

ระบบปัญญาประดิษฐ์สำหรับการนับหลอดด้ายแนวอนบนรถเข็นโดยใช้โมเดลตรวจจับวัตถุ Artificial Intelligence System for the Detection and Counting of Horizontal Spools in Carts using Object Detection

มนัสวี ลิตาธรรม, นาฏนลิน จันลาเศษ และ ครรชิต รองไชย*

ห้องวิจัยปัญญาประดิษฐ์และการพัฒนาที่ยั่งยืน (AI and Sustainability Laboratory) สาขาวิชาวิศวกรรมเครื่องกล คณะ
วิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน วิทยาเขตขอนแก่น 150 ถ. ศรีจันทร์ ต.ในเมือง
อ.เมืองขอนแก่น ขอนแก่น 40000

*Corresponding Author: kanchit.ro@rmu.ac.th

Received 6 December 2025; Received in revised form 17 February 2026; Accepted 2 April 2026


บทคัดย่อ

ในยุคที่อุตสาหกรรมการผลิตเปลี่ยนผ่านสู่ระบบอัตโนมัติและปัญญาประดิษฐ์ (AI) การนับหลอดด้ายบนรถเข็นในโรงงานสิ่งทอซึ่งพึ่งพาแรงงานมนุษย์ซึ่งใช้เวลามากและมีโอกาสเกิดข้อผิดพลาด งานวิจัยนี้พัฒนาระบบตรวจนับหลอดด้ายอัตโนมัติด้วยเทคโนโลยี AI โดยใช้บอร์ด Nvidia Jetson Nano ร่วมกับอัลกอริธึม YOLOv7 สำหรับตรวจจับหลอดด้ายทั้งแบบเอียงองศาและแบบนอน การดำเนินงานเริ่มจากการเก็บภาพหลอดด้ายเพื่อฝึกโมเดล ผลการทดสอบแสดงประสิทธิภาพสูงสุดด้วยค่า Precision 99.99%, Recall 99.99% และ mAP@0.5 เท่ากับ 99.97% โดยระบบตรวจจับได้แม่นยำทั้งสองรูปแบบด้วย F1-score 100% เมื่อทดสอบในโรงงานจริงระบบให้ค่า F1-score 100% ในทุกกรณี การเปรียบเทียบกับแรงงานมนุษย์พบว่า AI ใช้เวลาเฉลี่ยเพียง 505 มิลลิวินาทีต่อรอบ ขณะที่พนักงานใช้เวลา 4.28 วินาทีสำหรับหลอดแบบเอียง และ 50.4 วินาทีสำหรับหลอดแบบนอน แสดงให้เห็นว่าระบบ AI มีความเร็วและแม่นยำกว่าอย่างมีนัยสำคัญ เหมาะสำหรับการประยุกต์ใช้ในอุตสาหกรรมสิ่งทอเพื่อเพิ่มสมรรถนะและลดต้นทุนการผลิต

คำสำคัญ: ปัญญาประดิษฐ์ (AI), การมองเห็นของเครื่อง, การตรวจจับวัตถุ, YOLOv7

Abstract

In an era where industrial manufacturing is increasingly embracing automation and artificial intelligence (AI) to enhance efficiency, accuracy and reduce labour dependency, one persistent challenge in textile factories is the manual counting of yarn tubes on carts which is a task that demands high precision but remains time-consuming and reliant on human workers. This research presents the design and development of an AI-powered system for counting yarn tubes on carts, tailored for industrial applications. The system utilises an Nvidia Jetson Nano board and YOLOv7 object detection algorithm to identify and count yarn tubes positioned both at a 45-degree angle and horizontally. The development process involved collecting image data, training the models and validating their performance. The model demonstrated a Precision of 99.99%, Recall of 99.99% and mAP@0.5 of 99.97%. The system achieved an F1-score of 100% for both 45-degree and horizontal yarn tubes. In real-world industrial testing, the



model achieved an F1-score of 100% in all test cases. When comparing the performance of the AI system to that of human workers, the AI took only 505 millisecond per round to count, whereas human workers took an average of 4.28 seconds for angled tubes and 50.4 seconds for horizontal tubes.

Keywords: Artificial intelligence, Object detection, Machine Vision, YOLOv7

บทนำ

ปัญญาประดิษฐ์ (AI) กำลังเปลี่ยนแปลงการทำงานของอุตสาหกรรมหลากหลายประเภท ไม่เพียงแต่จะช่วยเพิ่มประสิทธิภาพและความสามารถในการดำเนินงานขององค์กร แต่ยังสร้างโอกาสใหม่ให้กับการพัฒนาเศรษฐกิจและสังคมทั่วโลก โดย AI ได้รับการประยุกต์ใช้อย่างแพร่หลายในภาคส่วนต่างๆ เช่น การผลิต การแพทย์ การขนส่ง การตลาด รวมถึงการศึกษาและเกษตรกรรม [1]

ในอุตสาหกรรม 5.0 การประยุกต์ใช้เทคโนโลยีการมองเห็นด้วยคอมพิวเตอร์ (Computer Vision) ร่วมกับ AI ช่วยเพิ่มสมรรถนะในการผลิต โดยการใช้กล้องและเซ็นเซอร์ในการ "มองเห็น" และเข้าใจข้อมูลภาพ ซึ่งสามารถตรวจสอบการทำงานของเครื่องจักร การตรวจจับความผิดปกติในกระบวนการผลิต และการตรวจสอบคุณภาพสินค้าได้อย่างแม่นยำและรวดเร็ว การใช้เทคโนโลยีเหล่านี้ทำให้สามารถลดข้อผิดพลาดที่เกิดจากมนุษย์ และช่วยลดเวลาในการผลิต เพิ่มผลผลิต และทำให้กระบวนการผลิตมีความยืดหยุ่นและมีคุณภาพสูงขึ้น ซึ่งสอดคล้องกับหลักการของอุตสาหกรรม 5.0 ที่มุ่งเน้นการผสมผสานเทคโนโลยีอัจฉริยะ เช่น AI และหุ่นยนต์ เพื่อยกระดับการผลิตให้มีประสิทธิภาพและความรวดเร็วมากขึ้น [2-4]

ตัวอย่างหนึ่งที่โดดเด่นคือ การใช้ AI ในอุตสาหกรรมการผลิตแหวนสำหรับการประมง ซึ่งเป็นส่วนสำคัญของเศรษฐกิจในหลายประเทศที่การประมงเป็นอาชีพหลัก การผลิตแหวนต้องการความแม่นยำในการตรวจสอบคุณภาพ วัสดุที่นำมาใช้ต้องมีความแข็งแรง ทนทานต่อแรงดึงและการกัดกร่อนจากน้ำทะเล กระบวนการผลิตแหวนประกอบด้วยหลายขั้นตอน ตั้งแต่การเตรียมวัสดุ การปั่นเส้นด้าย การถัก

แห และการตรวจสอบคุณภาพ ซึ่งทุกขั้นตอนต้องมีความแม่นยำ

ปัญหาที่พบบ่อยคือการนับจำนวนหลอดด้ายที่ใช้ในกระบวนการผลิตแหวน การที่ยังพึ่งพาแรงงานคนในการนับจำนวนหลอดด้ายทำให้เกิดข้อผิดพลาดได้ง่าย เช่น การนับซ้ำซ้อนหรือนับไม่ครบอันเนื่องมาจากความเหนื่อยล้าของแรงงาน แต่การนำ AI เข้ามาใช้ควบคู่กับแรงงานคนภายในกระบวนการนี้ [5] ช่วยลดข้อผิดพลาด เพิ่มความแม่นยำ และยังสามารถทำงานได้อย่างต่อเนื่องโดยไม่หยุดพัก ช่วยเพิ่มผลผลิตต่อวันและลดค่าใช้จ่ายในระยะยาว [6]

การนับจำนวนวัตถุดิบมีความสำคัญในหลายอุตสาหกรรม โดยเฉพาะอุตสาหกรรมการผลิต ซึ่งการนับที่แม่นยำจะช่วยเพิ่มประสิทธิภาพการดำเนินงาน ลดความสูญเสีย และสนับสนุนการบริหารจัดการด้านโลจิสติกส์ได้ เทคโนโลยีด้าน Machine Vision และปัญญาประดิษฐ์ จึงได้รับการพัฒนาอย่างต่อเนื่องเพื่อใช้ในงานที่ต้องการความแม่นยำสูง โดยงานวิจัยนี้ได้นำโมเดล YOLOv7 [7] มาใช้ร่วมกับระบบ Edge AI ซึ่งประมวลผลบนอุปกรณ์ปลายทางอย่าง Nvidia Jetson Nano ที่ได้รับความนิยมอย่างแพร่หลาย เนื่องจากช่วยลดภาระของระบบเครือข่ายและศูนย์ข้อมูล โดยการประมวลผลภาพสามารถทำได้แบบเรียลไทม์ที่อุปกรณ์ ช่วยลดความล่าช้าในการส่งข้อมูล [8]

การปรับใช้ AI ยังช่วยให้อุตสาหกรรมสามารถปรับตัวได้ทันกับยุคแห่งเทคโนโลยีที่เปลี่ยนแปลงอย่างรวดเร็ว ไม่เพียงช่วยให้ธุรกิจสามารถแข่งขันได้ในตลาดโลก แต่ยังช่วยสร้างมาตรฐานใหม่ในการผลิตเพิ่มโอกาสทางเศรษฐกิจ และช่วยสร้างความยั่งยืนให้กับภาคการผลิตในอนาคต [9]

การทบทวนวรรณกรรม

บทบาทของปัญญาประดิษฐ์ ในการสนับสนุนอุตสาหกรรม 4.0 และ 5.0 พบว่า AI เป็นตัวขับเคลื่อนสำคัญในการสร้างระบบการผลิตอัจฉริยะ และส่งเสริมความเป็นอยู่ของแรงงานอย่างยั่งยืน การทบทวนวรรณกรรมจาก 2,887 บทความเผยให้เห็นการเติบโตของงานวิชาการตั้งแต่ปี 2018 และระบุ 4 กลุ่มเนื้อหาเด่น โดยเฉพาะหัวข้อเกี่ยวกับอุตสาหกรรม 5.0 และการเรียนรู้เชิงลึก พร้อมนำเสนอแนวทางและประเด็นวิจัยเชิงลึกสำหรับอนาคต [10]

การทำงานของ Convolutional Neural Networks (CNNs) เป็นหัวใจสำคัญของงานด้าน Artificial Intelligence ที่สามารถอธิบายได้ (xAI) เพราะแม้ว่า CNNs จะประสบความสำเร็จสูง แต่ยังมีลักษณะเป็น กล่องดำ ทำให้เข้าใจเหตุผลเบื้องหลังการตัดสินใจได้ยาก ปัจจุบัน วิธีอธิบายส่วนใหญ่ยังเน้นการสร้างภาพหรือการทำ Visualization ซึ่งยังไม่ครอบคลุมทุกแง่มุมของการตีความโมเดล [11]

การประยุกต์ใช้ปัญญาประดิษฐ์ (Artificial Intelligence) และ เอจ (Edge) หรือ Edge AI ซึ่งหมายถึงการประมวลผล AI ในอุปกรณ์ที่ใกล้กับผู้ใช้ หรืออุปกรณ์แบบฝังตัว โดยเน้นการประมวลผล AI ใกล้กับผู้ใช้ แทนที่จะดำเนินการในศูนย์ข้อมูลส่วนกลาง [8]

ใช้เทคโนโลยี AI ตรวจจับภาพด้วยโมเดล YOLOv7 เพื่อระบุและพ่นยาฆ่าวัชพืชเฉพาะจุดโดยใช้ระบบอัตโนมัติและโดรน แทนการฉีดพ่นทั่วพื้นที่ที่มีต้นทุนสูงและเป็นอันตรายต่อสิ่งแวดล้อม ผลการทดลองพบว่า YOLOv7 ให้สมรรถนะการตรวจจับวัชพืชสูง โดยได้ mAP และค่าประเมินอื่นๆ สูงกว่า 99% [12]

โมเดลตรวจจับและนับผลผลิตผลไม้ที่ผสมผสานกลไก self-attention ของ Vision Transformer (CBAM และ CA) เข้ากับ YOLOv7 เพื่อแก้ปัญหาการนับผลไม้ที่ซับซ้อน เช่น การบดบังและความแปรผันของผลไม้ พร้อมเสริมด้วยวิธีติดตามวัตถุหลายตัว (SORT และ Cascade-SORT) สำหรับการนับข้ามเฟรม

ผลลัพธ์พบว่าโมเดล YOLOv7-CA ให้ค่า mAP 91.3% และ F1 score 0.85 สูงกว่า YOLOv7 เดิม พร้อมลดค่า Mean Absolute Error ลง 0.642 แสดงให้เห็นว่าโมเดลใหม่นี้ช่วยเพิ่มความแม่นยำในการประเมินผลผลิต และเป็นประโยชน์ต่อการตัดสินใจในอุตสาหกรรมผลไม้ [13]

พัฒนาโมเดล MSC-YOLO จาก YOLOv7 เพื่อเพิ่มสมรรถนะการตรวจจับวัตถุขนาดเล็กในภาพถ่ายจากโดรน ซึ่งมีความยากเพราะความสูงในการบินที่เปลี่ยนแปลงได้ การเคลื่อนที่ที่เร็วทำให้ภาพเบลอและวัตถุมีขนาดเล็กมาก วิธีที่เสนอได้เพิ่มส่วน HEAD เพื่อช่วยตรวจจับวัตถุเล็กแทนการใช้วิธีลดขนาดภาพแบบเดิม และออกแบบโมดูลใหม่ที่จะดึงรายละเอียดของบริบทในหลายขนาด เพื่อให้มองเห็นวัตถุเล็กได้ชัดเจน ผลการทดลองกับชุดข้อมูลภาพถ่ายทางอากาศพบว่าวิธีใหม่ให้ความแม่นยำสูงกว่าวิธีมาตรฐานเดิมประมาณ 3 เปอร์เซ็นต์ แสดงให้เห็นว่าเหมาะสำหรับการใช้งานจริงในงานตรวจจับวัตถุจากโดรน [14]

วิธีอธิบายผลลัพธ์ของโมเดลเรียนรู้ของเครื่องที่ออกแบบมาสำหรับผู้ทั่วไป ไม่ใช่เฉพาะผู้เชี่ยวชาญ โดยใช้เทคนิคการมาสก์บางส่วนเพื่อระบุส่วนสำคัญในภาพสำหรับงานจำแนกภาพ แล้วสร้างคำอธิบายทั้งแบบภาพและข้อความ เช่น แผนที่ส่วนสำคัญของฟิกเชลและกราฟแสดงน้ำหนักของฟิเจอร์ จากการทดสอบกับผู้ใช้อย่างน้อย 50 คน วิธีนี้ให้คำอธิบายที่เข้าใจง่ายและมีประสิทธิภาพดีกว่าวิธีเดิม ทำให้เหมาะสำหรับใช้จริงในการอธิบายการตัดสินใจของโมเดลให้ผู้ใช้อย่างทั่วไประบุ [15]

ระบบตรวจจับ ติดตาม และนับยานพาหนะแบบเรียลไทม์ด้วย YOLOv7 เพื่อแก้ปัญหาการตรวจจับพลาดและการมองเห็นรถขนาดเล็กบนทางหลวง ระบบสามารถจำแนกประเภทรถ วิเคราะห์การไหลของการจราจร และให้ข้อมูลสถิติแบบทันที ช่วยในการจัดการจราจร วางแผน และป้องกันเหตุการณ์ต่างๆ ได้ [16]

YOLOv7 เป็นตัวตรวจจับวัตถุแบบเรียลไทม์ที่ให้ความสำคัญและความแม่นยำโดดเด่น โดยทำงานได้ตั้งแต่ 5 ถึง 160 FPS และทำความแม่นยำสูงสุดได้

56.8% AP บน GPU V100 รุ่น YOLOv7-E6 (56 FPS, 55.9% AP) เร็วและแม่นยำกว่าตัวตรวจจับขั้นสูงทั้งแบบ transformer และแบบ convolution เช่น SWIN-L Cascade-Mask R-CNN และ ConvNeXt-XL Cascade-Mask R-CNN โดย YOLOv7 ทำงานเร็วกว่า 5 เท่าและแม่นยำกว่าทั้งคูนอกจากนี้ยังเหนือกว่าโมเดลยอดนิยมอื่น ๆ เช่น YOLOR, YOLOX, Scaled-YOLOv4, YOLOv5 และ DETR ทั้งในด้านความเร็วและความแม่นยำ พร้อมทั้งสามารถเทรนจากศูนย์บนชุดข้อมูล MS COCO ได้โดยไม่พึ่งพาการ pretrain [17]

Mask YOLOv7 เพื่อตรวจจับและนับวัตถุจากภาพถ่ายโดรนทั้งในสภาพแวดล้อมควบคุมและไม่ควบคุม โดยเพิ่มกลไกการแยกวัตถุเพื่อแยกวัตถุแต่ละตัว ผลการทดลองพบว่ามีความแม่นยำ 93-95% แสดงให้เห็นว่าโมเดลสามารถแข่งขันกับวิธีตรวจจับและแยกวัตถุอื่น ๆ ได้ทั้งด้านความแม่นยำและความเร็ว และสามารถนำไปประยุกต์ใช้ในการจัดการปศุสัตว์ เช่น การติดตาม ตรวจสอบ และรายงานข้อมูลวัวแต่ละตัว [18]

วิธีนับข้าวสาลีอัตโนมัติด้วย YOLOv7 ที่ปรับปรุงแล้วและ DeepSORT สำหรับติดตามหลายเป้าหมายและการนับแบบแบ่งเขตข้ามเส้น โดยมีการปรับปรุงเครือข่ายหลักด้วย DCNV3, PConv, BiFPN และโมดูลให้ความสนใจ CBAM เพื่อเพิ่มความแม่นยำและสมรรถนะ ผลการทดลองพบว่าโมเดลปรับปรุงมีความแม่นยำการตรวจจับ 93.8% และ mAP@0.5 เท่ากับ 94.9% การติดตามหลายเป้าหมายมีความแม่นยำ 93.0% และ MOTA 82.3% ส่วนการนับข้าวสาลีมีความแม่นยำเฉลี่ยสูงกว่า 97.5% ทำงานได้เร็ว 19.2 เฟรมต่อวินาที ทำให้สามารถใช้งานจริงในภาคการผลิตได้อย่างเสถียร [19]

ระบบการตรวจจับลิงโดยใช้ YOLOv7 โดยสร้างชุดข้อมูลเฉพาะจากภาพลิงในธรรมชาติและภาพส่วนตัว แบ่งชุดข้อมูลสำหรับฝึกและทดสอบ ทำเครื่องหมายกรอบกรณีด้วยเครื่องมือ เช่น labellmg จากนั้นฝึกโมเดล YOLOv7 ด้วยตารางการฝึกและการปรับค่าพารามิเตอร์ที่เหมาะสม เลือกจุดตรวจที่มี

สมรรถนะดีที่สุดเพื่อใช้วิเคราะห์และประเมินผลการตรวจจับ [20]

วิธีติดตามและนับนกในพื้นที่ชุ่มน้ำโดยใช้ YOLOv7 ร่วมกับการติดตามหลายวัตถุ DeepSORT โดยสร้างชุดข้อมูลนกทำ Labelling ลำตัวและหัวรวมกว่า 3,737 ภาพ และชุดข้อมูลนกเดี่ยว 11,139 ภาพ ปรับปรุง YOLOv7 ด้วยโมดูล GAM และ Alpha-IoU loss เพื่อเพิ่มความแม่นยำของการตรวจจับ ผลการทดลองได้ค่า mAP@0.5 เท่ากับ 0.951 และ mAP@0.5:0.95 เท่ากับ 0.815 จากนั้นข้อมูลถูกใช้สำหรับติดตามและนับชนิดของนกตามพื้นที่ ทำให้สามารถประเมินจำนวนและการกระจายของฝูงนกได้อย่างมีประสิทธิภาพ ช่วยสนับสนุนงานอนุรักษ์นก [21]

YOLOv7 และ DeepSORT สำหรับตรวจจับและติดตามวัตถุแปลกปลอมในเหมืองถ่านหิน โดยแก้ปัญหาความคล้ายคลึงทางกายภาพระหว่างวัตถุแปลกปลอมกับถ่านหิน โมเดลถูกปรับด้วยโมดูลเสริมและกลไกความสนใจเชิงพื้นที่ ทำให้การตรวจจับมีความแม่นยำ 91.3% และติดตามหลายวัตถุได้อย่างมีประสิทธิภาพด้วย MOTA 76.1% และ MOTP 80.6% พัฒนาการเหล่านี้เหนือกว่าอัลกอริทึมเดิมแสดงถึงศักยภาพของระบบสำหรับการใช้งานจริงในเหมืองถ่านหินและการปรับปรุงความปลอดภัยและประสิทธิภาพการผลิต [22]

YOLOv7 สำหรับตรวจจับวัตถุในภาพพืชอายุโดยเพิ่ม Modulated Deformable Convolution เพื่อปรับตำแหน่งการสุ่มตัวอย่างและลดความบิดเบือนขอบภาพ และใช้ Swin Transformer เพื่อเพิ่มประสิทธิภาพในการตรวจจับวัตถุขนาดเล็ก ผลการทดลองพบว่าโมเดลปรับปรุงเพิ่มค่า mAP สูงสุด 5.9% บนชุดข้อมูล VOC-360 และ 2.4% บน ERP-360 ยืนยันความสามารถในการตรวจจับวัตถุในภาพพืชอายุและภาพถ่ายแบบ equirectangular [23]

วิธีดำเนินงาน

1. เครื่องมือและอุปกรณ์ที่ใช้ในการทดลอง

Jetson Nano เป็นอุปกรณ์คอมพิวเตอร์หลักที่ใช้ในการประมวลผลระบบ AI ด้วยความสามารถในการประมวลผลภาพและฮาร์ดแวร์สำหรับปัญญาประดิษฐ์ในราคาที่ไม่แพง โดยเชื่อมต่อกับกล้องอุตสาหกรรม KAYETON U-400 เลนส์ 5-50 mm ใช้ในการถ่ายภาพที่มีความละเอียดและสามารถถ่ายภาพได้รวดเร็ว

2. การเก็บข้อมูล

ในการเก็บข้อมูล ผู้จัดทำได้บันทึกวิดีโอของหลอดด้ายแบบ 45 องศาและแบบนอนตามรูปที่ 1 และ 2 จากห้องทดลองและโรงงานอุตสาหกรรม โดยใช้กล้อง KAYETON เลนส์ 5-50mm ความละเอียด 1280x720 พิกเซล จากนั้นแปลงวิดีโอเป็นรูปภาพด้วยโปรแกรม Computer Vision Annotation Tool (CVAT) จำนวนภาพที่ใช้ในการพัฒนาโมเดลแสดงในตารางที่ 1



รูปที่ 1 หลอดด้ายแบบเอียง

ตารางที่ 1 จำนวนภาพที่ใช้ในการพัฒนาโมเดล

รายการ	Model
Train Set (ภาพ)	2,683
Validation Set (ภาพ)	298
หลอดด้ายแบบเอียง(ภาพ)	1,468
หลอดด้ายแบบนอน(ภาพ)	1,513



รูปที่ 2 หลอดด้ายแบบนอน


3. การจัดเตรียมข้อมูล

กระบวนการจัดเตรียมข้อมูลประกอบด้วยการทำความสะอาดข้อมูลเบื้องต้น โดยดำเนินการตรวจสอบและแก้ไขข้อมูลที่ขาดหาย ข้ำซ้อน หรือไม่สอดคล้องกัน ภายหลังจากนั้นจึงดำเนินการติดป้ายกำกับข้อมูล (Labeling) เพื่อนำไปใช้ในการฝึกโมเดลปัญญาประดิษฐ์ โดยในงานวิจัยนี้ใช้โปรแกรม CVAT ในการดำเนินการ

เมื่อกระบวนการติดป้ายกำกับข้อมูลเสร็จสมบูรณ์ จึงทำการแบ่งชุดข้อมูลออกเป็นสามส่วน ได้แก่ ชุดข้อมูลฝึกสอน (Training Set) คิดเป็น 80% ชุดข้อมูลตรวจสอบ (Validation Set) คิดเป็น 10% สำหรับการตรวจสอบสมรรถนะและป้องกันปัญหา Overfitting และชุดข้อมูลทดสอบ (Test Set) คิดเป็น 20% สำหรับการประเมินสมรรถนะของโมเดลกับข้อมูลที่ไม่เคยพบเห็นมา

4. การออกแบบระบบตรวฉับจำนวนหลอดด้าย

โครงสร้างของระบบตรวฉับจำนวนหลอดด้ายแสดงดังรูปที่ 3



รูปที่ 3 ระบบตรวฉับจำนวนหลอดด้าย

5. Hyperparameters ในการฝึกโมเดลและ การป้องกันปัญหา overfitting

โมเดล YOLOv7 ถูกฝึกด้วยอัลกอริธึม Stochastic Gradient Descent (SGD) โดยตั้งค่า batch size เท่ากับ 16, ขนาดภาพที่ป้อนเข้า (input image size) ที่ 640×640 พิกเซล และจำนวนรอบการฝึก (epoch) เท่ากับ 130 รอบ ค่า learning rate เริ่มต้น (lr0) ถูกตั้งไว้ที่ 0.01, ค่า momentum เท่ากับ 0.937 และใช้ weight decay ที่ 0.0005 เพื่อควบคุมไม่ให้น้ำหนักของโมเดลมีค่ามากเกินไป ซึ่งอาจนำไปสู่การ overfitting โดยมีการใช้เทคนิค OneCycleLR เพื่อปรับ learning rate ตลอดกระบวนการฝึก โดยตั้งค่าอัตราสุดท้าย (lrf) ที่ 0.1 และมีช่วง warm-up จำนวน 3 epoch เพื่อให้โมเดลเริ่มเรียนรู้อย่างมั่นคง โดยค่า momentum เริ่มต้นอยู่ที่ 0.8 และ learning rate ของ bias เริ่มที่ 0.1 นอกจากนี้ เพื่อเพิ่มความสามารถในการ generalize และลดความเสี่ยงของการ overfitting ยังมีการใช้เทคนิค data augmentation ที่หลากหลาย เช่น การปรับค่า HSV ของภาพ (hue = 0.015, saturation = 0.7, value = 0.4), การเลื่อนภาพ (translation ± 0.2), การย่อ-ขยายภาพ (scaling ± 0.5) และการกลับภาพในแนวนอน (flip left-right) ด้วยความน่าจะเป็น 0.5 ขณะที่การกลับภาพในแนวตั้งไม่ได้ถูกใช้งาน (flipud = 0.0) ทั้งนี้ ยังเปิดใช้งาน mosaic augmentation (mosaic = 1.0) เพื่อรวมภาพจาก 4 แหล่งเข้าด้วยกัน เพิ่มความหลากหลายของบริบทในข้อมูลฝึก โดยไม่มีการใช้เทคนิค mixup, copy-paste และ perspective เพื่อหลีกเลี่ยงการบิดเบือนลักษณะทางกายภาพของหลอดด้ายซึ่งอาจส่งผลกระทบต่อความแม่นยำของการตรวจจับวัตถุ มีการกำหนด positive/negative samples ระหว่างการฝึกใช้วิธี Optimal Transport Assignment (OTA) เพื่อเพิ่มสมรรถนะในการเรียนรู้การจับคู่วัตถุเป้าหมาย และโมเดลถูกประเมินด้วยชุดข้อมูล validation และ test ที่แยกออกจากชุดฝึก เพื่อประเมินสมรรถนะอย่างเป็นระบบ

6. การทดสอบสมรรถนะโมเดล ปัญหาประติษฐ์

ในการประเมินสมรรถนะของระบบตรวจนับหลอดด้าย ได้ดำเนินการทดสอบในสภาพแวดล้อมจริงของโรงงาน โดยแบ่งการทดลองออกเป็น 2 รูปแบบการวางหลอดด้าย ได้แก่ แบบเอียงและแบบนอน รูปแบบละ 5 ครั้ง

ตารางที่ 2 เมทริกซ์ความสับสน

		Actual Values	
		Positive	Negative
Predicted Value	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

ผลลัพธ์จากการทดสอบถูกนำมาจัดทำเป็นเมทริกซ์ความสับสน (Confusion Matrix) ดังแสดงตารางที่ 2 ซึ่งเป็นตารางแสดงผลการทำนายของโมเดลเปรียบเทียบกับค่าจริง ประกอบด้วย 4 ค่าหลัก คือ

- True Positive (TP) จำนวนหลอดด้ายที่ระบบตรวจจับได้ถูกต้อง
- False Positive (FP) จำนวนที่ระบบตรวจจับผิดพลาด (ตรวจพบแต่ไม่มีจริง)
- True Negative (TN) จำนวนที่ระบบระบุว่าไม่มีหลอดด้ายได้ถูกต้อง
- False Negative (FN) จำนวนหลอดด้ายที่มีจริงแต่ระบบตรวจไม่พบ

$$\text{Precision (P)} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Recall (R)} = \frac{TP}{TP + FN} \quad (2)$$

$$F_1\text{-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

จากเมทริกซ์ความสับสนดังกล่าว จึงนำมาคำนวณค่าตัวชี้วัดสมรรถนะต่างๆ ได้แก่ Precision

(ความแม่นยำในการตรวจจับ) ตามสมการที่ (1), *Recall* (ความสามารถในการตรวจจับครบถ้วน) ตามสมการที่ (2), และ *F1-Score* (ค่าเฉลี่ยฮาร์โมนิกของ *Precision* และ *Recall*) ตามสมการที่ (3) เพื่อประเมินสมรรถนะโดยรวมของระบบ

$$AP = \int_0^1 P \times R \, dR \quad (4)$$

Average Precision (AP) ตามสมการที่ (4) ใช้ประเมินสมรรถนะของโมเดลในแต่ละคลาส โดยคำนวณจากพื้นที่ใต้กราฟความสัมพันธ์ระหว่าง *Precision* และ *Recall* ซึ่งแสดงความสามารถของโมเดลในการรักษาความแม่นยำเมื่อค่า *Recall* เพิ่มขึ้น

$$mAP = \frac{1}{n} \sum_i^n AP_i \quad (5)$$


Mean Average Precision (mAP) ตามสมการที่ (5) คือค่าเฉลี่ยของ *AP* จากทุกคลาส ใช้ประเมิน

สมรรถนะโดยรวมของโมเดลในการตรวจจับวัตถุหลายประเภทพร้อมกัน


ผลการทดลองและการอภิปรายผล

ผลการฝึกโมเดลด้วยจำนวน 130 รอบ (Epoch) พบว่า โมเดลมีสมรรถนะสูง โดยมีค่า *Precision* อยู่ที่ 99.96% และ *Recall* ที่ 99.94% สำหรับค่า *mAP@0.5* ได้ 99.91% และ *mAP@0.95* ได้ 74.94% ตามที่แสดงในรูปที่ 4 โดยกระบวนการฝึกอบรวมทั้งหมดใช้เวลา 22 ชั่วโมง 13 นาที

ค่า Total loss จากการฝึกโมเดล ดังรูปที่ 5 อยู่ที่ 0.1258 โดยเป็นการวัดค่าความผิดพลาดของโมเดล ยิ่งค่าน้อยเท่าไรโมเดลยิ่งมีความถูกต้องสูง จากแนวโน้มของกราฟยังไม่มีปรากฏว่าค่า Total loss สูงขึ้น ดังนั้นโมเดลยังมีความสามารถในการเรียนรู้รูปแบบจากข้อมูลโดยไม่จำข้อมูลฝึกสอน



รูปที่ 4 กราฟความสัมพันธ์ระหว่าง Precision, Recall และ mAP เทียบกับ Epochs



รูปที่ 5 Total loss หรือค่าความสูญเสียทั้งหมด

ผลการนับจำนวนหลอดด้ายแบบเก่าโดยใช้คนในการเปรียบเทียบกับการนับโดยใช้โมเดล YOLOv7 ในการนับ ดังตารางที่ 3 และ 4 โดยนับทั้งวางเรียงและวางแบบนอน ดังรูปที่ 6 และ 7

ตารางที่ 3 ผลการเปรียบเทียบการนับจำนวนหลอดด้ายรถเข็นแบบเรียง

	TIME AVERAGE	PRECISION (%)	RECALL (%)	F1-SCORE (%)
คนนับ	4.82s	100	100	100
AI นับ	505ms	100	100	100

ตารางที่ 4 ผลการเปรียบเทียบการนับจำนวนหลอดด้ายรถเข็นแบบนอน

	TIME AVERAGE	PRECISION (%)	RECALL (%)	F1-SCORE (%)
คนนับ	50.4s	100	99.02	99.5
AI นับ	505ms	100	100	100



รูปที่ 6 การวางหลอดด้าย 45 องค์



รูปที่ 7 การวางหลอดด้ายแบบนอน

สรุป


การศึกษากการพัฒนากระบวนการนับหลอดด้ายโดยใช้ปัญญาประดิษฐ์เพื่อเพิ่มสมรรถนะในกระบวนการผลิตแหวน พบว่า AI สามารถลดข้อผิดพลาดจากแรงงานคนและเพิ่มความรวดเร็วได้อย่างมีนัยสำคัญ เวลาเฉลี่ยที่พนักงานใช้นับหลอดด้ายแบบ 45 องค์ คือ 4.28 วินาที และ Precision 100% ซึ่ง AI ใช้เวลาเฉลี่ย 1 วินาที Precision 100% Recall 100% F1-Score 100% และ เวลาเฉลี่ยที่คนใช้นับหลอดด้ายแบบนอนคือ 50.4 วินาที และ Precision 99.02% ซึ่ง AI ใช้เวลาเฉลี่ย 1 วินาที Precision 100% Recall 100% F1-Score 100% ซึ่งตัวอย่างจากการนับแบบนอนมีจำนวนหลอดด้ายกว่าหนึ่งร้อยหลอด และคนนับต้องใช้ความพยายามในการนับ จากผลการทดลองพบว่ายังมีกรณีที่พนักงานนับผิดพลาดซึ่งทำให้เห็นว่า ระบบ AI นั้นมีเวลาเฉลี่ย และ สมรรถนะที่สูงกว่าพนักงาน

กิตติกรรมประกาศ

ขอขอบคุณมหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน วิทยาเขตขอนแก่น และบริษัทขอนแก่นแหวน จำกัด ในการสนับสนุนในการดำเนินงานวิจัย ในการเขียนบทความนี้ได้ใช้ปัญญาประดิษฐ์แบบรู้สร้าง Gemini, ChatGPT, Claude.ai ช่วยในการแปลภาษา และปรับปรุงการสื่อสารทางวิชาการให้ชัดเจนยิ่งขึ้น

เอกสารอ้างอิง

- [1] Leng, J., Sha, W., Wang, B., Zheng, P., Zhuang, C., Liu, Q., Wuest, T., Mourtzis, D., & Wang, L. (2024). Unlocking the power of industrial artificial intelligence towards Industry 5.0: Insights, pathways, and challenges. *Journal of Manufacturing Systems*, vol. 73, pp. 349–363.
- [2] Sharma, M., Tomar, A., & Hazra, A. (2024). Edge computing for Industry 5.0: Fundamental, applications and research challenges. *IEEE Internet of Things Journal*, vol. 11(11), pp. 19070–19093.



[3] Vyhmeister, E., and Castane, G. G. (2024, March). When Industry meets trustworthy AI: A systematic review of AI for Industry 5.0.

[4] Martini, B., Bellisario, D., Coletti, P. (2024). Human-centered and sustainable artificial intelligence in Industry 5.0: Challenges and perspectives. *Sustainability*, vol. 16(13), pp. 1–24.

[5] Wang, Z., and Yan, J. (2024). Deep learning-based assembly process action recognition and progress prediction facing human-centric intelligent manufacturing. *Computers & Industrial Engineering*, vol. 196, p. 109381.

[6] Rame, I., Purwanto, P., & Sudarno, S. (2024). Industry 5.0 and sustainability: An overview of emerging trends and challenges for a green future. *Innovation and Green Development*. vol. 3(4), p. 100173.

[7] Wang, C.-Y., Bochkovskiy, A., Liao, H.-Y. M. (2025). WongKinYiu /yolov7: Implementation of paper – YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [Computer software]. GitHub.

[8] Singh, R., and Gill, S. S. (2023). Edge AI: A survey. *Journal of Information Security and Applications*, vol. 70, p. 103308.

[9] Bin Rashid, A., and Kausik, M. A. K. (2024). AI revolutionizing industries worldwide: A comprehensive overview of its diverse applications. *Hybrid Advances*, vol. 7, p. 100277.

[10] Fosso-Wamba, S., and Guthrie, C. (2024). Artificial intelligence and Industry 4.0 and 5.0: A bibliometric study and research

agenda. *Procedia Computer Science*, vol. 235, pp. 718–725.

[11] López-González, C. I., Gómez-Silva, M. J., Besada-Portas, E., Pajares, G. (2024). Analyzing and interpreting convolutional neural networks using latent space topology. *Neurocomputing*, vol. 593, p. 127713.

[12] Lakshmi Narayana, C., & Venkata Ramana, K. (2023). An efficient real-time weed detection technique using YOLOv7. *International Journal of Advanced Computer Science and Applications*, vol. 14(2), pp. 550–556.


[13] Hu, J., Fan, C., Wang, Z., Ruan, J., Wu, S. (2023). Fruit detection and counting in apple orchards based on improved YOLOv7 and multi-object tracking methods. *Sensors*, vol. 23(13), p. 5931.

[14] Tang, X., Ruan, C., Li, X., Li, B., Fu, C. (2024). MSC-YOLO: Improved YOLOv7 based on multi-scale spatial context for small object detection in UAV-view. *Computers, Materials & Continua*, vol. 79(1), pp. 983–1003.

[15] Anjomshoe, S., Omeiza, D., Jiang, L. (2021). Context-based image explanations for deep neural networks. *Image and Vision Computing*, vol. 116, p. 104337.

[16] Rouf, A., Iwahori, Y., Wu, Q., Wu, H., Yu, X., Wang, A. (2023). Real-time vehicle detection, tracking and counting system based on YOLOv7. *Embedded Self Organizing Systems*, vol.10(7), pp. 4-8.

[17] Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv*.



[18] Bello, A.-W., & Oladipo, M. A. (2024). Mask YOLOv7-based drone vision system for automated cattle detection and counting. *Artificial Intelligence and Applications*. vol. 2(2), pp. 115-125.

[19] Li, Z., Zhu, Y., Sui, S., Zhao, Y., Liu, P., Li, X. (2024). Real-time detection and counting of wheat ears based on improved YOLOv7. *Computers and Electronics in Agriculture*, vol. 218, p. 108544.

[20] Vamshi, M., Marupaka, N., Nallamothu, S. C., Naureen, A. (2023). A deep learning approach – Monkey detection using YOLOv7. In *Proceedings of the 2023 International Conference on Evolutionary Algorithms and Soft Computing Techniques (EASCT 2023)*. IEEE.

[21] Chen, X., Li, Y., Zhang, Y., Wang, H., Liu, Z. (2023). An efficient method for monitoring birds based on object detection and multi-object tracking networks. *Animals*, vol. 13(10), p. 1713.

[22] Yang, D., Miao, C., Liu, Y., Wang, Y., Zheng, Y. (2024). Improved foreign object tracking algorithm in coal for belt conveyor gangue selection robot with YOLOv7 and DeepSORT. *Measurement*, vol. 228, p. 114178.

[23] Zhou, J., Yang, D., Song, T., Ye, Y., Zhang, X., & Song, Y. (2024). Improved YOLOv7 models based on modulated deformable convolution and Swin transformer for object detection in fisheye images. *Image and Vision Computing*, vol. 144, p. 104876.

