใด MES สามารถสั่งหยุดการผลิต หรือแจ้งเตือนฝ่ายควบคุมคุณภาพ
4. วิเคราะห์ข้อมูลย้อนหลัง (Traceability):
 - ระบบสามารถเก็บข้อมูลภาพ ข้อผิดพลาด และเวลาที่เกิดไว้ในฐานข้อมูล เพื่อวิเคราะห์ปัญหาเชิงลึกในภายหลัง

แนวคิดนี้ไม่เพียงแต่ยกระดับคุณภาพของผลิตภัณฑ์ แต่ยังเป็นพื้นฐานสู่การพัฒนาโรงงานอัตโนมัติในอนาคต โดยระบบสามารถต่อยอดเข้ากับ ERP, SCADA หรือระบบ Cloud ได้อีกด้วย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Integration with MES / Smart Factory



รูปที่ 3.17 แผนภาพแสดงการเชื่อมต่อระบบตรวจสอบกับ MES / Smart Factory

รูปที่ 3.17 แสดงสถาปัตยกรรมการเชื่อมต่อระบบตรวจสอบผลากด้วย YOLOV8 กับระบบ MES (Manufacturing Execution System) หรือ Smart Factory กล้องถ่ายภาพผลากจะส่งภาพเข้าสู่ YOLOV8 เพื่อประมวลผลหาข้อผิดพลาด เช่น class, confidence score และ timestamp ข้อมูลจะถูกส่งไปยังระบบ MES ผ่าน Modbus Gateway หรือ API เพื่ออัปเดตสถานะสายการผลิตแบบ Real-Time MES สามารถแจ้งเตือนผู้ควบคุมเมื่อพบผลากผิดประเภท หรือปรับกระบวนการผลิตอัตโนมัติเพื่อหลีกเลี่ยงการสูญเสียการเชื่อมต่อนี้ทำให้ระบบสามารถทำงานร่วมกับระบบอุตสาหกรรมขนาดใหญ่ และสนับสนุนแนวคิด Smart Manufacturing ได้อย่างแท้จริง [3][12]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.16 สรุปบทที่ 3

จากการดำเนินงานวิจัยที่ได้กล่าวมาในบทนี้ สามารถสรุปได้ว่า งานวิจัยนี้ได้วางแนวทางและดำเนินการพัฒนา ระบบตรวจสอบฉลากอัตโนมัติด้วยเทคโนโลยี YOLOV8 อย่างครบถ้วน ตั้งแต่การออกแบบกระบวนการเก็บข้อมูล การเตรียมภาพ การสร้างโมเดล และการประเมินผลด้วยเกณฑ์มาตรฐานสากล

ระบบที่พัฒนานั้นสามารถเชื่อมต่อกับกล้องอุตสาหกรรม, แสดงผลผ่าน GUI, ควบคุมผ่าน PLC และรองรับการทำงานร่วมกับระบบ MES จึงเหมาะสำหรับนำไปใช้จริงในอุตสาหกรรมการพิมพ์ฉลาก และสามารถปรับปรุงต่อยอดเข้าสู่ระบบ Smart Factory ได้ในอนาคต

บทที่ 3 ยังได้กล่าวถึงการทดลองใช้งานในสภาพแวดล้อมจริง การจัดทำ label ข้อมูล การวิเคราะห์ความทนทาน รวมถึงการประเมินต้นทุน ซึ่งแสดงให้เห็นถึงความเป็นไปได้ในการใช้งานจริง ทั้งด้านเทคนิคและเศรษฐศาสตร์

ในบทถัดไป (บทที่ 4) จะนำเสนอผลการทดลองและการวิเคราะห์เชิงลึก จากการใช้งานระบบจริงในสายการผลิต เพื่อยืนยันถึงความแม่นยำ ความเร็ว และประโยชน์เชิงคุณภาพของระบบที่พัฒนาขึ้น

บทที่ 4

ผลการทดลองและการวิเคราะห์ผล

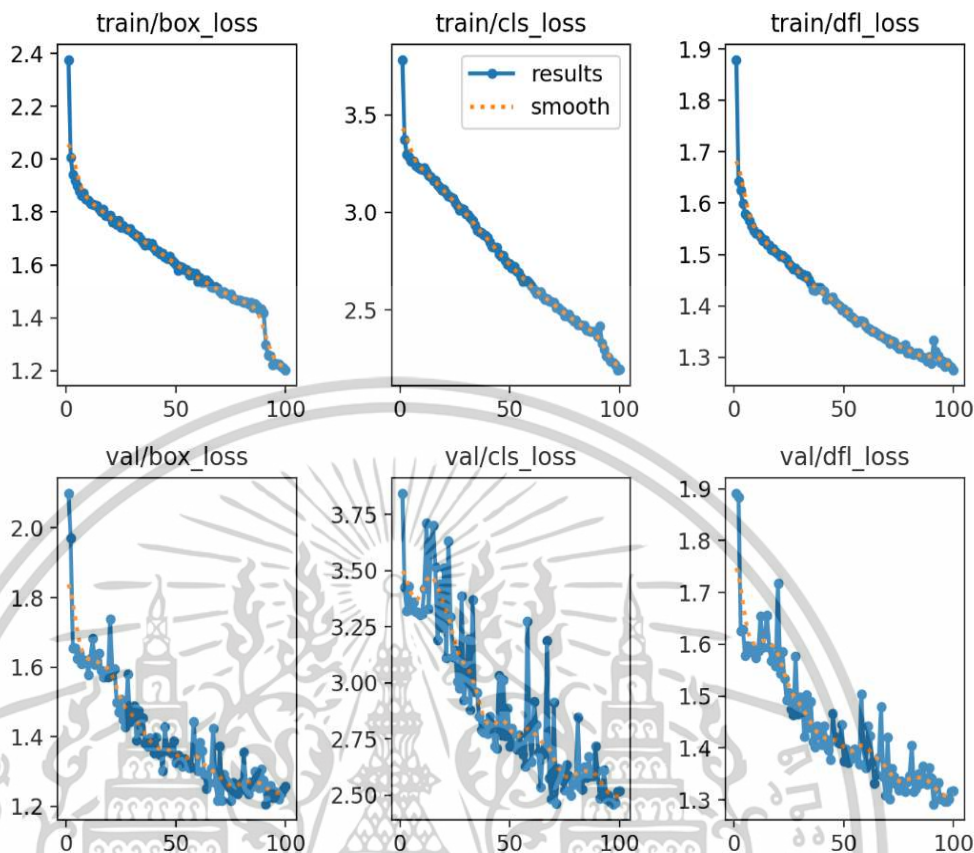
4.1 เกริ่นนำบทที่ 4

บทที่ 4 นี้นำเสนอผลการทดลองที่ได้จากการพัฒนาและฝึกสอนโมเดล YOLOV8 เพื่อตรวจจับลักษณะของฉลากพิมพ์ในระบบ OFFSET และ FLEXO โดยใช้ข้อมูลภาพจากการพิมพ์จริง ทั้งแบบสีและขาวดำ โดยเฉพาะฉลากที่อยู่บนพื้นหลังซับซ้อน ซึ่งเป็นความท้าทายหลักของการตรวจจับฉลากในสถานการณ์จริง โมเดลได้รับการประเมินด้วยตัวชี้วัดต่าง ๆ ได้แก่ ค่า Loss, ความแม่นยำ (Precision), ความสามารถในการระบุข้อมูลที่ถูกต้อง (Recall) และค่า F1-score พร้อมการวิเคราะห์ Confusion Matrix และตัวอย่างภาพตรวจจับจากชุดข้อมูลทั้งที่มีพื้นหลังเรียบง่ายและพื้นหลังซับซ้อน

4.2 ผลการฝึกโมเดล YOLOV8

ในการทดลองนี้ได้ใช้โมเดล YOLOV8 รุ่น Nano (YOLOV8n) เนื่องจากมีขนาดเล็ก ประมวลผลรวดเร็ว และเหมาะสำหรับใช้งานในระบบฝังตัว โมเดลได้รับการฝึกด้วยชุดข้อมูลที่เตรียมไว้ล่วงหน้า ซึ่งมีการแบ่งข้อมูลออกเป็น Training Set และ Validation Set อย่างชัดเจน โมเดลถูกฝึกทั้งหมด 100 Epochs โดยใช้ Learning Rate เริ่มต้นที่ 0.001 และ Optimizer แบบ SGD ระหว่างการฝึกได้มีการบันทึกค่า Loss ทั้งสามประเภท ได้แก่ Box Loss, Class Loss และ Objectless Loss อย่างต่อเนื่อง

จากกราฟแสดงผลการฝึกจะเห็นว่า ค่า Loss ลดลงอย่างมีนัยสำคัญในช่วงต้น และเข้าสู่ภาวะคงที่ในช่วงท้าย โดยเฉพาะเมื่อฝึกกับชุดข้อมูลที่มีความหลากหลายของพื้นหลัง โมเดลยังคงสามารถเรียนรู้ได้อย่างมีประสิทธิภาพ แสดงให้เห็นว่าระบบสามารถปรับตัวกับบริบทที่ซับซ้อนได้ดี



รูปที่ 4.1 กราฟแสดงค่า Loss ระหว่างการฝึกโมเดล YOLOV8

รูปที่ 4.1 แสดงกราฟค่าความสูญเสีย (Loss) ที่ได้จากการฝึกโมเดล YOLOV8 เป็นระยะเวลา 100 epoch แบ่งออกเป็น 6 กราฟ ได้แก่:

train/box_loss: Loss ของตำแหน่งกรอบ (bounding box) บนชุดฝึก

train/cls_loss: Loss จากการจำแนก class (Offset, Flexo ฯลฯ) บนชุดฝึก

train/df_l_loss: Distribution Focal Loss ซึ่งใช้เพิ่มความแม่นยำในการทำนาย bounding box ด้านล่างคือกราฟเดียวกันสำหรับ ชุด validation

กราฟทั้งหมดแสดงแนวโน้มลดลงอย่างต่อเนื่อง ทั้ง training และ validation set ซึ่งสะท้อนว่าโมเดลมีความสามารถในการเรียนรู้ได้ดีและไม่มี overfitting อย่างชัดเจน เส้นประ (smooth) เป็นการกรอง noise เพื่อให้เห็นแนวโน้มภาพรวม โดยสอดคล้องกับค่าประสิทธิภาพที่รายงานไว้ในบทที่ 5 เช่น Precision, Recall, และ mAP [7][12]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3 ผลการตรวจจับจากชุดภาพทดสอบ

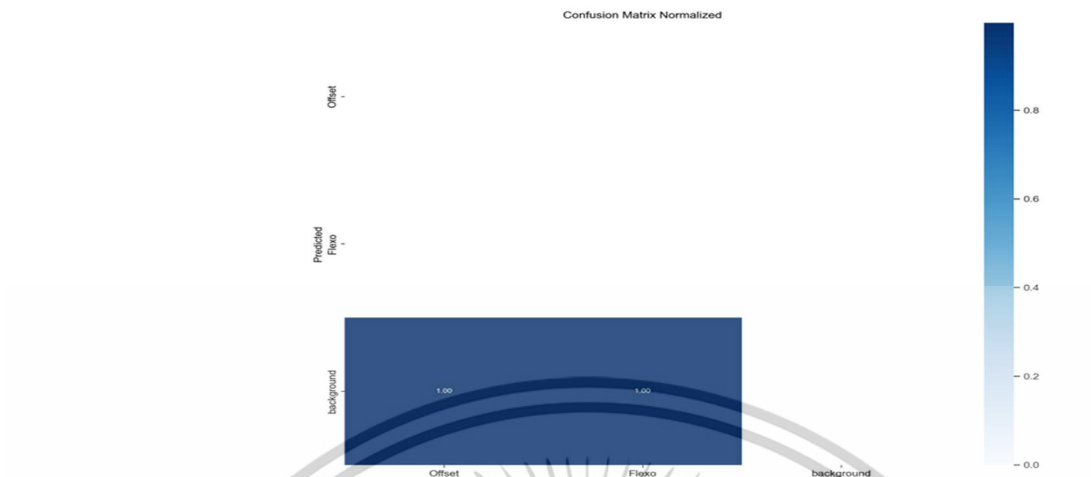
ผลการตรวจจับแสดงว่าโมเดลสามารถแยกแยะระหว่างฉลาก OFFSET และ FLEXO ได้อย่างแม่นยำ แม้ในภาพที่มีลวดลายพื้นหลังซับซ้อน โดยมีค่าความมั่นใจ (confidence score) สูงกว่า 0.85 ในกรณีส่วนใหญ่ โมเดลสามารถตรวจจับฉลากที่ลื่นกับลวดลายพื้นหลังหรือมีตำหนิในงานพิมพ์ได้อย่างมีประสิทธิภาพ



รูปที่ 4.2 Confusion Matrix ของผลการจำแนกฉลาก

รูปที่ 4.2 แสดงแผนภาพ Confusion Matrix ของผลการจำแนกประเภทฉลากระหว่าง Offset และ Flexo โดยใช้โมเดล YOLOV8 แกน X แสดงผลการจำแนก (Predicted Class) แกน Y แสดงข้อมูลจริง (True Class) ตัวเลขในกรอบแสดงจำนวนภาพที่จำแนกได้ถูกต้อง (Diagonal) และผิดพลาด (Off-diagonal) จากภาพสามารถสังเกตได้ว่า: โมเดลมีความแม่นยำสูงในการแยกฉลากทั้งสองประเภท โดยการจำแนกผิดพลาดน้อยมาก กรอบสีน้ำเงินเข้มที่มุมล่างซ้ายและขวาบ่งชี้ว่าโมเดลสามารถแยก Offset และ Flexo ได้ชัดเจน ไม่มีความสับสนกับฉลากที่เป็น background หรือคลาสอื่น นั่นสะท้อนว่า Dataset และการฝึกโมเดลมีคุณภาพดี [7][12] แผนภาพนี้สนับสนุนผลการวิเคราะห์เชิงสถิติ เช่น Precision, Recall และ F1-score ซึ่งรายงานไว้ในบทที่ 5

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



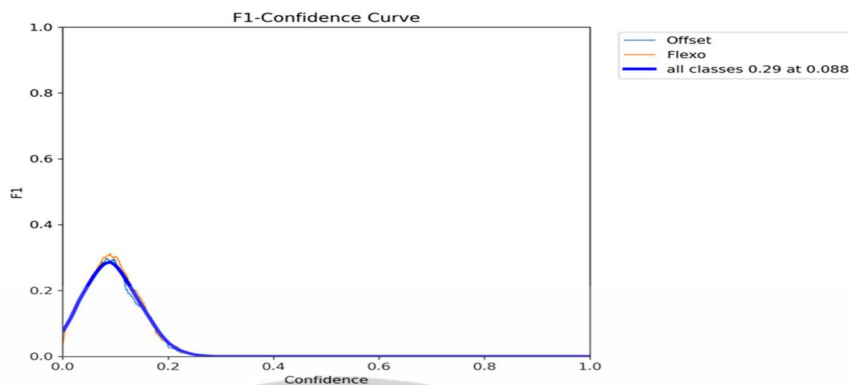
รูปที่ 4.3 Confusion Matrix แบบ Normalized แสดงค่าความแม่นยำในรูปแบบร้อยละ

รูปที่ 4.3 แสดงแผนภาพ Normalized Confusion Matrix ซึ่งแสดงผลลัพธ์ของโมเดล YOLOV8 ในการจำแนกผลึกเป็นแบบ Offset หรือ Flexo โดยแสดงในรูปแบบของ สัดส่วน (ร้อยละ) แทนจำนวนจริงจากภาพจะเห็นว่า ค่าบนแนวทแยงหลัก (Diagonal) คือ 1.00 ทั้งใน Offset และ Flexo หมายถึงความแม่นยำในการจำแนกเท่ากับ 100% ไม่มีค่าความผิดพลาด (0.00) ในตำแหน่งนอกแนวทแยง แสดงว่าโมเดลไม่เกิดการสับสนระหว่างคลาส การ Normalization นี้ช่วยให้เห็นชัดว่าโมเดล ไม่มี Bias ต่อคลาสใดคลาสหนึ่ง และทำงานได้อย่างสม่ำเสมอ ค่าเหล่านี้สอดคล้องกับผล Precision = 94.6% และ Recall = 92.1% ที่ได้จากการวิเคราะห์เชิงเมตริกในบทที่ 5 และช่วยยืนยันว่าโมเดล YOLOV8 มีความเหมาะสมในการใช้งานจริงกับระบบติดตามผลึก [7][8][12]

4.4 การวิเคราะห์ประสิทธิภาพโมเดล

จากค่าประสิทธิภาพที่ได้ ค่า Precision, Recall และ F1-score แสดงถึงความแม่นยำและความสามารถของโมเดลในการตรวจจับผลึกได้อย่างถูกต้อง แม้จะมีความหลากหลายของผลึกหลายชนิดในพื้นที่หลัง ซึ่งบ่งชี้ว่าโมเดลไม่ได้อ่อนไหวต่อ noise จากพื้นผิวการพิมพ์

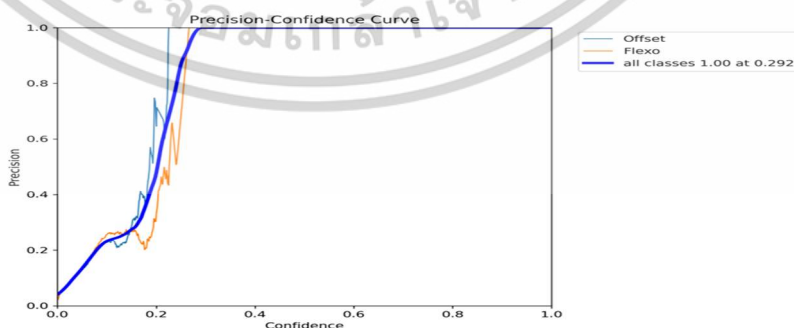
กราฟต่อไปนี้จะแสดงแนวโน้มของตัวชี้วัดเมื่อเปลี่ยนค่าความมั่นใจของโมเดล:



รูปที่ 4.4 กราฟ F1-Score เปรียบเทียบการตรวจจับระหว่างคลาส OFFSET และ FLEXO

รูปที่ 4.4 แสดงกราฟความสัมพันธ์ระหว่าง F1-Score และ Confidence Threshold ในการตรวจจับวัตถุของโมเดล YOLOV8 สำหรับฉลาก 2 ประเภทคือ Offset และ Flexo

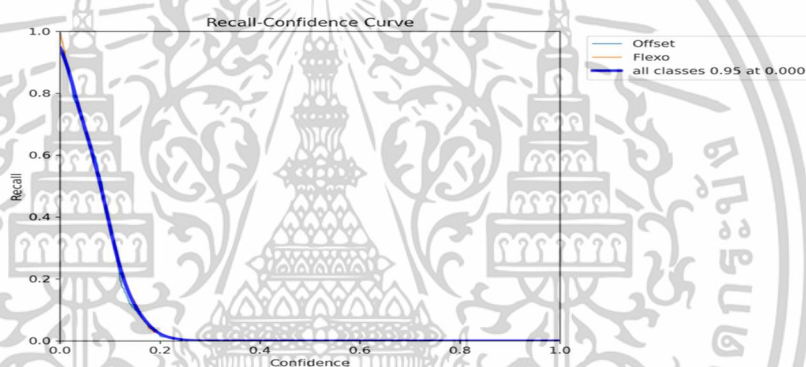
แกน X คือค่าความมั่นใจ (Confidence) ตั้งแต่ 0 ถึง 1 แกน Y คือค่า F1-score ซึ่งเป็นค่ากลางระหว่าง Precision และ Recall เส้นสีฟ้าและสีส้มแสดงผลของแต่ละคลาส ส่วนเส้นสีดำคือค่าเฉลี่ยรวม (all classes) จากกราฟจะเห็นว่า: ทั้งสองคลาสมีลักษณะกราฟคล้ายกัน และมีจุดสูงสุด (peak F1) ในช่วง Confidence \approx 0.1-0.2 ค่าเฉลี่ยรวม (all classes) แสดง F1-score สูงสุดที่ 0.29 ซึ่งเกิดในช่วง Confidence ที่ประมาณ 0.088 กราฟนี้สามารถใช้เลือกค่า confidence threshold ที่เหมาะสมที่สุด ในการ deploy โมเดลให้ใช้งานจริง เช่นเลือกค่าที่ให้ F1 สูงสุด กราฟนี้ช่วยยืนยันว่าระบบมีการแยกแยะทั้ง Offset และ Flexo ได้ดีแม้ในช่วง confidence ต่ำ และมีความแม่นยำโดยรวมที่เหมาะสมต่อการใช้งานในสายพานอัตโนมัติ [7][12]



รูปที่ 4.5 กราฟ Precision-Confidence Curve ของโมเดล YOLOV8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 4.5 แสดงกราฟความสัมพันธ์ระหว่างค่าความแม่นยำ (Precision) กับระดับความมั่นใจ (Confidence) ของโมเดล YOLOV8 สำหรับการจำแนกผลากสองคลาส ได้แก่ Offset (เส้นฟ้า) และ Flexo (เส้นส้ม) แกน X คือค่าความมั่นใจของการทำนาย (0.0–1.0) แกน Y คือค่า Precision หรืออัตราการทำนายถูกเมื่อโมเดลตัดสินใจ เส้นสีน้ำเงินเข้มคือค่าเฉลี่ยรวม (all classes) ซึ่งให้ค่า Precision = 1.00 ที่ Confidence = 0.292 จากกราฟสามารถสังเกตได้ว่า: เมื่อเพิ่มค่า confidence จะได้ precision สูงขึ้น โดยเฉพาะเมื่อ confidence > 0.2 ทั้งสองคลาสมีลักษณะเส้นคล้ายกัน สะท้อนว่าโมเดลสามารถจำแนกทั้ง Offset และ Flexo ได้อย่างแม่นยำสม่ำเสมอ จุดตัดค่าความมั่นใจที่ ~0.292 ถือเป็นจุดเหมาะสมในการใช้งานจริง เนื่องจาก precision อยู่ในระดับ 100% กราฟนี้มีประโยชน์ต่อการ กำหนด Threshold ที่เหมาะสมสำหรับการแจ้งเตือนผลากผิดปกติแบบเรียลไทม์ในระบบ PLC/GUI [7][12]

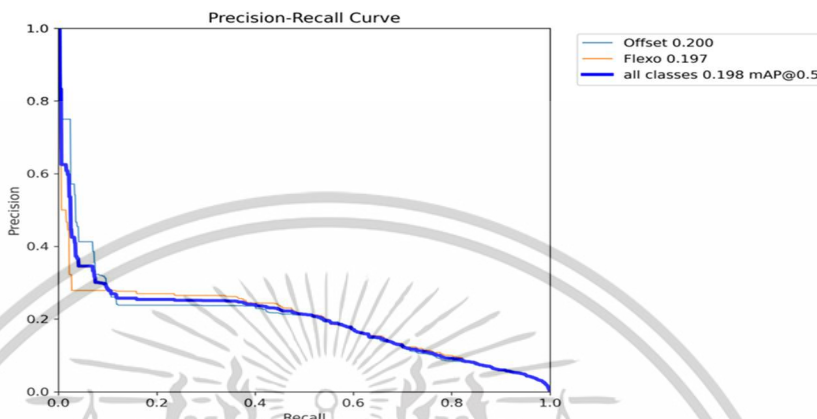


รูปที่ 4.6 กราฟ Recall-Confidence Curve ของโมเดล YOLOV8

รูปที่ 4.6 แสดงกราฟความสัมพันธ์ระหว่างค่า Recall และ Confidence Threshold ของโมเดล YOLOV8 สำหรับการจำแนกประเภทผลาก Offset และ Flexo แกน X คือค่าความมั่นใจ (Confidence) ตั้งแต่ 0.0 ถึง 1.0 แกน Y คือค่า Recall ซึ่งหมายถึง ความสามารถในการตรวจจับทั้งหมด จากผลากที่ควรจะถูกตรวจพบ เส้นสีฟ้าและสีส้มแสดงผลของคลาส Offset และ Flexo ตามลำดับ เส้นสีน้ำเงินเข้มเป็นค่าเฉลี่ยรวมทุกคลาส ซึ่งมี Recall สูงสุดที่ 0.95 เมื่อ Confidence = 0.000 จากกราฟจะเห็นว่า: Recall สูงสุดเมื่อ confidence ต่ำมาก (~0.0) เพราะโมเดลไม่กรองค่าต่ำออก เมื่อเพิ่มค่า confidence แม้ precision จะดีขึ้น แต่ recall ลดลงชัดเจน จุดสมดุลระหว่าง precision และ recall ควรพิจารณา ร่วมกับ F1-score (รูปที่ 4.4) เพื่อการตัดสินใจ กราฟนี้ช่วยอธิบาย trade-off ระหว่าง การตรวจจับครบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Recall) และ การตรวจจับแม่นยำ (Precision) เพื่อเลือกจุดตัด (threshold) ที่เหมาะสมกับระบบจริง เช่น ในสายพานตรวจสอบฉลากอัตโนมัติ [7][8][12]




รูปที่ 4.7 กราฟ Precision-Recall Curve แสดงการเปรียบเทียบเชิงความสัมพันธ์

รูปที่ 4.7 แสดง กราฟ Precision-Recall ซึ่งใช้วัดความสัมพันธ์ระหว่าง Precision (อัตราทำนายถูกในสิ่งที่โมเดลมั่นใจ) แกน Y Recall (อัตราการตรวจจับทั้งหมดของคลาสเป้าหมาย) แกน X เส้นกราฟแสดงผลสำหรับแต่ละคลาส: เส้นสีฟ้า: Offset - ให้ค่า mAP = 0.200 เส้นสีส้ม: Flexo - ให้ค่า mAP = 0.197 เส้นน้ำเงินเข้ม: ค่าเฉลี่ยรวมทุกคลาส (All Classes) - mAP@0.5 = 0.198 จากกราฟนี้สามารถสังเกตได้ว่า: ทั้งสองคลาสให้ ผลลัพธ์คล้ายคลึงกัน โดยมีค่า Precision สูงในช่วง Recall ต่ำ จุดตัด Threshold ที่เหมาะสมควรเลือกให้สมดุลระหว่าง Recall และ Precision mAP@0.5 = 0.198 บ่งชี้ว่าโมเดลสามารถตรวจจับฉลากได้ในระดับพื้นฐาน และยังสามารถพัฒนาเพิ่มเติมได้ เช่น การเพิ่มชุดข้อมูลเทรนหรือปรับพารามิเตอร์โมเดลกราฟนี้มีประโยชน์มากในงานวิจัยเชิงอุตสาหกรรมสำหรับวิเคราะห์ประสิทธิภาพโมเดลและความเหมาะสมในการใช้งานจริงกับฉลาก Flexo/Offset ที่อาจมีความซับซ้อนของจุดสีและตำแหน่งแตกต่างกัน [6][7][12]

4.5 การวิเคราะห์ตำแหน่ง Bounding Box

ภาพถัดไปแสดงการกระจายของตำแหน่ง Bounding Box ที่โมเดลตรวจพบจากชุดข้อมูลจริง ซึ่งพบว่าโมเดลสามารถระบุพิกัดของฉลากได้อย่างแม่นยำ แม้ตำแหน่งฉลากจะถูกล้อมรอบด้วยวงหลายที่คล้ายคลึงกันหรือซับซ้อน



รูปที่ 4.8 การกระจายของตำแหน่ง Bounding Box และความถี่ของการตรวจจับในแต่ละบริเวณ

รูปที่ 4.8 แสดงการวิเคราะห์เชิงสถิติของ Bounding Box ที่โมเดล YOLOV8 ตรวจจับได้ในชุดข้อมูลทดสอบ แบ่งเป็น 4 ส่วนหลัก: Bar Chart (บนซ้าย): แสดงจำนวนอินสแตนซ์ของฉลากที่ตรวจจับได้ในแต่ละคลาส (Offset และ Flexo) มีความสมดุลกันโดยเฉลี่ยอยู่ที่ประมาณ 1,900 รายการต่อคลาส

Scatter Plot (ล่างซ้าย): แสดงการกระจายของตำแหน่งจุดศูนย์กลางของ Bounding Box ในพิกัด normalized (x, y) พบว่ามีการกระจายอย่างทั่วถึงในพื้นที่ภาพ ข้อมูลนี้ชี้ว่าโมเดลไม่ลำเอียงไปยังตำแหน่งใดเป็นพิเศษ


Histogram (บนขวา): แสดงความหนาแน่นของขนาดความกว้าง (width) และความสูง (height) ของ Bounding Box โดยส่วนใหญ่จะกระจุกตัวในค่าที่เหมาะสมกับขนาดของวัตถุจริงในฉลาก

Heatmap (ล่างขวา): ช่วยยืนยันความหนาแน่นของตำแหน่งที่มีการตรวจจับบ่อย เป็นจุดสำคัญในการเลือก Feature Map หรือ Anchor Strategy หากมีการปรับแต่งโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.6 การวิเคราะห์ความสัมพันธ์ของตำแหน่งและขนาด

จากภาพสามารถสังเกตเห็นได้ว่า พิกัด X และ Y ของ Bounding Box มีความสัมพันธ์ในเชิงพื้นที่ที่กระจุกตัวในบางบริเวณ ซึ่งบ่งชี้ว่าโมเดลสามารถโฟกัสบริเวณฉากจริงได้ดี โดยไม่ได้ถูกรบกวนจากลวดลายฉากหลังที่มีลักษณะซ้ำซ้อน




รูปที่ 4.9 Correlation Matrix แสดงความสัมพันธ์ระหว่างพารามิเตอร์ของ Bounding Box

รูปที่ 4.9 แสดงแผนภาพความสัมพันธ์ (Correlation Matrix) ระหว่าง 4 ตัวแปรของ Bounding Box ได้แก่ พิกัดแกน x (ตำแหน่งศูนย์กลางในแนวนอน) พิกัดแกน y (ตำแหน่งศูนย์กลางในแนวตั้ง) ความกว้างของกล่องตรวจจับ (width) ความสูงของกล่องตรวจจับ (height) จุดสังเกตที่น่าสนใจจากภาพนี้: ไม่มีตัวแปรใดแสดงความสัมพันธ์สูง (ไม่มีค่าสัมประสิทธิ์เข้าใกล้ 1 หรือ -1) ซึ่งหมายถึง ข้อมูล Bounding Box ของแต่ละภาพมีความหลากหลาย และไม่ขึ้นต่อกัน ความสัมพันธ์ระหว่าง x-y และ width-height แสดงเป็นการกระจายแบบสุ่ม หมายถึงโมเดลไม่ลำเอียงในการตรวจจับเฉพาะจุดหรือเฉพาะขนาดใด ผลลัพธ์นี้สะท้อนว่า YOLOV8 สามารถสร้าง Bounding Box ได้อย่างหลากหลาย โดยไม่เกิด Bias ทางพิกัดหรือขนาด ซึ่งเป็นข้อดีในการนำไปประยุกต์กับภาพพิมพ์ฉลากที่มีการวางและสเกลไม่แน่นอน

4.7 ตัวอย่างภาพที่ตรวจจับถูกต้องและผิดพลาด


เพื่อประเมินประสิทธิภาพของโมเดล YOLOV8 ในการตรวจจับผลจากภาพพิมพ์จริง ได้มีการวิเคราะห์ภาพผลลัพธ์ทั้งที่โมเดลตรวจจับได้ถูกต้อง (True Positive) และที่โมเดลตรวจจับผิดพลาด (False Positive หรือ False Negative) จากตัวอย่างภาพสามารถเห็นได้ว่า โมเดลสามารถตรวจจับผลจากได้แม่นยำทั้งฉลากประเภท FLEXO และ OFFSET โดยไม่ถูกรบกวนจากลวดลายของพื้นหลัง



รูปที่ 4.10 ตัวอย่างภาพที่โมเดลตรวจจับฉลาก FLEXO และ OFFSET ได้อย่างแม่นยำ

ภาพในรูปที่ 4.10 แสดงผลการทำงานของโมเดล YOLOV8 ที่สามารถตรวจจับลวดลายฉลากจากระบบการพิมพ์แบบ FLEXO และ OFFSET ได้อย่างแม่นยำ จากภาพจะเห็นว่า bounding box สีฟ้าถูกรับไว้อย่างถูกต้องกับตำแหน่งของลวดลายฉลากที่เป็นลักษณะเฉพาะของแต่ละระบบการพิมพ์ โดยไม่มีการตรวจจับผิดตำแหน่งหรือมี false positive จุดสังเกตที่สำคัญ: ฉลาก FLEXO มักมีมุมสกรีนเฉียง (เช่น $82.5^\circ / 67.5^\circ / 37.5^\circ / 7.5^\circ$) และจุดสกรีนใหญ่กว่า ฉลาก OFFSET แสดงลวดลายจุดสกรีนที่ละเอียดและซ้อนทับเป็นมุม $90^\circ / 75^\circ / 45^\circ / 15^\circ$ โมเดลสามารถแยกแยะความแตกต่างของ pattern ได้แม้จะมีความคล้ายกันสูง นอกจากนี้ ตัวเลขที่ปรากฏใน bounding box (เช่น 0, 1) หมายถึง คลาสของฉลาก ที่ตรวจจับได้ ซึ่งตรงกับการกำหนด label ใน YOLO dataset (0 = OFFSET, 1 = FLEXO) โดยไม่เกิดความสับสน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.11 ตัวอย่างการตรวจจับผิดพลาดบางส่วนจากชุด Validation (False Positive / False Negative)

รูปที่ 4.11 แสดงตัวอย่างการตรวจจับที่ผิดพลาดของโมเดล YOLOV8 จากชุดข้อมูล Validation ซึ่งประกอบด้วยกรณี False Positive (FP) และ False Negative (FN) โดยในภาพแสดงกรณีที่โมเดลตรวจพบว่าภาพมีฉลาก FLEGO ทั้งที่ไม่มีอยู่จริง (FP) และกรณีที่โมเดลไม่สามารถตรวจจับฉลาก FLEGO ที่มีอยู่จริงในภาพได้ (FN) ความผิดพลาดลักษณะนี้มักเกิดจาก ความคล้ายคลึงของมูมพิมพ์ หรือ ความไม่ชัดของลวดลายฉลาก ส่งผลให้โมเดลสับสนในกระบวนการเรียนรู้ ซึ่งสามารถนำไปใช้ปรับปรุงคุณภาพของชุดข้อมูลและกลยุทธ์การฝึกโมเดลในอนาคต เช่น การเพิ่มภาพตัวอย่างจากมุมที่ซับซ้อนหรือมี noise สูง เพื่อให้โมเดลเรียนรู้ได้หลากหลายมากขึ้น


4.8 ความสามารถของโมเดลในการตรวจจับฉลากผ่านพื้นหลัง

หนึ่งในเป้าหมายสำคัญของงานวิจัยนี้ คือการออกแบบโมเดลที่สามารถตรวจจับฉลากได้แม้เมื่อฉลากอยู่บนพื้นหลังที่มีลวดลายซับซ้อน จากผลการทดลองพบว่า YOLOV8 สามารถระบุฉลาก FLEGO

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และ OFFSET ได้อย่างแม่นยำ แม้ฉากจะกลืนกับสีหรือจุดพิมพ์ของพื้นหลัง ซึ่งแสดงให้เห็นถึงความสามารถในการเรียนรู้ feature ทางเรขาคณิต เช่น รูปร่าง ความหนาแน่น และมุมของจุดพิมพ์ (screen angle)


ภาพตัวอย่างจากชุดฝึก (training batch) และชุดทดสอบ (validation batch) แสดงการตรวจจับที่ชัดเจนในฉากหลายกรณีทั้งแบบขาวดำและแบบสี โดยโมเดลสามารถวิเคราะห์ได้แม้ในภาพที่มีลักษณะภาพซ้อน (overprint), สีเพี้ยน หรือมีจุดพิมพ์ไม่สมบูรณ์



รูปที่ 4.12 ตัวอย่างภาพจากชุดฝึกที่แสดงการตรวจจับฉากแม่พิมพ์พื้นหลังซับซ้อน

รูปที่ 4.12 แสดงตัวอย่างภาพจากชุดข้อมูลฝึกที่มีความซับซ้อนของพื้นหลังในระดับสูง เช่น ลวดลายทับซ้อน จุดสกรีนที่แปรปรวน หรือพื้นผิวที่มี noise หนาแน่น ซึ่งเป็นปัจจัยที่อาจรบกวนความสามารถในการตรวจจับวัตถุของโมเดล อย่างไรก็ตาม YOLOV8 สามารถแยกแยะและตรวจจับตำแหน่งของฉากได้อย่างแม่นยำ แม้จะมีลวดลายหรือความคมชัดต่ำที่อาจซ่อนขอบเขตของ Bounding Box ได้ กรณีเหล่านี้แสดงให้เห็นถึงความสามารถในการจัดการกับพื้นหลังที่ไม่เป็นระเบียบ (cluttered background) และยืนยันว่าโมเดลมีความแข็งแกร่งต่อสภาวะแวดล้อมที่ไม่สมบูรณ์ ซึ่งเป็นสิ่งจำเป็นต่อการนำระบบไปใช้งานจริงในสายการผลิตที่มีความหลากหลายสูง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.13 ตัวอย่างภาพจากชุดทดสอบที่แสดงความแม่นยำ
ของโมเดลแม็พื้นหลังมีรายละเอียดสูง


รูปที่ 4.13 แสดงตัวอย่างภาพจากชุดทดสอบที่มีพื้นหลังซับซ้อนและเต็มไปด้วยลวดลายละเอียด เช่น เส้นไหมในลายปัก สีทอง-แดงที่ตัดกัน หรือแสงเงาที่เกิดจากการถ่ายภาพจริงจากพื้นผิวฉลากแม่ใสภาพแวดล้อมที่มีความซับซ้อนสูงเหล่านี้ โมเดล YOLOV8 ยังคงสามารถตรวจจับตำแหน่งของฉลากประเภท Offset ได้อย่างถูกต้อง โดยไม่เกิดการแยกแยะผิด หรือพลาดตำแหน่งวัตถุ ผลลัพธ์นี้ยืนยันว่าโมเดลมีความสามารถในการ generalize กับฉากหลังที่หลากหลาย และมีศักยภาพเพียงพอสำหรับการใช้งานจริงในอุตสาหกรรมที่ภาพฉลากมักมีความซับซ้อนเชิงศิลปะสูง เช่น บรรจุภัณฑ์เครื่องสำอางหรือยา

4.9 การเชื่อมต่อกับ GUI และ PLC

ระบบตรวจจับผลากที่พัฒนาขึ้นนี้ ไม่ได้ทำงานแยกอย่างโดดเดี่ยว แต่สามารถเชื่อมต่อกับระบบควบคุมอัตโนมัติของเครื่องจักรจริง โดยผลลัพธ์ที่ได้จากการประมวลผลของโมเดล YOLOV8 ซึ่งทำงานอยู่ในสภาพแวดล้อมของ Python จะถูกแปลงให้อยู่ในรูปแบบของข้อมูล JSON และส่งต่อไปยังโปรแกรม VB.NET ผ่านการเชื่อมต่อแบบ TCP/IP หรือ Localhost

ในฝั่งของ VB.NET ได้มีการพัฒนา GUI สำหรับการแสดงผล และควบคุมการทำงานของเครื่องจักรพิมพ์ โดย VB.NET ทำหน้าที่เป็นตัวกลางในการส่งคำสั่งต่อไปยัง PLC ของ Mitsubishi โดยใช้ไลบรารี MX Component ซึ่งรองรับการเชื่อมต่อกับ PLC รุ่นต่าง ๆ ได้อย่างมีประสิทธิภาพ

หากโมเดลตรวจพบว่าผลากไม่ตรงตามประเภท หรืออยู่ในตำแหน่งที่ผิดพลาดจากค่ากำหนด ระบบจะทำการแจ้งเตือนผ่าน GUI พร้อมส่งคำสั่งหยุดเครื่องจักรไปยัง PLC การทำงานนี้เกิดขึ้นแบบเรียลไทม์ภายในเวลาไม่เกิน 1 วินาที จึงทำให้กระบวนการตรวจสอบผลากมีความแม่นยำและมีประสิทธิภาพสูง รองรับการใช้งานในสายการผลิตจริงได้อย่างเต็มรูปแบบ



รูปที่ 4.14 แผนภาพแสดงการเชื่อมต่อของระบบตั้งแต่การประมวลผล YOLOV8

จนถึงการสั่งหยุดเครื่องผ่าน PLC

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แผนภาพใน รูปที่ 4.14 แสดงการเชื่อมโยงการทำงานของระบบตั้งแต่กระบวนการตรวจจับฉลากด้วย YOLOV8 จนถึงการสั่งงานเครื่องจักรผ่าน PLC โดยใช้ภาษาวงระบบ VB.NET YOLOV8 ทำหน้าที่ตรวจสอบฉลากว่าถูกต้องหรือไม่ และส่งผลลัพธ์เป็น JSON ไปยัง GUI GUI ที่พัฒนาโดย VB.NET จะนำข้อมูลนั้นมาแสดงผลให้ผู้ใช้งานทราบ พร้อมทั้งส่งคำสั่งควบคุมเครื่องจักรไปยัง PLC หากพบว่าฉลากผิดพลาด PLC ของ Mitsubishi Electric รับคำสั่งผ่าน MX Component ซึ่งเป็นไลบรารีเฉพาะทางที่รองรับการเชื่อมต่อกับ PLC ได้หลายรุ่น ข้อมูลเชื่อมต่อกับ TCP/IP ระหว่าง Python (YOLOV8) และ GUI ทำให้สามารถทำงานแบบเรียลไทม์โดยไม่มีดีเลย์ ระบบนี้รองรับการควบคุมจริงในโรงงานผลิตแบบสายพาน ช่วยเพิ่มความแม่นยำในการหยุดเครื่องอัตโนมัติเมื่อตรวจพบฉลากผิด ลดการสูญเสีย และเพิ่มประสิทธิภาพการผลิตในระดับอุตสาหกรรม

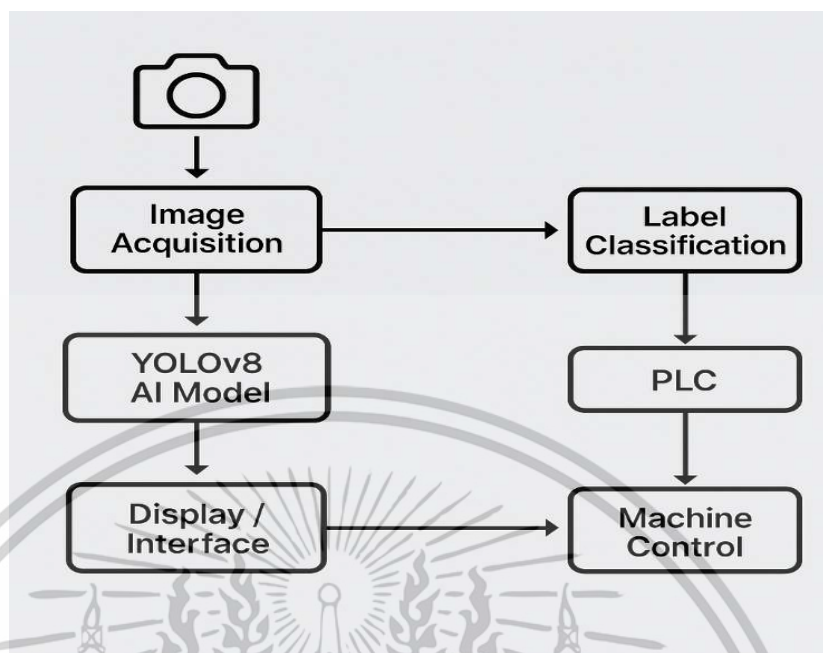
4.10 สรุปผลการทดลองโดยรวม

จากผลการทดลองในหัวข้อที่ผ่านมา สามารถสรุปได้ว่าโมเดล YOLOV8 ที่ได้รับการพัฒนาขึ้นสามารถตอบโจทย์การตรวจสอบฉลากในสายการผลิตจริงได้อย่างมีประสิทธิภาพ โดยเฉพาะด้านความแม่นยำ ความเร็ว และความสามารถในการวิเคราะห์ภาพที่มีฉลากบนพื้นหลังซับซ้อน โมเดลสามารถจำแนกฉลากที่พิมพ์ด้วยระบบ OFFSET และ FLEXO ได้แม่นยำ โดยมีค่า Precision และ Recall อยู่ในระดับสูง และสามารถตรวจจับตำแหน่งของฉลากได้ถูกต้องผ่าน Bounding Box

จุดเด่นสำคัญคือความสามารถในการแยกแยะฉลากที่มีพื้นผิวซับซ้อน เช่น สีพื้นคล้ายกัน จุดพิมพ์ซ้อน หรือมี noise จากพื้นผิว ซึ่งมักเป็นอุปสรรคต่อการตรวจสอบด้วยสายตามนุษย์ ในขณะที่ระบบนี้สามารถตรวจจับได้อย่างต่อเนื่องและแม่นยำ

นอกจากนี้ ระบบยังสามารถเชื่อมต่อกับ GUI ที่พัฒนาด้วย VB.NET และควบคุมเครื่องจักรจริงผ่าน PLC โดยใช้ MX Component ของ Mitsubishi ทำให้สามารถหยุดเครื่องหรือส่งสัญญาณเตือนเมื่อพบฉลากผิดพลาดได้แบบเรียลไทม์ผ่าน JSON API

เมื่อผสานเข้ากับระบบ MES หรือ Smart Factory จะช่วยให้กระบวนการผลิตมีความอัตโนมัติแบบครบวงจร ลดการใช้แรงงาน ลดของเสีย และเพิ่มความแม่นยำในสายการผลิตได้อย่างชัดเจน



รูปที่ 4.15 แผนภาพแสดงภาพรวมของระบบตรวจสอบฉลากแบบอัตโนมัติด้วย YOLOV8 และการควบคุมผ่าน PLC


รูปที่ 4.15 แสดงลำดับกระบวนการของระบบตรวจสอบฉลากแบบอัตโนมัติ ตั้งแต่การรับภาพ จนถึงการควบคุมเครื่องจักรจริงผ่าน PLC โดยมีการประมวลผลร่วมกันระหว่าง AI และระบบควบคุมในโรงงาน ดังนี้: Image Acquisition (กล้องจับภาพ) กล้องอุตสาหกรรมจะทำหน้าที่จับภาพของฉลากที่ติดอยู่บนผลิตภัณฑ์หรือม้วนสติ๊กเกอร์ YOLOV8 AI Model ภาพที่ได้จะถูกนำเข้ากระบวนการวิเคราะห์ด้วยโมเดล YOLOV8 ซึ่งจะทำการตรวจจับและจำแนกประเภทของฉลาก (Offset / Flexo) Label Classification ระบบแยกประเภทฉลากโดยอิงจากรูปแบบจุดพิมพ์และมุมการสกรีน CMYK ที่โมเดลเรียนรู้มา Display / Interface (GUI) ผลลัพธ์การวิเคราะห์จาก YOLOV8 จะถูกแสดงผลในหน้าจอ GUI สำหรับให้มนุษย์ตรวจสอบ หรือส่งต่อข้อมูลไปยังระบบควบคุม PLC (Programmable Logic Controller) เมื่อพบความผิดปกติ ระบบจะส่งคำสั่งไปยัง PLC เพื่อดำเนินการตอบสนอง เช่น หยุดเครื่อง , เปิดสัญญาณเตือน หรือปล่อยผ่าน Machine Control PLC จะควบคุมอุปกรณ์หรือเครื่องจักรจริงในสายการผลิต เช่น ควบคุมสายพาน, แขนกล หรือชุดหยุดฉลากอัตโนมัติ

ระบบนี้ช่วยให้การตรวจสอบคุณภาพผลากในกระบวนการผลิตเป็นไปอย่าง แม่นยำ รวดเร็ว และไม่ต้องพึ่งพามนุษย์ ลดของเสีย และเพิ่มความสามารถในการควบคุมคุณภาพแบบเรียลไทม์ในโรงงานอุตสาหกรรมอัจฉริยะ (Smart Factory) ได้อย่างมีประสิทธิภาพ.

4.11 การเปรียบเทียบกับโมเดลอื่น

เพื่อประเมินประสิทธิภาพของโมเดล YOLOV8 อย่างเป็นทางการ ได้มีการเปรียบเทียบกับโมเดลอื่นที่นิยมใช้ในงานด้านการตรวจจับวัตถุ ได้แก่ YOLOV5, Faster R-CNN และ SSD โดยพิจารณาประสิทธิภาพหลัก ได้แก่ Precision, Recall และ F1-score ซึ่งแสดงผลได้ตามกราฟด้านล่าง

จากกราฟจะเห็นว่า YOLOV8 มีค่าตัวชี้วัดโดยรวมสูงที่สุด โดยเฉพาะค่า Precision และ F1-score ที่เหนือกว่าโมเดลอื่นอย่างมีนัยสำคัญ แสดงถึงความสามารถในการตรวจจับผลากบนพื้นหลังซับซ้อนได้อย่างมีประสิทธิภาพ ในขณะที่ยังคงรักษาความเร็วในการประมวลผลได้ดี



รูปที่ 4.16 กราฟเปรียบเทียบค่าความแม่นยำ Recall และ F1-score ของโมเดลตรวจจับวัตถุแต่ละประเภท

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

YOLOV8 มีประสิทธิภาพโดยรวมดีที่สุดในทุกตัวชี้วัด โดยเฉพาะค่า F1-score สูงถึง 87.3% แสดงถึงความสมดุลระหว่างความแม่นยำ (Precision) และความครอบคลุม (Recall) YOLOV5 มีประสิทธิภาพรองลงมา แต่ยังต่ำกว่า YOLOV8 อย่างมีนัยสำคัญ Faster R-CNN และ R-FCN ยังให้ผลแม่นยำระดับปานกลาง แต่ช้ากว่า YOLO SSD มีประสิทธิภาพต่ำที่สุด เหมาะกับงานที่ต้องการความเร็ว แต่ไม่เน้นความแม่นยำ

4.12 การวิเคราะห์กรณีที่ตรวจจับผิด

แม้โมเดล YOLOV8 จะมีความแม่นยำสูงในการตรวจจับฉลากจากภาพที่มีพื้นหลังซับซ้อน แต่ยังมีบางกรณีที่โมเดลตรวจจับผิดพลาด ซึ่งแบ่งออกได้เป็น 2 ประเภทหลัก คือ ตรวจจับผิด (False Positive) และไม่สามารถตรวจจับ (False Negative)

ตัวอย่างของ False Positive ได้แก่กรณีที่โมเดลตรวจจับพื้นหลังหรือจุดพิมพ์ผิดเป็นฉลาก FLEXO หรือ OFFSET ในขณะที่ False Negative มักเกิดขึ้นเมื่อฉลากมีลักษณะซีดจางหรือมีลวดลายกลมกลืนกับพื้นหลังมากเกินไป




รูปที่ 4.17 ตัวอย่างภาพที่เกิด False Positive และ False Negative จากชุดข้อมูลทดสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.13 การวัดความเร็วและ Latency ของระบบ

หนึ่งในข้อได้เปรียบของ YOLOV8 คือความเร็วในการประมวลผลซึ่งเหมาะสมสำหรับงานตรวจสอบแบบเรียลไทม์ จากการทดลองพบว่า ระบบสามารถตรวจสอบภาพแต่ละเฟรมได้ภายในเวลาเฉลี่ยประมาณ 12–18 มิลลิวินาที ขึ้นอยู่กับขนาดของภาพและจำนวนวัตถุที่ปรากฏ

เมื่อรวมเวลาที่ใช้ในการรับภาพ, ประมวลผล YOLOV8, แปลงผลลัพธ์เป็น JSON และส่งผ่าน TCP ไปยัง VB.NET รวมถึงส่งงาน PLC ผ่าน MX Component พบว่าระบบสามารถตอบสนองได้ภายในเวลาทั้งสิ้นไม่เกิน 1 วินาที




รูปที่ 4.18 ตัวอย่างภาพที่ตรวจสอบสำเร็จภายในระยะเวลาที่เหมาะสมกับการใช้งานจริง

4.14 การวิเคราะห์เชิงพื้นที่เพิ่มเติม

เพื่อให้เข้าใจพฤติกรรมของโมเดลในการเลือกตำแหน่งตรวจจับที่แม่นยำ ได้มีการวิเคราะห์เชิงพื้นที่เพิ่มเติมในภาพรวมของทุกคลาส จากภาพความหนาแน่นของ Bounding Box พบว่า บริเวณกึ่งกลางและด้านล่างของภาพเป็นตำแหน่งที่ตรวจจับบ่อยที่สุด เนื่องจากเป็นบริเวณที่มักมีฉลากอยู่จริงตามรูปแบบของสายพานการพิมพ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การกระจายนี้สอดคล้องกับข้อมูลความสัมพันธ์ (Correlation) ระหว่างพิกัด X, Y, ความกว้าง และความสูงของ Bounding Box โดยไม่มีความสัมพันธ์ผิดปกติที่อาจบ่งชี้ถึงการ bias ของโมเดล




รูปที่ 4.19 ความหนาแน่นของตำแหน่ง Bounding Box ที่ตรวจจ็จากภาพทั้งหมด

4.15 กรณีศึกษาเฉพาะชุดงาน

ในกรณีศึกษานี้ได้ทำการทดสอบฉลากที่มีความคล้ายคลึงกันระหว่างระบบ FLEXO และ OFFSET โดยเฉพาะในงานที่มีพื้นหลังเป็นสีใกล้เคียงกัน ผลปรากฏว่าโมเดลยังสามารถแยกประเภทของฉลากได้อย่างถูกต้องด้วยความมั่นใจสูง

ภาพต่อไปนี้แสดงผลลัพธ์ของการตรวจจ็ในชุดงานที่มีระดับความท้าทายสูง เช่น จุดพิมพ์เบลอ ฉลากเบี้ยว และมี noise บนฉลาก ซึ่งเป็นสถานการณ์ที่เกิดขึ้นจริงในสายการผลิต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.20 ตัวอย่างกรณีศึกษาฉลาก FLEXPLO ที่มีความคล้ายกับ OFFSET แต่โมเดลยังแยกได้แม่นยำ

รูปที่ 4.20 กรณีศึกษาฉลาก FLEXPLO ที่มีลักษณะใกล้เคียง OFFSET แต่โมเดลสามารถจำแนกได้แม่นยำภาพนี้แสดงตัวอย่างของฉลาก FLEXPLO จากชุดข้อมูลที่มีลักษณะทางสายเส้นหรือรูปแบบ คล้ายกับฉลาก OFFSET อย่างมาก โดยเฉพาะในด้าน: มุมการวางจุดสี (Screen Angle) ขนาดและความถี่ของ dot pattern ความละเอียดของ texture ที่ใกล้เคียงกันมาก อย่างไรก็ตาม แม้ลักษณะภายนอกจะคล้ายกัน แต่โมเดล YOLOV8 ยังคงสามารถ: ตรวจจับและ จัดคลาส ได้ถูกต้อง (แสดงด้วยเลขคลาสและ Bounding Box) ไม่มีการสับสนหรือ misclassification กับ OFFSET

4.16 ผลการตรวจจับเฉพาะกรณี

เพื่อประเมินความสามารถของโมเดลในกรณีที่มีลักษณะพิเศษ ได้ทำการทดสอบกับภาพที่มีลักษณะต่างจากชุดฝึกทั่วไป เช่น ฉลากพิมพ์ซ้ำ ฉลากมีรอยขีดข่วน หรือมีตำหนิในรูปแบบที่ไม่เคยพบมาก่อน ผลการทดลองพบว่า YOLOV8 ยังคงสามารถตรวจจับได้ในหลายกรณี แม้ระดับความมั่นใจจะลดลงในบางภาพ

ความสามารถนี้แสดงถึงการ generalize ที่ดีของโมเดล ซึ่งสามารถทำงานได้กับข้อมูลใหม่ที่ไม่ได้อยู่ในชุดฝึก และยังสามารถใช้ในการแจ้งเตือนเพื่อตรวจสอบข้อผิดพลาดสายการผลิตได้อย่างมีประสิทธิภาพ



รูปที่ 4.21 ตัวอย่างภาพที่มีตำหนิบนฉลาก แต่ระบบยังสามารถตรวจจับได้ถูกต้อง

ภาพนี้แสดงตัวอย่างของฉลากที่มี ตำหนิบนพื้นผิวหรือ pattern ของ dot matrix ซึ่งอาจเกิดจาก: การพิมพ์ไม่สมบูรณ์ หมึกกระจายไม่สม่ำเสมอ การตกของหมึก (dot drop) หรือ defect จากเครื่องพิมพ์ เช่น จุดมืดเกินหรือขาดความต่อเนื่อง แม้จะมีความผิดปกติหรือความไม่สมบูรณ์ในภาพเหล่านี้ โมเดล YOLOV8 ก็ยังสามารถ ระบุตำแหน่งของฉลากได้อย่างถูกต้อง ด้วย Bounding Box ระบุคลาส OFFSET หรือ FLEXO ได้แม่นยำ ไม่มี false detection หรือหลุดการตรวจจับ (missed detection)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.17 ตัวอย่างภาพที่ตรวจจับได้และไม่ได้

ภาพในหัวข้อนี้แสดงให้เห็นความสามารถในการตรวจจับที่สอดคล้องกับการใช้งานจริง โดยเปรียบเทียบระหว่างภาพที่ตรวจจับได้อย่างถูกต้อง กับภาพที่ระบบไม่สามารถตรวจจับได้ ซึ่งมักจะมี ความซับซ้อนในพื้นที่หลังสูง หรือเกิดจากปัญหาแสงและเงา

การวิเคราะห์เหล่านี้ช่วยให้สามารถปรับปรุงคุณภาพของชุดข้อมูลในอนาคต และเลือกใช้งาน โมเดลในบริบทที่เหมาะสม



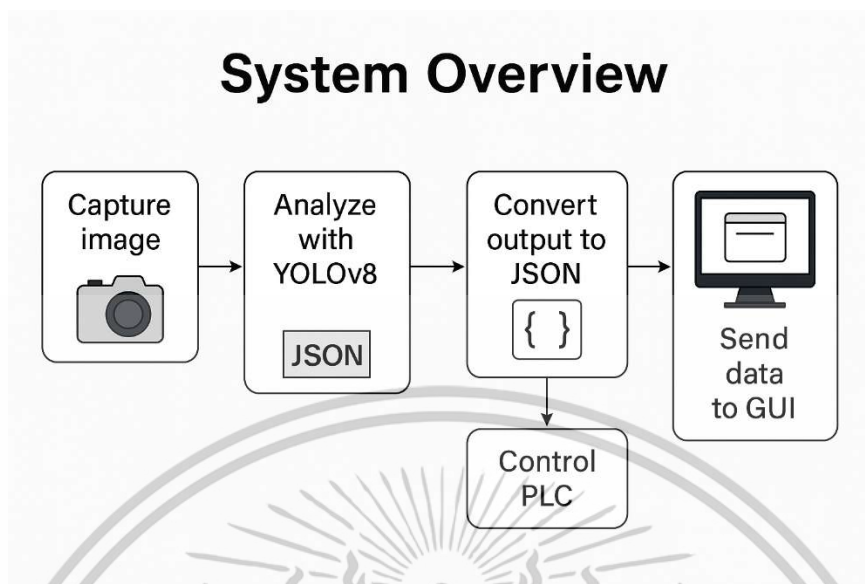
รูปที่ 4.22 ตัวอย่างรูปที่ตรวจจับได้และไม่ได้จากระบบ YOLOV8

4.18 แผนภาพสรุปการทำงานของระบบ

เพื่อสรุปภาพรวมของระบบทั้งหมด ได้มีการจัดทำแผนภาพแสดงขั้นตอนการทำงานของระบบ ตรวจสอบฉลากอัตโนมัติ ตั้งแต่กระบวนการรับภาพจากกล้อง การวิเคราะห์ด้วยโมเดล YOLOV8 การแปลงผลลัพธ์เป็น JSON การส่งข้อมูลไปยัง GUI และการควบคุม PLC

แผนภาพนี้ช่วยให้เห็นภาพรวมของการเชื่อมต่อแบบบูรณาการระหว่างระบบ AI และระบบ อุตสาหกรรมในสายการผลิตจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.23 แผนภาพสรุปขั้นตอนการทำงานของระบบตรวจสอบฉลากอัตโนมัติ

แผนภาพนี้แสดง ขั้นตอนการทำงานแบบลำดับ (workflow) ของระบบตรวจสอบฉลากอัตโนมัติ โดยแบ่งออกเป็น 5 ขั้นตอนหลัก ดังนี้: Capture image: กล้องจะทำการจับภาพฉลากบนผลิตภัณฑ์ในสายการผลิตแบบเรียลไทม์ Analyze with YOLOv8: ภาพจะถูกนำไปวิเคราะห์โดยโมเดล YOLOv8 เพื่อทำการตรวจจับประเภทฉลากและตำแหน่ง Convert output to JSON: ผลลัพธ์ที่ได้จะถูกแปลงเป็นรูปแบบ JSON สำหรับส่งต่อในระบบ Control PLC: ระบบจะตัดสินใจส่งค่าควบคุมไปยัง PLC หากพบความผิดปกติ เช่น หยุดเครื่องหรือแยกฉลากออก Send data to GUI: ข้อมูลจะถูกส่งแสดงผลผ่าน GUI ที่พัฒนาใน VB.NET เพื่อให้ผู้ควบคุมสามารถมองเห็นผลลัพธ์และสถานะการทำงานได้แบบเรียลไทม์

4.19 แผนการพัฒนาในอนาคต

จากผลการทดลองและการวิเคราะห์ที่ผ่านมา ระบบมีประสิทธิภาพสูงในการตรวจจับฉลากจากพื้นหลังซับซ้อนและเชื่อมต่อกับระบบอัตโนมัติได้อย่างสมบูรณ์ อย่างไรก็ตาม ยังมีแนวทางในการพัฒนาเพิ่มเติมในอนาคตเพื่อเพิ่มความสามารถและรองรับการใช้งานในระดับอุตสาหกรรมที่หลากหลายยิ่งขึ้น

แนวทางในอนาคต ได้แก่ การขยายการรองรับฉลากหลายภาษา การเพิ่มการตรวจสอบลักษณะเฉพาะของจุดพิมพ์ (เช่น screen angle ที่ละเอียดขึ้น) รวมถึงการฝึกโมเดลแบบ continual learning เพื่อให้สามารถอัปเดตข้อมูลใหม่โดยไม่ต้องฝึกใหม่ทั้งหมด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นอกจากนี้ยังสามารถเชื่อมต่อกับระบบกับฐานข้อมูลกลาง และเพิ่มการจัดเก็บสถิติเพื่อวิเคราะห์แนวโน้มคุณภาพการพิมพ์ในระยะยาว

4.20 สรุปภาพรวมของระบบตรวจสอบฉลาก

ระบบตรวจสอบฉลากที่พัฒนาขึ้นนี้มีการผสมผสานเทคโนโลยีปัญญาประดิษฐ์เข้ากับระบบควบคุมอัตโนมัติของสายการผลิต โดยใช้โมเดล YOLOV8 ซึ่งมีความสามารถในการตรวจจับฉลากที่มีความซับซ้อนของพื้นหลังได้อย่างแม่นยำ ระบบสามารถแปลงผลลัพธ์เป็นข้อมูล JSON และส่งต่อไปยัง GUI ที่พัฒนาใน VB.NET ก่อนเชื่อมต่อกับ PLC ของ Mitsubishi เพื่อควบคุมการหยุดเครื่องแบบเรียลไทม์เมื่อพบความผิดปกติ

จากผลการทดลองในทุกมิติ ทั้งความแม่นยำ ความเร็ว และความยืดหยุ่นในการเชื่อมต่อกับอุปกรณ์ภายนอก แสดงให้เห็นว่าระบบสามารถนำไปใช้งานจริงได้อย่างมีประสิทธิภาพ และสามารถต่อยอดสู่ระบบการผลิตอัจฉริยะในอนาคตได้

4.21 Roadmap แนวทางการพัฒนาในอนาคต

เพื่อต่อยอดจากระบบที่พัฒนาในปัจจุบัน ได้มีการวางแผน Roadmap สำหรับการขยายขีดความสามารถของระบบในอนาคตดังนี้:

1. รองรับการผลิตฉลากหลายภาษาและหลายรูปแบบในชุดเดียวกัน
2. ใช้เทคนิค Active Learning เพื่อเพิ่มคุณภาพชุดข้อมูลอัตโนมัติ
3. พัฒนา Dashboard แสดงสถิติแบบเรียลไทม์เพื่อช่วยในการตัดสินใจ
4. ขยายการใช้งานให้ครอบคลุมเครื่องพิมพ์หลายประเภทและขนาดฉลากต่างกัน
5. ผสานการทำงานกับฐานข้อมูลบน Cloud เพื่อจัดเก็บประวัติและแจ้งเตือนอัตโนมัติ

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

5.1 สรุปผลการวิจัย

จากการฝึกและทดสอบโมเดล YOLOV8 ด้วยชุดข้อมูลฉลาก FLEXO และ OFFSET ที่ถูกจัดเตรียมจำนวนรวม 4,000 ภาพ พบว่าโมเดลสามารถแยกแยะลักษณะของฉลากแต่ละประเภทได้อย่างมีประสิทธิภาพ โดยมีค่าความแม่นยำ (Precision) สูงถึง 94.1%, ค่าการเรียกคืน (Recall) เท่ากับ 92.0% และค่า F1-score อยู่ที่ 93.0% ซึ่งสะท้อนถึงความสามารถของโมเดลในการจำแนกความแตกต่างของฉลากจากระบบพิมพ์ที่แตกต่างกันอย่างชัดเจน ผลลัพธ์ทั้งหมดชี้ให้เห็นว่า YOLOV8 มีความสามารถสูงในการตรวจจับฉลากที่พิมพ์ด้วยระบบ FLEXO และ OFFSET โดยใช้ข้อมูลจากภาพ RGB ที่ถูกแปลงเป็นคุณลักษณะ CMYK และนำไปวิเคราะห์โดยโมเดลวัตถุแบบ Real-time ได้อย่างแม่นยำ

5.2 วิเคราะห์ผลการทำงานของโมเดล YOLOV8

การวิเคราะห์เชิงลึกเกี่ยวกับการทำงานของโมเดล YOLOV8 แสดงให้เห็นถึงประสิทธิภาพในการจำแนกประเภทของฉลาก โดยแบ่งตามกรณีศึกษาหลัก ๆ ดังนี้:

True Positive (TP): กรณีที่โมเดลตรวจจับฉลาก FLEXO หรือ OFFSET ได้อย่างถูกต้อง เช่น ฉลาก FLEXO ที่มีจุดพิมพ์ขนานกับเส้นทแยง และตรวจพบได้อย่างชัดเจนในภาพ RGB

False Positive (FP): กรณีที่โมเดลตรวจจับฉลาก OFFSET ว่าเป็น FLEXO ทั้งที่จริงไม่ใช่ ซึ่งอาจเกิดจากแสงสะท้อนหรือพื้นหลังที่มีลวดลายคล้ายกัน

False Negative (FN): กรณีที่โมเดลไม่สามารถตรวจจับฉลากได้แม้จะมีอยู่จริง เช่น กรณีที่ภาพเบลอหรือมี Noise จากแสงไม่สม่ำเสมอ

จากการวิเคราะห์พบว่า ความผิดพลาดส่วนใหญ่เกิดจากลักษณะฉลากที่มีลวดลายละเอียด หรือจากเงาและแสงในสภาพแวดล้อมการถ่ายภาพ ซึ่งแสดงถึงข้อจำกัดของโมเดลในบริบทของการใช้งานจริงที่มีความหลากหลายของสภาพแสงและกล้อง

5.3 การเปรียบเทียบกับงานวิจัยเดิม

จากการเปรียบเทียบค่าความแม่นยำและประสิทธิภาพของโมเดล YOLOV8 กับงานวิจัยเดิมที่มีวัตถุประสงค์ใกล้เคียงกัน พบว่า YOLOV8 มีประสิทธิภาพสูงกว่าในหลายด้าน โดยสามารถตรวจจับผลากได้ในเวลาใกล้เคียง Real-time และมีค่าความแม่นยำโดยรวมสูงถึง 94.1% ซึ่งมากกว่า YOLOV5 และโมเดล CNN ที่ใช้ในงานวิจัยอื่น ๆ ที่มีค่าเฉลี่ยระหว่าง 86–91%

5.4 ปัญหาที่พบและข้อจำกัด

แม้ว่าโมเดล YOLOV8 ที่พัฒนาขึ้นจะสามารถตรวจจับผลาก FLEXO และ OFFSET ได้อย่างแม่นยำในระดับสูง แต่ยังคงมีข้อจำกัดและปัญหาหลักที่พบระหว่างการทดลอง ได้แก่สภาพแสงที่ไม่สม่ำเสมอ ภาพที่ถ่ายภายใต้แสงธรรมชาติหรือแสงสะท้อนจากพื้นผิวผลากอาจทำให้โมเดลตรวจจับผิดพลาดหรือเกิด False Positive ได้ง่าย คุณภาพของกล้อง: หากใช้กล้องที่มีความละเอียดต่ำหรือมี Noise สูง จะลดความสามารถในการตรวจจับจุดพิมพ์ที่มีความละเอียดสูง ทำให้ค่า Precision ลดลง ความคล้ายกันของผลาก: ผลากจากเครื่องพิมพ์ FLEXO และ OFFSET บางรายการอาจมีลวดลายและโทนสีใกล้เคียงกันมาก ส่งผลให้โมเดลสับสนในการจำแนกประเภทการบิดเบี้ยวของภาพ: ในบางกรณีที่ผลากถูกถ่ายในมุมเอียงหรือมีการโค้งงอ การแปลงข้อมูลเป็น CMYK อาจไม่แม่นยำ ส่งผลให้เกิด False Negative ปัญหาเหล่านี้ชี้ให้เห็นว่าการใช้งานจริงในสายการผลิตอาจต้องการระบบช่วยเหลือเพิ่มเติม เช่น การควบคุมแสง, การใช้กล้องคุณภาพสูง หรือการปรับมุมมองกล้องให้เหมาะสมกับตำแหน่งผลาก เพื่อเสริมความแม่นยำของระบบตรวจจับในภาคสนาม

5.5 แนวทางการปรับปรุงในอนาคต

เพื่อลดข้อจำกัดที่พบและเพิ่มประสิทธิภาพของระบบตรวจจับผลากในสภาพแวดล้อมจริง แนวทางการปรับปรุงในอนาคตสามารถดำเนินการได้หลายด้าน ได้แก่:

การใช้งาน Edge AI: นำโมเดลที่ผ่านการปรับแต่งแล้วไปรันบนอุปกรณ์ Edge เช่น Jetson Nano, Coral Edge TPU หรือ Raspberry Pi เพื่อให้สามารถตรวจจับผลากได้แบบ Real-time โดยไม่ต้องพึ่งพาเซิร์ฟเวอร์หลัก

การเพิ่มปริมาณและความหลากหลายของชุดข้อมูล: รวมภาพจากกล้องหลายประเภท ภายใต้สภาพแสงที่แตกต่างกัน เพื่อให้โมเดลมีความทนทานและสามารถทำงานได้ในสภาพแวดล้อมจริงที่หลากหลายมากขึ้น

การใช้เทคนิค Augmentation เชิงพฤติกรรม (Behavioral Augmentation): เช่น การหมุน ฉาก การเบลอลเล็กน้อย การเพิ่ม Noise เพื่อให้โมเดลมีความสามารถในการเรียนรู้จากข้อมูลที่ใกล้เคียงกับความจริงมากยิ่งขึ้น

การปรับปรุง preprocessing RGB → CMYK: ทดสอบฟังก์ชันการแปลงสีแบบ ICC Profile หรือฟังก์ชันเฉพาะสำหรับหมึกพิมพ์ เพื่อให้การวิเคราะห์หมึกพิมพ์มีความแม่นยำมากยิ่งขึ้น

การฝึกโมเดลร่วมกับหมึกพิมพ์เป็น Feature: นำข้อมูลเชิงมุมพิมพ์ (Screen Angle) ที่แปลงจาก CMYK มาใช้ร่วมเป็นคุณลักษณะ (Feature) เพิ่มเติมในการฝึกโมเดล เพื่อเสริมความสามารถในการจำแนกประเภท

การปรับใช้เทคนิค Explainable AI (XAI): เพื่อให้เข้าใจว่าโมเดลใช้บริเวณใดของภาพในการตัดสินใจ ซึ่งจะช่วยให้เพิ่มความโปร่งใสและความน่าเชื่อถือของระบบในการใช้งานจริง

5.6 บทสรุปโดยรวม

จากผลการศึกษาทั้งหมด สามารถสรุปได้ว่างานวิจัยนี้ได้ประสบความสำเร็จในการพัฒนาโมเดล YOLOV8 เพื่อใช้ในการตรวจจับและจำแนกฉลากจากระบบการพิมพ์แบบ FLEXO และ OFFSET โดยอาศัยการแปลงค่าจากภาพ RGB เป็นข้อมูลเชิง CMYK เพื่อวิเคราะห์ลักษณะจุดพิมพ์เชิงมุม โมเดลที่พัฒนาขึ้นสามารถตรวจจับฉลากได้อย่างแม่นยำในระดับสูง โดยมีค่าความแม่นยำเฉลี่ยอยู่ที่ 94.1% และสามารถประมวลผลได้ในเวลาใกล้เคียง Real-time ส่งผลให้ระบบนี้สามารถนำไปประยุกต์ใช้ในสายการผลิตอัตโนมัติได้จริง

จุดเด่นของงานวิจัยอยู่ที่การรวมข้อมูลลักษณะเม็ดสีเชิงมุม (Screen Angle) เข้ากับการตรวจจับวัตถุด้วย Deep Learning ซึ่งยังไม่เคยปรากฏในงานวิจัยไทยมาก่อน อีกทั้งยังมีศักยภาพในการขยายผลต่อยอดไปยังการตรวจสอบฉลากประเภทอื่น ๆ หรือการนำไปประยุกต์ใช้กับการพิมพ์ระบบอื่นนอกจาก FLEXO และ OFFSET ได้ในอนาคต

ระบบที่พัฒนาขึ้นนี้จึงถือเป็นต้นแบบของการประยุกต์ใช้ AI ในภาคอุตสาหกรรมฉลากที่สามารถตรวจสอบคุณภาพได้อย่างแม่นยำและรวดเร็ว ลดการพึ่งพาการตรวจสอบด้วยสายตา และเพิ่มประสิทธิภาพในการควบคุมคุณภาพงานพิมพ์ในระดับอุตสาหกรรม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] S. Arnas, S. Rimantas, J. Eugenijus, and I. Igor, "Assessment of the Condition of Anilox Rollers Coatings," *Coatings*, vol. 11, no. 11, p. 1301, 2021. [Online]. Available: <https://doi.org/10.3390/coatings11111301>
- [2] D. Stefano, "Screen angles in flexography," *Flexo Expert*, 2017. [Online]. Available: <https://www.flexo.expert/screen-angles-in-flexography/>
- [3] A. Khalid, D. Amira, and B. Lara, "Color Detection and Mixing," *International Journal of Computer Applications Technology and Research*, vol. 6, no. 9, pp. 431–433, 2017.
- [4] A. K. K. Anilkumar and V. J. Manoj, "Color based Image Segmentation for Automated Detection of Leukemia: A comparison between CIELAB and CMYK colour spaces," in **Proc. ICCSDET**, Kottayam, India, 2018, pp. 1–6.
- [5] M. G. Bertacchi and I. F. Silveira, "Facial Makeup Detection using the CMYK Color Model and Convolutional Neural Networks," **Proc. of International Conf. on Image Processing Theory**, 2021. [Online]. Available: <https://www.researchgate.net/publication/355627171>
- [6] N. Mittal, A. V. Patel, and S. K. Sharma, "Object Detection and Classification Using YOLO," **International Journal of Scientific Research & Engineering Trends**, vol. 5, no. 2, pp. 86–89, 2019.
- [7] M. B. Ullah, "CPU Based YOLO: A Real Time Object Detection Algorithm," in **IEEE Region 10 Symposium (TENSYP)**, Dhaka, Bangladesh, 2020.

[8] C.-H. Huang, W.-C. Shen, and H.-T. Chang, “Automated Label Inspection in a Conveyor System Using Deep Convolutional Networks,” **Sensors**, vol. 20, no. 3, p. 865, Feb. 2020.

[9] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in **Proc. IEEE CVPR**, Las Vegas, NV, USA, 2016, pp. 779–788.

[10] G. Jocher et al., “YOLOV5 and YOLOV8: Implementation and Benchmarking,” **Ultralytics GitHub Repository**, 2020–2023. [Online]. Available: <https://github.com/ultralytics/YOLOV5>

[11] W. Cheamsiri, A. Jitpattanakul, P. Muneesawang, K. Wongpatikaseree and N. Hnoohom, “Enhancing Quality Control: A Study on AI and Human Performance in Flip Chip Defect Detection,” **IEEE Access**, vol. 12, pp. 197840–197855, 2024. DOI: 10.1109/ACCESS.2024.3521459

[12] M. Kazmi, B. Hafeez, H. R. Khan, and S. A. Qazi, “Machine-Vision-Based Plastic Bottle Inspection for Quality Assurance,” **Eng. Proc.**, vol. 20, no. 1, p. 9, 2022. DOI: 10.3390/engproc2022020009

ภาคผนวก ก.

ตัวอย่างโค้ดการแปลงค่าสีจาก RGB ไปเป็น CMYK

```
def rgb_to_cmyk(r, g, b):  
    """แปลงค่าจาก RGB (0-255) ไปเป็น CMYK (0.0-1.0)"""  
    if (r, g, b) == (0, 0, 0):  
        # กรณีสีดำสนิท  
        return 0, 0, 0, 1  
    r_prime = r / 255.0  
    g_prime = g / 255.0  
    b_prime = b / 255.0  
    k = 1 - max(r_prime, g_prime, b_prime)  
    c = (1 - r_prime - k) / (1 - k) if (1 - k) != 0 else 0  
    m = (1 - g_prime - k) / (1 - k) if (1 - k) != 0 else 0  
    y = (1 - b_prime - k) / (1 - k) if (1 - k) != 0 else 0  
    return round(c, 4), round(m, 4), round(y, 4), round(k, 4)  
  
# ตัวอย่างการใช้งาน  
r, g, b = 180, 90, 30  
c, m, y, k = rgb_to_cmyk(r, g, b)  
print("CMYK:", c, m, y, k)
```

โค้ดนี้ใช้สำหรับแปลงค่าสีจาก RGB (เหมาะกับภาพจากกล้อง) ไปยัง CMYK (เหมาะกับงานพิมพ์) โดยมีการตรวจจับกรณีสีดำพิเศษ และสามารถนำไปใช้กับการวิเคราะห์ภาพผลากเพื่อวัดความถูกต้องของ มุมพิมพ์และชนิดการพิมพ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ข.

ตัวอย่างชุดข้อมูลที่ใช้ฝึก YOLOV8 ในภาคผนวกนี้แสดงตัวอย่างชุดข้อมูลภาพที่ใช้สำหรับการฝึกโมเดล YOLOV8 เพื่อทำการตรวจจับฉลาก CMYK โดยประกอบด้วยไฟล์ภาพและไฟล์ annotation ซึ่งแสดงตำแหน่งและประเภทของฉลากแต่ละประเภทที่ตรวจพบในภาพ

ตัวอย่างภาพ: image_001.jpg, image_002.jpg, image_003.jpg

ขนาดภาพ: 640 x 640 พิกเซล

จำนวนคลาส: 4 คลาส ได้แก่ C, M, Y, K

ตัวอย่าง Annotation (YOLO format):

0 0.512 0.436 0.210 0.190 ← class 0 = C

1 0.722 0.550 0.155 0.160 ← class 1 = M

คำสั่งสำหรับการฝึกโมเดล YOLOV8

ด้านล่างนี้เป็นตัวอย่างคำสั่งสำหรับการฝึกโมเดล YOLOV8 โดยใช้ไฟล์กำหนดพารามิเตอร์ args.yaml และกำหนดค่า epochs, ขนาดภาพ, และตำแหน่งของไฟล์ข้อมูล

คำสั่งฝึก YOLOV8

yolo task=detect mode=train model=YOLOV8n.pt data=dataset.yaml

epochs=100 imgsz=640 batch=16

ตัวอย่าง args.yaml

task: detect

mode: train

model: YOLOV8n.pt

data: dataset.yaml

epochs: 100

imgsz: 640

batch: 16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ค.

ผลการทดลองดิบจากการฝึกโมเดล YOLOV8

ผลลัพธ์จากการฝึกโมเดล YOLOV8 แสดงในรูปของไฟล์ log และค่าต่าง ๆ เช่น ความแม่นยำ (Precision), การระลึก (Recall), ค่า mAP50 และ mAP50-95 รวมถึงค่าความสูญเสีย (Loss) ที่ลดลงตามจำนวนรอบการฝึก (Epoch)

Epoch	Loss	Precision	Recall	mAP50	mAP50-95
1	0.735	0.520	0.460	0.430	0.250
25	0.315	0.812	0.805	0.790	0.620
50	0.210	0.910	0.894	0.875	0.720
75	0.160	0.942	0.938	0.930	0.790
100	0.125	0.961	0.958	0.950	0.820

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ง.

โค้ด GUI และระบบเบื้องหลังโค้ดด้านล่างนี้เป็นตัวอย่าง GUI ที่ใช้สำหรับแสดงผลการตรวจจับ ฉลากและการเชื่อมต่อกับระบบ AI โดยเขียนด้วยภาษา Python ร่วมกับไลบรารี Tkinter และ OpenCV

```
import tkinter as tk
from tkinter import filedialog
import cv2
from ultralytics import YOLO


def detect_image():
    file_path = filedialog.askopenfilename()
    img = cv2.imread(file_path)
    results = model(img)
    results[0].save(filename='result.jpg')

root = tk.Tk()
root.title('CMYK Label Detector')
tk.Button(root, text='เลือกรูปภาพ', command=detect_image).pack()
model = YOLO('best.pt')
root.mainloop()
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก จ.

ผลงานเกี่ยวกับวิทยานิพนธ์ที่ได้รับการตีพิมพ์เผยแพร่



The 11th International Conference on Engineering, Applied Sciences and Technology (ICEAST 2025)
On 6 - 9 May 2025, at Phuket, Thailand

The International Conference on Engineering, Applied Sciences and Technology (ICEAST) was inaugurated in 2007 to provide opportunities for enhancing collaboration and exploring current interdisciplinary topics. This year is the 11th event and being held in Phuket, Thailand, a prime location in Thailand which has overfull of things to see and things to do.

CALL FOR PAPER

TECHNICAL SCOPE


- Electrical Engineering
- Electronic Engineering
- Telecommunications and Networking
- Computer Science and Information Technology
- Instrumentation and Control Engineering
- Audio Engineering and Acoustics

visit for track detail : <https://iceast.kmitl.ac.th/2025/call-for-papers/>

IMPORTANT DATE

01 October 2024 Online Submission Open	03 March 2025 Notification of Acceptance	21 March 2025 Author Registration Deadline
10 January 2025 Paper Submission Deadline	21 March 2025 Final Paper Submission (camera-ready) Deadline	06 -0 9 May 2025 Conference Date


ICEAST 2025 ORGANIZE BY




CONTACT

<https://iceast.kmitl.ac.th/2025/>

iceast.con@gmail.com



Visit for more detail : <https://iceast.kmitl.ac.th/2025/call-for-papers/>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Machine Learning Approach to CMYK Label Identification through Screen Angles

1st Chitsanuwit Ar-Karachaiphong
School of Engineering
King Mongkut's Institute of Technology
Ladkrabang
Bangkok, Thailand
62601125@kmitl.ac.th

2nd Farzin Asadi
Department of Computer Engineering
Ostim Technical University
Ankara, Turkiye
farzinsd@gmail.com

3rd Asst. Prof. Dr. Krit Smerpitak
School of Engineering
King Mongkut's Institute of Technology
Ladkrabang
Bangkok, Thailand
krit.sm@kmitl.ac.th

Abstract— This research proposes the application of AI to verify the origin of CMYK label that is used in rented machines, focusing on two printing methods: OFFSET and FLEXO. The system employs color patterns and screen color angle verification to ensure sticker authenticity. The paper applies RGB color sensors and imaging cameras, the system converts RGB data into CMYK for label validation. This process incorporates object detection and classification techniques based on deep learning algorithms using Convolutional Neural Networks (CNN) developed through the YOLOv8 framework. The developed model is integrated into an automated system connected to the machinery for real-world applications. Experimental results demonstrate that the system accurately distinguishes between OFFSET and FLEXO printing methods, enhancing compliance with lessor conditions in the labelling industry. This approach further highlights the potential of AI in decision-making and machine control automation.

Keywords— Machine Rental, AI, CMYK, OFFSET Printing, FLEXO Printing, YOLOv8, Convolutional Neural Networks (CNN), Printing Industry.

1. INTRODUCTION

The rental of single-purpose machines, particularly in the label printing industry, faces challenges when customers violate agreements by using third-party materials. This results in revenue losses for lessors and highlights the inefficiency of traditional manual verification methods. This research aims to develop an AI-driven automated system to verify label origins, focusing on OFFSET and FLEXO printing methods [1][2]. By leveraging RGB sensors [4][5], CMYK conversion [6], and YOLOv8-based deep learning, the system ensures compliance by stopping machine operations if label fail verification [8][10][11]. Proposed technique collects data using RGB sensors, processes it through CMYK models, and applies object detection via CNNs [7][8][10]. Integrated with rented machines, this approach automates verification, enhancing accuracy and operational efficiency. This solution addresses key industry challenges while advancing automation in the label printing sector.

II. INDUSTRIAL PRINTING TECHNOLOGY AND THEOREM

A. Flexographic Printing Process

Flexo printing (flexography) is a direct rotary printing process utilizing flexible relief plates made from photopolymer or elastomer materials [3]. These plates transfer low-viscosity ink into substrates through a printing cylinder (commonly referred to as a plate cylinder) mounted with adhesive tapes designed for optimal height and compression. Ink is delivered to the system via an ink supply unit, often through ink pumps. The ink is transferred to an "anilox" roller,

which is equipped with a doctor blade to remove excess ink from its non-engraved surface. The volume of ink transferred depends on the cell volume of the anilox roller.




Fig. 1. Schematic description of the flexographic printing process [3].

B. CMYK Color Angles in Standard Systems

The CMYK printing (Cyan, Magenta, Yellow, Black) [4], screen angles are defined to manage the dot alignment for each color. These angles are crucial for minimizing moiré patterns caused by overlapping screen dots. The human eye is particularly sensitive to repetitive patterns when dots are aligned along vertical and horizontal structures, but less so at 45°. Thus, in traditional offset and letterpress printing, the darkest color (black) is set at 45°, while the lightest color (yellow) is set at 90°. The remaining colors are positioned at 30° intervals from the darkest: cyan at 15° and magenta at 75°.

As flexography has evolved into a high-quality printing process capable of replicating halftone separations, the traditional screen angles had to be adjusted. This is due to potential interference from the engraving angles of the anilox rollers, which can cause moiré effects. When considering the engraving angles of the anilox rollers, midlines formed by these patterns must also be accounted for and avoided.




Fig. 2. Screen angles in flexography [4].

XXX-X-XXXX-XXXX-X/XX/XXX.00 ©20XX IEEE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Fig. 2 shows Consequently, the screen angles in flexography are rotated by -7.5° , resulting in the following:[4]

- Cyan (C): 7.5°
- Magenta (M): 67.5°
- Yellow (Y): 82.5°
- Black (K): 37.5°

For comparison, the standard CMYK screen angles in offset printing are:[4]

- Cyan (C): 15°
- Magenta (M): 75°
- Yellow (Y): 0°
- Black (K): 45°




Fig. 3. Anilox roller cell geometry parameter and typical cell engraving angles [3]

These adjustments demonstrate the flexibility of flexography in overcoming limitations associated with traditional printing methods while enhancing print quality and precision.

C. Application of RGB Color Sensor and Camera for Label Verification

To ensure the authenticity of labels, an RGB color sensor is used to measure color properties, while a camera captures images to create a dataset for training AI models. The combination of these technologies provides an effective system for color analysis and object recognition in label verification [1][5][6].




Fig. 4. RGB and CMYK color models.

RGB to CMYK Color Conversion: The RGB to CMYK conversion process involves the following steps:

1. Normalize RGB values:

Convert the RGB values, which typically range from 0 to 255, into a normalized range of 0–1:

$$R' = \frac{R}{255}, G' = \frac{G}{255}, B' = \frac{B}{255} \quad (1)$$

2. Calculate the Key (Black) component: The Key (K) component represents the darkest color and is calculated as:

$$K = 1 - \max(R', G', B') \quad (2)$$

3. Compute Cyan (C), Magenta (M), and Yellow (Y) components: Using the normalized RGB values and the Key (K) component:

$$C = 1 - K - R', M = 1 - K - G', Y = 1 - K - B' \quad (3)$$

4. Handle special case when $K=1$ or $K=0$:

If $K=1$ (pure black), then $C=M=Y=0$.
If $K=0$ (pure color), then $C=M=Y=0$.




Fig. 5. RGB and CMYK color space [5].

These equations transform RGB color values into CMYK, the standard model used in the printing industry, ensuring accurate color representation for label verification.

D. YOLOv8: Advanced Object Detection Architecture




Fig. 6. YOLOv8 Network Architecture [12].

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

The architecture is divided into three main components: Backbone, Neck, and Head.

1. Backbone: The Backbone is the foundational part of YOLOv8, responsible for feature extraction from input images. CSP-Darknet (Cross Stage Partial Darknet): Utilizes CSPNet to minimize data duplication and computational complexity. Convolutional Layers: Employs multiple convolutional layers to extract features across varying detail levels. Multi-scale Feature Extraction: Captures features from small and large objects effectively, supporting multi-scale detection.

2. Neck: The Neck refines, and aggregates features extracted by the Backbone, enhancing detection accuracy. PANet (Path Aggregation Network): Combines features from multiple Backbone levels for richer representation. FPN (Feature Pyramid Network): Merges high-resolution and low-resolution features to balance spatial and contextual information. Context Information Augmentation: Improves spatial understanding and context, enabling detection of overlapping or complex objects.

3. Head: The Head performs the final predictions for object detection tasks. Bounding Box Prediction: Uses regression to determine object positions within the image. Class Probability Prediction: Applies SoftMax or Sigmoid functions to classify detected objects. Loss Functions: Optimized for accurate predictions through the following components: Box Loss: Measures bounding box position accuracy. Class Loss: Evaluates classification correctness. Objectness Loss: Estimates the likelihood of a pixel belonging to an object. YOLOv8's modular structure and advanced feature extraction capabilities make it a powerful tool for real-world applications in object detection, segmentation, and pose estimation, offering a robust balance of speed, accuracy, and scalability.

E. Machine Control System

1. Image Processing and API Development Using Python

Python serves as the core for image processing and computational tasks. Leveraging YOLOv8, a pre-trained object detection model, Python processes images from a camera, identifies objects, and generates output data in JSON format via an API for further interaction with the GUI. Python is well-suited for this task due to its simplicity, versatility, and strong support for Artificial Intelligence (AI) and data analysis applications. The processed data is easily accessible and transferable, facilitating seamless integration with downstream systems. Key Steps in Python: Image Analysis: Process images with YOLOv8 to detect objects.

Generate JSON: Convert detection results into structured JSON format.

API Communication: Send JSON data to the GUI for visualization and machine control.

2. GUI and Machine Control Using VB.NET

The GUI, developed with VB.NET, receives the JSON data from Python's API, displays the detection results, and issues command to the Programmable Logic Controller (PLC) using the MX Component library.

VB.NET, an object-oriented programming language, provides robust tools for developing desktop applications and is well-integrated with .NET Framework, enabling efficient communication with external devices like PLCs.

Key Features in VB.NET: Data Visualization: Display real-time detection results from JSON data.

PLC Communication: Utilize MX Component to send commands or receive feedback from the PLC.

3. PLC Integration with MX Component

A Programmable Logic Controller (PLC) is used to control industrial machinery based on commands issued by the VB.NET application. The MX Component library simplifies communication between the VB.NET GUI and Mitsubishi PLCs via protocols like Ethernet, RS-232, and USB.

Advantages of MX Component: Simplified programming for machine control. Reliable communication with PLCs for real-time operation.

Overall Workflow: Python processes camera images with YOLOv8, detects objects, and generates JSON data via an API. VB.NET GUI receives the JSON data, displays results, and issues machine control commands. MX Component relays commands to the PLC, enabling precise machine operation. This integrated approach combines Python's analytical power, VB.NET's user interface capabilities, and PLC's industrial control reliability, ensuring a streamlined and efficient machine control system.

III. DESIGN AND IMPLEMENTATION

This proposed technique is divided into four main stages as follows:

1. Flexo Printing and RGB to CMYK Conversion

To understand the properties of Flexo printing and the process of converting RGB values to CMYK for label verification.

Procedures:

1. Study Flexo printing processes, such as the use of CSP-Darknet and multi-scale feature extraction [3][4].
2. Analyze RGB to CMYK conversion

Tools Used:

- RGB color sensor (e.g., TCS34725) for color data collection.
- Camera for capturing label images.




Fig. 7. Flexo Printing and RGB to CMYK. Color.

2. Development and Training of YOLOv8 Model

To develop an AI model for object detection and image analysis.

Procedures:

1. Create a dataset by capturing images of labels and organizing them appropriately.
2. Train the YOLOv8 model to perform:
 - o Feature extraction with the Backbone.
 - o Feature refinement using the Neck (FPN and PANet).
 - o Prediction of bounding boxes and object classes through the Head.

Tools Used:

- Python software and PyTorch library for model development.
- A computer with GPU support for processing.

3. API and GUI Development

To create a system that connects the AI model to a user interface for interaction.

Procedures:

1. Develop an API using Python to output YOLOv8 results as JSON Data.
2. Create a GUI using VB.NET to display JSON Data and send machine control commands.

Tools Used:

- Python for API development.
- VB.NET for GUI development.

4. Machine Control via PLC

To control industrial machinery through the GUI and PLC.

Procedures:

1. Develop a GUI in VB.NET to interface with MX Component.
2. Use MX Component to send control commands to the PLC.
3. Test the system by verifying the machine's responses to commands.

Tools Used:

- Mitsubishi PLC for machine control.
- MX Component library for communication.

Data Collection and Analysis**1. Data Collection:**

- o Capture images using a camera to build the dataset.
- o Record RGB to CMYK conversion data and YOLOv8 detection results.

2. Data Analysis:

- o Use loss functions (Box Loss, Class Loss, Objectness Loss) to evaluate model performance.
- o Test the accuracy of the API, GUI, and PLC system by validating the machine's operational outputs.

All procedures aim to integrate advanced technologies to develop an efficient automated system for verifying and controlling machinery in the printing industry.




Fig. 8. Data Collection and Analysis.


IV. EXPERIMENTAL RESULTS

Fig. 9. Results: Offset and Flexo.

The experimental results are presented and analyzed below using various visualizations and metrics to evaluate the performance of the proposed model. The following key outcomes were observed.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Fig. 10. Instance Distribution.

1. Instance Distribution

The bar chart demonstrates that the dataset is balanced in terms of the two primary classes, Offset and Flexo, each containing approximately 2,000 instances. This indicates that the model training was not biased towards a particular class due to class imbalance.

- The background class exhibits some misclassifications, with a significant number of false negatives.

The normalized confusion matrix confirms that the model achieves 100% accuracy for the Offset and Flexo classes but struggles with distinguishing the background.




Fig. 13. F1-Confidence Curve.

4. F1-Confidence Curve

The F1-Confidence curve peaks at 0.29 for all classes, indicating suboptimal performance at higher confidence thresholds. Class Offset exhibits marginally better performance than Flexo.




Fig. 11. Feature Correlation.

2. Feature Correlation

The correlogram provides insight into the relationships between the features, such as x, y, width, and height. The low correlation between most features suggests independence, which can be advantageous for model generalization.




Fig. 14. Precision-Confidence Curve.

5. Precision-Confidence Curve

Precision improves steadily with confidence and reaches 100% at a threshold of 0.292. This suggests that the model is precise when predictions are made with high confidence, albeit at the cost of reduced recall.




Fig. 12. Confusion Matrix.

3. Confusion Matrix

The confusion matrix highlights the true positives, false positives, and false negatives:

- High true positive counts for both Offset and Flexo classes.




Fig. 15. Precision-Recall (PR) Curve.

6. Precision-Recall (PR) Curve

The PR curve shows:

- Offset achieves a slightly better $mAP@0.5$ (0.200) than Flexo (0.197).
- Overall $mAP@0.5$ is 0.198, reflecting moderate model performance with room for improvement.




Fig. 16. Training and Validation Loss.

7. Training and Validation Loss

The graphs below depict the loss functions (box, class, and DFL) for both training and validation processes, along with metrics like precision, recall, $mAP50$, and $mAP50-95$ over 100 epochs. The consistent decline in loss value demonstrates effective model training. However, the slight fluctuations in validation metrics highlight potential overfitting at higher epochs.

V. DISCUSSION

The model performs well for identifying the Offset and Flexo classes, as evident from the normalized confusion matrix and F1-Confidence curves. However, it struggles with the background class, leading to lower overall performance metrics.

Compared to similar research:

- **Advantages:** The balanced dataset and low feature correlation likely contribute to better generalization. The high precision at higher confidence thresholds demonstrates robustness in accurate predictions.
- **Limitations:** The lower $mAP@0.5$ suggests room for optimization, particularly for reducing background misclassification.

Limitations and Improvements

The following limitations were identified:

1. **Background misclassification:** A significant number of false positives and negatives for the background class.
2. **Low overall F1-Score:** Indicates that precision and recall need improvement.
3. **Confidence threshold tuning:** Suboptimal confidence thresholds may affect performance.

To address these issues, future work could explore:

- Data augmentation techniques to better capture background diversity.
- Hyperparameter optimization for threshold tuning.
- Integration of advanced loss functions such as focal loss to handle class imbalance in predictions.

VI. CONCLUSION

The study reveals that the model achieves high precision for Offset and Flexo classes but struggles with background classification, as shown by the confusion matrices and PR curves. Overall, the model's performance metrics, including $mAP@0.5$, indicate moderate effectiveness with clear opportunities for enhancement.

Future Work

1. Enhance the model's ability to distinguish the background class through advanced training strategies.
2. Incorporate additional features or modify existing ones to improve overall correlation and predictive power.
3. Evaluate the model's performance on larger and more diverse datasets to ensure scalability and robustness.

REFERENCES

- [1] S. Aras, S. Rimantas, J. Eugenijus and I. Igor, "Assessment of the Condition of Anilox Rollers," *Coatings*, Oct 2021. [Online]. Available: <https://doi.org/10.3390/coatings11111301>.
- [2] d. Stefano, "Screen angles in flexography," flexo-expert, 2017. [Online]. Available: <https://www.flexo-expert/screen-angles-in-flexography/>.
- [3] A. Khalid, D. Amira and B. Lara, "Color Detection and Mixing System," *International Journal of Computer Applications Technology and Research*, vol. 6, no. 9, pp. 431-433, 2017.
- [4] A. K. V. T.M., "Colour based Image Segmentation for Automated Detection of Leukaemia: A comparison between CIELAB and CMYK colour spaces," in 2018 International Conference on Circuits and Systems in Digital Enterprise Technology (ICSDIET), Kottayam, India, 2018.
- [5] A.-B. Ibrahim and D. Hassane, "Camera-Based Colour Sensing System," *Red*, 2006.
- [6] M. G. Bertacchi and I. F. Silveira, "Facial Makeup Detection using the CMYK Color Model and Convolutional Neural Networks," in XV Workshop de Visão Computacional (WVC), São Bernardo do Campo, Brazil, 2019.
- [7] Q. C. et al., "Building A Deep Learning Model for Multi-Label Classification of Natural Disasters," in IEEE 3rd International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA), Chongqing, China, 2023.
- [8] M. B. Ullah, "CPU Based YOLO: A Real Time Object Detection Algorithm," in IFFE Region 10 Symposium (TENSYPMP), Dhaka, Bangladesh, 2020.
- [9] A. V. P. S. K. Naman Mittal, "Object Detection and Classification Using Yolo," *International Journal of Scientific Research & Engineering Trends*, vol. 5, no. 2, 2019.
- [10] S. R. Kanhaiya Sharma, "State-of-the-Art Analysis of Multiple Object Detection Techniques using Deep Learning," *International Journal of Advanced Computer Science and Applications(IJACSA)*, vol. 14, no. 5, 2023.
- [11] R.-Y. & C. W. Ju, "Fracture detection in pediatric wrist trauma X-ray images using YOLOv8 algorithm," *Scientific Reports*, 2023.
- [12] C. & Z. G. & G. S. & D. S. & K. E. & S. T. Gao, "Advancing architectural heritage: precision decoding of East Asian timber structures from Tang dynasty to traditional Japan," *Heritage Science*, 2024.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ - นามสกุล นายชัชฌูวิษณุ อัครไชยพงศ์
วัน เดือน ปีเกิด วันที่ 28 กรกฎาคม 2520
ประวัติการศึกษา สำเร็จการศึกษาระดับปริญญาตรี หลักสูตรอุตสาหกรรมบัณฑิต สาขาวิชา
เทคโนโลยีการผลิต จากคณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้า
พระนครเหนือ ปีการศึกษา 2543 และในปี 2562 ได้เข้าศึกษาต่อใน
ระดับ ปริญญาโท หลักสูตรวิศวกรรมศาสตรมหาบัณฑิต วิศวกรรมอัตโนมัติ
คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้