



การเปรียบเทียบระหว่างผลกระทบของภาพสีและสีขาวดำด้วยการเรียนรู้เชิงลึก: กรณีศึกษาการตรวจจับก้อนน้ำที่มีข้อบกพร่องในสายการผลิต

อรรณพ ปิยะสินธ์ชาติ¹ พิสิฐ พรพงศ์เตชวานิช² ภราดร บุญพอ³ ภัคศิษฐ์ ศรีอมรตระกูล³ และ เทอดพงษ์ แดงสี*

¹ สาขาวิชาเทคโนโลยีธุรกิจดิจิทัล, คณะเทคโนโลยีดิจิทัลและนวัตกรรม, มหาวิทยาลัยเซาธ์อีสท์บางกอก

² สาขาวิชาเทคโนโลยีสารสนเทศ, คณะอุตสาหกรรมและเทคโนโลยี,
มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ วิทยาเขตวังไกลกังวล

³ สาขาวิชาวิศวกรรมการจัดการอุตสาหกรรมเพื่อความยั่งยืน, คณะวิศวกรรมศาสตร์,
มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร

* ผู้ประสานงาน E-mail: therdpong.d@rmutp.ac.th

วันที่รับบทความ: 4 กรกฎาคม 2567; วันที่ทบทวนบทความ: 8 พฤศจิกายน 2567; วันที่ตอบรับบทความ: 26 พฤศจิกายน 2567

วันที่เผยแพร่ออนไลน์: 21 ธันวาคม 2567

บทคัดย่อ: ปัจจุบันผู้ประกอบการในภาคอุตสาหกรรมต่างๆ ได้เริ่มมีการศึกษาความเป็นไปได้ในการที่จะนำเทคโนโลยีปัญญาประดิษฐ์ซึ่งเป็นเทคโนโลยีสมัยใหม่มาช่วยในการปรับปรุงและพัฒนากระบวนการผลิต ด้วยเหตุนี้ การศึกษาที่มุ่งเน้นการขึ้น โดยมีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้แบบถ่ายโอนในการจำแนกตรวจจับก้อนน้ำที่มีข้อบกพร่องในสายการผลิตและเพื่อพัฒนาระบบอัตโนมัติสำหรับการคัดแยกชิ้นงานที่มีความบกพร่องออกจากสายการผลิต วิธีดำเนินการวิจัยเริ่มจากการเก็บรวบรวมภาพ การทำเครื่องหมายกำกับภาพ การประมวลผลภาพเบื้องต้น การแบ่งข้อมูล การเรียนรู้โมเดล การตรวจสอบความถูกต้อง และการประเมินโมเดลเป็นขั้นตอนสุดท้าย โดยใช้โมเดลการเรียนรู้แบบถ่ายโอน 6 โมเดล ซึ่งจากผลการวิจัยที่ได้ พบว่า ในการประมวลผลภาพสี โมเดล EfficientNetB0 ให้ค่าความแม่นยำสูงที่สุด (100%) ส่วนภาพขาวดำ DenseNet121, InceptionV3, MobileNet และ Xception ให้ความแม่นยำ 100% เท่ากัน อย่างไรก็ตาม เมื่อพิจารณาขนาดโมเดลร่วมด้วย พบว่า MobileNet มีขนาดเล็กที่สุดคือ 38.70 MB โดยมีประสิทธิภาพอยู่ที่ 8.824% จึงสรุปได้ว่าควรเลือกใช้โมเดล MobileNet ในการประมวลผลภาพขาวดำ เพื่อพัฒนาต่อยอดสำหรับสร้างสถานีงานอัตโนมัติในการคัดแยกชิ้นงานที่มีข้อบกพร่องออกจากสายการผลิตก้อนน้ำ

คำสำคัญ: การเรียนรู้แบบถ่ายโอน; การเรียนรู้เชิงลึก; การคัดแยก; การประมวลผลภาพ; โมเดลการเรียนรู้



Comparison Between Impacts of Color and Gray Images by Deep Learning: A Case Study of Defective Water Tap Detection in Production Line

Annop Piyasinchart¹, Phisit Pornpongtechavanich², Paradorn Boonpoor³,
Pakkasit Sriamorntrakul³ and Therdpong Daengsi^{3*}

¹ Department of Digital Business Technology, Faculty of Technology Digital and Innovation,
Southeast Bangkok University

² Department of Information Technology, Faculty of Industry and Technology,
Rajamangala University of Technology Rattanakosin Wang Klai Kangwon Campus

³ Department of Sustainable Industrial Management Engineering, Faculty of Engineering,
Rajamangala University of Technology Phra Nakhon

* Corresponding author, E-mail: therdpong.d@rmutp.ac.th

Received: 4 July 2024; Revised: 8 November 2024; Accepted: 26 November 2024

Online Published: 21 December 2024

Abstract: Currently, entrepreneurs across various industrial sectors have begun studying the feasibility of implementing artificial intelligence, a modern technology, to help improve and develop their production processes. For this reason, this study was conducted with the objective of comparing the efficiency of transfer learning models in classifying and detecting defective water taps in the production line and to develop an automated system for sorting defective pieces from the production line. The research methodology begins with image collection, image labeling, preliminary image processing, data splitting, model training, validation, and model evaluation as the final step. Six transfer learning models were used. The research results show that for color image processing, the EfficientNetB0 model provides the highest accuracy (100%), while for grayscale images, DenseNet121, InceptionV3, MobileNet, and Xception all achieve 100% accuracy. However, MobileNet is the smallest at 38.70 MB, with an efficiency of 0.824% when considering model size. Therefore, it is concluded that the MobileNet model should be chosen for grayscale image processing to develop further an automated workstation for sorting defective parts from the water tap production line.

Keywords: Transfer learning; Deep learning; Classification; Image Processing; Learning Models



1. บทนำ

กึ่งอัตโนมัติ โดยทั่วไปผลิตจากโลหะผสมทองแดง เป็นอุปกรณ์ติดตั้งที่พบได้ในทุกครัวเรือนและอาคาร ไม่ว่าจะเป็นบ้านพักอาศัย สำนักงาน หรือสถานที่สาธารณะ ด้วยเหตุนี้ จึงเป็นสิ่งจำเป็นในชีวิตประจำวันที่ใช้ตลอดทั้งวัน โดยเฉพาะอย่างยิ่งในตอนเช้าและก่อนเข้านอน ความจำเป็นนี้สะท้อนให้เห็นถึงความสำคัญอย่างยิ่งของอุตสาหกรรมกึ่งอัตโนมัติในระบบเศรษฐกิจและชีวิตความเป็นอยู่ของผู้คน อย่างไรก็ตาม การผลิตกึ่งอัตโนมัติแต่ละประเภทเป็นกระบวนการที่ซับซ้อน ประกอบด้วยขั้นตอนมากกว่าสิบขั้นตอน แต่ละขั้นตอนมีความสำคัญและต้องการความแม่นยำสูง ตัวอย่างขั้นตอนที่ต้องการความแม่นยำได้แก่ การตีขึ้นรูป การกลึง การเจาะ และการประกอบ แต่ละขั้นตอนต้องใช้ทักษะและเทคโนโลยีเฉพาะทางเป็นอย่างมากจนถึงขั้นตอนสุดท้ายของการผลิตสินค้าสำเร็จรูป มีความเป็นไปได้สูงที่ผลลัพธ์ของแต่ละขั้นตอน ที่เรียกว่างานระหว่างทำ (Work in Process: WIP) อาจมีผลิตภัณฑ์ที่บกพร่อง ซึ่งอาจเกิดจากหลายปัจจัย เช่น ความผิดพลาดของเครื่องจักร คุณภาพวัตถุดิบ หรือข้อผิดพลาดในการตั้งค่า ชิ้นงานที่บกพร่องเหล่านี้ต้องได้รับการระบุและคัดออกอย่างรวดเร็วและแม่นยำก่อนที่จะดำเนินการในขั้นตอนต่อไป เพื่อรักษาคุณภาพของผลิตภัณฑ์สุดท้ายและลดการสูญเสียทรัพยากร ซึ่งหนึ่งในขั้นตอนที่น่าสนใจและมีความสำคัญในการผลิตกึ่งอัตโนมัติคือ การตีขึ้นรูปเป็นกระบวนการบีบขึ้นรูปโลหะให้ได้รูปทรงตามที่ได้มีการออกแบบไว้ ก่อนนำชิ้นงานที่ได้ไปเข้ากระบวนการตัดแต่งในขั้นตอนถัดไป ซึ่งจะเกิดการสูญเสียเวลาพลังงาน และทรัพยากรอื่น ๆ โดยไม่จำเป็น ส่งผลกระทบเชิงลบต่อประสิทธิภาพและต้นทุนการผลิตของ

สายการผลิตทั้งหมด หากชิ้นงานที่มีตำหนิหรือบกพร่องถูกป้อนเข้าสู่กระบวนการดังกล่าว การตรวจจับข้อบกพร่องก่อนที่จะดำเนินการสู่กระบวนการตัดแต่งจึงมีความสำคัญอย่างยิ่งเพื่อหลีกเลี่ยงความผิดพลาดเหล่านี้ จึงเกิดเป็นแนวคิดที่จะนำเอาเทคโนโลยีที่ทันสมัยในปัจจุบันมาช่วยในการลดข้อผิดพลาด เช่น การประมวลผลภาพและปัญญาประดิษฐ์ (Artificial Intelligence: AI) เพื่อตรวจจับข้อบกพร่องล่วงหน้าที่มีแนวโน้มที่จะเพิ่มประสิทธิภาพโดยรวมของอุปกรณ์ (Overall Equipment Effectiveness: OEE) เนื่องจากเทคโนโลยีเหล่านี้สามารถทำงานได้อย่างรวดเร็ว แม่นยำ และต่อเนื่องตลอด 24 ชั่วโมง มากกว่าใช้มนุษย์ในการทำงาน

ด้วยเหตุนี้ การศึกษานี้ซึ่งพัฒนาต่อยอดจาก [1-2] ได้ถูกดำเนินการขึ้นโดยมีวัตถุประสงค์เพื่อศึกษาเปรียบเทียบประสิทธิภาพของโมเดลที่ใช้จำแนกชิ้นงานระหว่างกระบวนการผลิตที่เป็นขั้นที่ดีและที่มีตำหนิ โดยมีเป้าหมายคือ การหาโมเดลที่เหมาะสมที่สุดสำหรับการนำไปพัฒนาระบบในการทำงานด้วยการสร้างระบบอัตโนมัติสำหรับการจำแนกและคัดแยกชิ้นงานที่มีข้อบกพร่องออกจากสายการผลิต (ซึ่งปัจจุบันยังไม่มีมีการนำระบบอัตโนมัติที่ทำงานร่วมกับปัญญาประดิษฐ์มาใช้ในงานดังกล่าว) ก่อนที่จะเข้าสู่กระบวนการการผลิตถัดไป ทั้งนี้เพื่อเพิ่มประสิทธิภาพการผลิต ลดของเสีย และปรับปรุงคุณภาพผลิตภัณฑ์โดยรวมในกระบวนการผลิต ซึ่งจะส่งผลต่อความสามารถในการแข่งขันของบริษัทในอนาคต อีกทั้งยังช่วยประหยัดพลังงาน และช่วยลดต้นทุนการผลิตของบริษัทในภาพรวมด้วย



2. การประมวลผลภาพ

การจัดการภาพดิจิทัลเพื่อสกัดข้อมูลสำคัญนั้น โดยทั่วไปเรียกว่า “การประมวลผลภาพ” หรือ “การประมวลผลภาพดิจิทัล” [1, 3] ซึ่งเป็นกระบวนการที่มีความสำคัญอย่างยิ่งในยุคดิจิทัลปัจจุบัน โดยครอบคลุมตั้งแต่การปรับปรุงคุณภาพภาพไปจนถึงการวิเคราะห์ข้อมูลเชิงลึกจากภาพ ในศาสตร์ของข้อมูลในสาขานี้ จะมีการใช้กลยุทธ์ที่หลากหลายเพื่อจัดการกับความท้าทายเฉพาะด้าน เช่น การเกิดสัญญาณรบกวนและการบิดเบือนของสัญญาณ ซึ่งเป็นปัญหาพื้นฐานที่พบบ่อยในการทำงานกับภาพดิจิทัล ทำให้การประมวลผลสัญญาณที่เป็นเทคนิคหนึ่งในการประมวลผลภาพดิจิทัลได้พิสูจน์แล้วว่ามีความสำคัญอย่างมากในการแก้ไขปัญหาเหล่านี้และเป็นที่ยอมรับอย่างแพร่หลาย โดยวิธีการนี้ได้ใช้หลักการทางคณิตศาสตร์และสถิติในการวิเคราะห์และปรับแต่งสัญญาณดิจิทัล เพื่อขจัดสัญญาณรบกวนและฟื้นฟูคุณภาพของภาพ นอกจากนี้ การประมวลผลภาพยังขยายขอบเขตการประยุกต์ใช้ไปสู่ด้านที่ซับซ้อนยิ่งขึ้น เช่น เทคโนโลยีคอมพิวเตอร์กราฟิกและคอมพิวเตอร์วิชัน ซึ่งไม่เพียงแต่สกัดข้อมูลเท่านั้น แต่ยังสามารถสร้างภาพเสมือนจริงและทำความเข้าใจเนื้อหาของภาพในระดับที่ลึกซึ้งขึ้น [3] เทคโนโลยีเหล่านี้จะช่วยการวิเคราะห์ข้อมูลและประมวลผลภาพได้อย่างมีประสิทธิภาพ ขอบเขตของการแก้ไขภาพดิจิทัลสำหรับการประมวลผลภาพ สามารถแยกย่อยลงลึกได้อีกหลายวิธีการ [4] โดยแต่ละวิธีการจะมีความเชี่ยวชาญและเทคนิคเฉพาะทางของแต่ละวิธีการ ได้แก่ (1) การแบ่งส่วนภาพ (Segmentation) เป็นกระบวนการแยกภาพออกเป็นส่วน ๆ ตามลักษณะหรือวัตถุที่สนใจ ช่วยใน

การวิเคราะห์ภาพที่ซับซ้อน เช่น การแยกพื้นหลังออกจากวัตถุหลัก (2) การสกัดและคัดเลือกคุณลักษณะ (Feature Extraction and Selection) เป็นการระบุและเลือกคุณลักษณะเด่นของภาพที่สำคัญต่อการวิเคราะห์หรือจำแนกประเภท เช่น การหาขอบ สี หรือพื้นผิว (3) การบีบอัดภาพ (Compression) เป็นเทคนิคการลดขนาดของไฟล์ภาพโดยพยายามรักษาคุณภาพไว้ให้มากที่สุด ช่วยประหยัดพื้นที่จัดเก็บและทำให้การส่งข้อมูลเร็วขึ้น (4) การเพิ่มคุณภาพภาพ (Image Enhancement) เป็นการปรับปรุงคุณภาพของภาพให้ดีขึ้น เช่น การเพิ่มความคมชัด การปรับความสว่าง หรือการลดสัญญาณรบกวน และ (5) การบูรณะภาพ (Restoration) เป็นการฟื้นฟูภาพที่เสียหายหรือเสื่อมคุณภาพให้กลับมามีคุณภาพใกล้เคียงกับภาพต้นฉบับมากที่สุด นอกจากนี้ยังมีการพัฒนาเทคนิคขั้นสูงอื่น ๆ เช่น การใช้ปัญญาประดิษฐ์ (Artificial Intelligence: AI) และการเรียนรู้ของเครื่อง (Machine Learning: ML) ในการประมวลผลภาพ ซึ่งช่วยเพิ่มความสามารถในการวิเคราะห์และตีความภาพให้ซับซ้อนและแม่นยำ [5] ยิ่งขึ้น เทคโนโลยีเหล่านี้มีบทบาทสำคัญในหลากหลายอุตสาหกรรม ตั้งแต่การแพทย์ การเกษตร ไปจนถึงระบบรักษาความปลอดภัยและยานยนต์ไร้คนขับ

การพัฒนาอย่างต่อเนื่องในด้านการประมวลผลภาพไม่เพียงแต่ช่วยปรับปรุงคุณภาพของภาพและการวิเคราะห์ข้อมูลเท่านั้น แต่ยังเปิดโอกาสใหม่ ๆ ในการประยุกต์ใช้เทคโนโลยีนี้ในชีวิตประจำวันและในภาคอุตสาหกรรม ซึ่งจะส่งผลต่อการพัฒนาเทคโนโลยีและนวัตกรรมในอนาคตอย่างมีนัยสำคัญ



3. การเรียนรู้เชิงลึกและการเรียนรู้แบบถ่ายโอน

ปัญญาประดิษฐ์ เป็นการประยุกต์ใช้วิธีการวิเคราะห์ขั้นสูงและวิธีการที่ขับเคลื่อนด้วยตรรกะ เช่น การเรียนรู้ของเครื่อง เพื่อทำความเข้าใจเหตุการณ์ได้ง่ายขึ้น ช่วยในการตัดสินใจ และทำให้การดำเนินการเป็นไปโดยอัตโนมัติ ปัญญาประดิษฐ์เป็นเทคโนโลยีที่กำลังได้รับการพัฒนาอย่างต่อเนื่อง ทำให้สิ่งต่าง ๆ มีความสามารถมากยิ่งขึ้น โดยปัญญาประดิษฐ์ไม่เพียงแต่จำลองกระบวนการคิดของมนุษย์ แต่ยังสามารถประมวลผลข้อมูลจำนวนมากมหาศาลหรือที่เรียกกันว่าบิ๊กเดต้า (Big Data) และทำงานได้อย่างต่อเนื่อง โดยเฉพาะเป็นเครื่องจักร [6] ซึ่งการเรียนรู้ของเครื่อง (ML) นั้นสามารถแยกย่อยลงไปได้อีกซึ่งที่เรียกว่าการเรียนรู้เชิงลึก (Deep Learning) โดยทั้งการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกนี้เป็นส่วนหนึ่งของเทคโนโลยีปัญญาประดิษฐ์ ซึ่งได้รับแรงบันดาลใจจากโครงสร้างของสมองมนุษย์ การเรียนรู้เชิงลึกเลียนแบบการทำงานของเครือข่ายประสาทในสมอง โดยใช้ชั้นของโหนดในการประมวลผลหลายชั้นเพื่อวิเคราะห์ข้อมูลในระดับที่ซับซ้อนมากขึ้น

การเรียนรู้เชิงลึกใช้เทคนิคที่เรียกว่าการเรียนรู้แบบถ่ายโอน ซึ่งคุณลักษณะที่เรียนรู้จากการฝึกฝนเครือข่ายหลักบนชุดข้อมูลหนึ่งสามารถถ่ายโอนไปยังเครือข่ายรองที่ฝึกฝนบนชุดข้อมูลอื่นได้ [7] วิธีการนี้ช่วยเพิ่มประสิทธิภาพและลดเวลาในการฝึกฝนสำหรับงานที่ต้องการได้ โดยใช้ประโยชน์จากความรู้ที่ได้รับจากการฝึกฝนเบื้องต้น ซึ่งโมเดลที่ผ่านการฝึกฝนมาก่อนนี้ เป็นที่นิยมในด้านคอมพิวเตอร์วิชันและการประมวลผลภาษาธรรมชาติ เนื่องจากประสิทธิภาพและความสามารถที่เหนือกว่าในงานที่คล้ายคลึงกัน โมเดล

เหล่านี้ได้รับการฝึกฝนบนชุดข้อมูลขนาดใหญ่และหลากหลาย ทำให้มีความชำนาญในการเข้าใจพื้นฐานที่ดีเกี่ยวกับคุณลักษณะทั่วไปของภาพหรือภาษา

การเรียนรู้แบบถ่ายโอน (Transfer Learning) มีความโดดเด่นซึ่งวิธีการนี้จะมี การปรับปรุงประสิทธิภาพอยู่เสมอเมื่อเปรียบ เทียบกับโมเดลการฝึกฝนทั่ว ๆ ไป การใช้โมเดลที่ผ่านการฝึกฝนมาก่อน ทำให้ค่าเริ่มต้นที่ดีกว่า เสถียรกว่าก่อนนำไปใช้งาน เพราะได้เกิดการเรียนรู้ของเครื่องมาแล้วหลายครั้ง ความชันของเกรเดียนต์ที่ดีกว่า และประสิทธิภาพโดยรวมที่สูงกว่า นอกจากนี้ ยังช่วยประหยัดทรัพยากรการคำนวณและเวลา ทำให้สามารถพัฒนาโมเดล AI ที่ซับซ้อนได้เร็วขึ้นและมีประสิทธิภาพมากขึ้น

การพัฒนาเหล่านี้ในด้าน AI, ML, และ Deep Learning กำลังเป็นที่นิยมในอุตสาหกรรม ตั้งแต่การวินิจฉัยทางการแพทย์ที่แม่นยำยิ่งขึ้น ไปจนถึงระบบการขนส่งอัจฉริยะและการวิเคราะห์ข้อมูลทางธุรกิจขั้นสูง ซึ่งจะส่งผลกระทบต่อวิถีชีวิตและการทำงานในอนาคต การเรียนรู้แบบอู้นัย การเรียนรู้แบบทรานสดักทิฟ และการเรียนรู้แบบไม่มีผู้สอน เป็นเกณฑ์การจำแนกบางส่วนที่ใช้ในการเรียนรู้แบบถ่ายโอน ช่วยในการจัดหมวดหมู่สถานการณ์การเรียนรู้แบบถ่ายโอนเพิ่มเติม [8] โมเดลการเรียนรู้แบบถ่ายโอน 6 แบบที่ใช้ในการศึกษาวิจัยนี้ ประกอบด้วยโมเดลต่อไปนี้ [2]

- 1) ResNet50: ย่อมาจาก Residual Network ที่มี 50 ชั้น เป็นโมเดลการเรียนรู้เชิงลึกที่มีเทคนิคพิเศษที่ช่วยให้เครือข่ายเข้าใจสิ่งที่เปลี่ยนแปลงจากชั้นหนึ่งไปยังอีกชั้นหนึ่ง ทำให้ง่ายต่อการจับลักษณะและรูปแบบที่ซับซ้อน



- 2) DenseNet121: เป็นโมเดลการเรียนรู้เชิงลึกที่ซับซ้อน แต่ได้รับการยอมรับอย่างสูงในด้านประสิทธิภาพในงานคอมพิวเตอร์วิชั่น ต่างจากเครือข่ายประสาทเทียมแบบดั้งเดิม โดยมีการเชื่อมต่อพิเศษที่ช่วยเพิ่มการนำคุณลักษณะกลับมาใช้ใหม่ ลดความเสี่ยงของการสูญเสียข้อมูลสำคัญเมื่อข้อมูลเคลื่อนที่ผ่านเครือข่าย
- 3) EfficientNetBo: เป็นโมเดลที่ออกแบบมาเพื่อสร้างสมดุลระหว่างประสิทธิภาพและความแม่นยำ โดยใช้เทคนิคการปรับขนาดที่เพิ่มประสิทธิภาพขนาดและความสามารถของโมเดล ที่เกี่ยวข้องกับปัจจัยการปรับเพิ่มขนาดความลึก 20% ความกว้าง 10% และความละเอียด 15%
- 4) InceptionV3: เป็นโมเดลการเรียนรู้เชิงลึกที่มีความแม่นยำในด้านคอมพิวเตอร์วิชั่น สถาปัตยกรรมของโมเดลนี้อยู่บนพื้นฐานของวิธีการสกัดคุณลักษณะด้วยเทคนิคพิเศษเพื่อรวบรวมคุณลักษณะในหลายสเกลและความละเอียด ซึ่งมีส่วนช่วยเพิ่มความสามารถในการรู้จำรูปแบบและวัตถุที่ซับซ้อนในภาพ
- 5) MobileNet: เป็นโมเดลการเรียนรู้เชิงลึกที่ให้ประสิทธิภาพที่ดีบนอุปกรณ์มือถือ โมเดลนี้ใช้เทคนิคพิเศษที่ช่วยลดภาระการคำนวณและความซับซ้อนของโมเดล แต่ยังคงรักษาความแม่นยำและเพิ่มประสิทธิภาพความเร็วและประสิทธิภาพบนอุปกรณ์ที่มีทรัพยากรจำกัด

- 6) Xception: ย่อมาจาก "Extreme Inception" เป็นโมเดลการเรียนรู้เชิงลึกขั้นสูง ปรับปรุงจากสถาปัตยกรรม Inception โดยใช้ Convolutions แบบพิเศษที่ปรับมีการแต่ง จนทำให้ได้ความแม่นยำที่สูงขึ้นแต่สามารถลดการฝึกฝนลง

4. การทบทวนวรรณกรรม

จากการทบทวนวรรณกรรมที่เกี่ยวข้องพบว่ามีการศึกษาที่น่าสนใจในอดีตหลายงานวิจัย อย่างไรก็ตามมีเพียงผลงานวิจัยก่อนหน้าบางส่วนเท่านั้น ดังที่แสดงในตารางที่ 1 [9-14] ที่เกี่ยวข้องกับคำสำคัญ เช่น การเรียนรู้เชิงลึก การจำแนกประเภท การเรียนรู้แบบถ่ายโอน และการผลิต แต่ก็ยังไม่ม้งานวิจัยที่เกี่ยวข้องกับวัตถุที่อยู่ระหว่างการผลิตที่คล้ายคลึงกับผลิตภัณฑ์ก๊อมน้ำที่กล่าวถึงในการศึกษานี้ ดังนั้นจึงเป็นที่มาของการศึกษานี้ที่นำโมเดลการเรียนรู้แบบถ่ายโอนที่มีคุณสมบัติโดดเด่น และนิยมใช้ใน [9-14] จำนวน 6 โมเดลมาประยุกต์กับงานการผลิตก๊อมน้ำซึ่งเป็นอุตสาหกรรมการแปรรูปโลหะ ซึ่งช่วยลดเวลาในการฝึกฝนลงได้เป็นอย่างมาก เนื่องจากได้ผ่านการฝึกฝนเบื้องต้นกับชุดข้อมูลขนาดใหญ่และหลากหลายมาแล้ว ทำให้มีค่าเริ่มต้นที่ดีกว่าและเสถียรกว่าโมเดลทั่วไป นอกจากนี้ โมเดลการเรียนรู้แบบถ่ายโอนทั้ง 6 โมเดลที่นำมาประยุกต์กับการศึกษานี้เป็นโมเดลที่มีสมรรถนะที่ดี โดยถูกนำไปใช้ในงานวิจัยที่ได้รับการตีพิมพ์เผยแพร่ และถูกนำไปอ้างอิงอย่างกว้างขวาง คณะผู้วิจัยจึงเลือกทั้ง 6 โมเดลมาใช้ในการศึกษานี้ ซึ่งแตกต่างจากงานวิจัยก่อนหน้าที่ไม่มีบทความใดศึกษาเปรียบเทียบทั้ง 6 โมเดลกับข้อมูลภาพที่เป็นข้อมูลชุดเดียวกัน



ตารางที่ 1 ตารางสรุปงานวิจัยที่เกี่ยวข้องกับโมเดลการเรียนรู้แบบถ่ายโอนทั้ง 6 โมเดล

Ref.	Learning Model						Major Findings
	ResNet	DenseNet	EfficientNet	Inception	MobileNet	Xception	
[9]	✓	-	✓	-	-	-	บทความนี้ได้นำเสนอ GarbageNet เพื่อแก้ไขโมเดลการรู้จำเชิงลึกที่มีข้อจำกัดทางด้านการขาดข้อมูลที่เพียงพอต้นทุนสูงและคุณภาพข้อมูลที่มีสัญญาณรบกวน ผลลัพธ์ที่ได้พบว่าโมเดล GarbageNet มีประสิทธิภาพที่ดีที่สุดในแง่ของความแม่นยำ เมื่อเทียบกับโมเดลที่นิยมใช้งานในปัจจุบัน
[10]	✓	✓	-	✓	✓	-	บทความนี้เสนอระบบการจำแนกขยะอัจฉริยะที่ใช้การเรียนรู้เชิงลึกและระบบ Linux ฝังตัว โดยใช้ Raspberry Pi 4B เป็นฮาร์ดแวร์หลักและโมเดล GNet สำหรับการจำแนกขยะ พร้อมพัฒนา GUI ด้วยภาษา Python และ QT ซึ่งระบบสามารถจำแนกขยะได้ด้วยความแม่นยำ 92.62% ที่ 0.63 วินาที
[11]	✓	✓	-	✓	-	✓	บทความนี้ทำการศึกษาเสนอระบบการจำแนกขวดพลาสติกโปร่งใสอัตโนมัติเพื่อช่วยในการรีไซเคิลขวดพลาสติกปกป้องสิ่งแวดล้อมและลดมลพิษโดยใช้เทคนิค Transfer Learning และ Ensemble Learning ซึ่งสามารถจำแนกขวดพลาสติกได้ด้วยความแม่นยำถึง 99.76%
[12]	✓	-	-	-	✓	✓	งานวิจัยนี้เป็นการพัฒนาโมเดลการเรียนรู้เชิงลึกเพื่อจำแนกอาหารไทย 6 ประเภทจากชุดข้อมูลที่ไม่สมดุล โดยใช้วิธีการ Augmentation ที่ต่างกัน ก่อนทำการฝึกฝนโมเดลการเรียนรู้แบบถ่ายโอน (ResNet50, MobileNet, InceptionV3) ผลลัพธ์พบว่าวิธีการ Hybrid Sampling ช่วยเพิ่มความแม่นยำของโมเดล ResNet50 จาก 94% เป็น 96%
[13]	✓	-	-	✓	✓	-	งานวิจัยนี้นำเสนอเทคนิคการตรวจจับข้อบกพร่องในการหล่อโลหะโดยใช้การเรียนรู้เชิงลึกโดยใช้โมเดล EfficientNet แบบแยกความลึกเพื่อลดการใช้ทรัพยากรคอมพิวเตอร์ วิธีการนี้สามารถทำงานได้ดีแม้ในสภาวะที่มีกำลังประมวลผลจำกัด
[14]	✓	-	✓	-	-	-	งานวิจัยนี้เสนอการใช้การเรียนรู้แบบถ่ายโอนในการจำแนกโรคกล้วย โดยทดลองใช้โมเดลหลายรูปแบบ เช่น EfficientNet, AlexNet, VGG และ ResNet เพื่อจำแนกโรคกล้วย 25 ชนิด ผลการทดลองพบว่า VGG-19 LeoNet ที่ใช้ตัวปรับ SGD มีประสิทธิภาพสูงสุดในการจำแนกโรค



5. วิธีการดำเนินงานวิจัย

เพื่อบรรลุวัตถุประสงค์ของการศึกษานี้ ซึ่งก็คือ การศึกษาเปรียบเทียบความแม่นยำ (Accuracy) ความเที่ยง (Precision) การเรียกคืน (Recall) และค่า F1-score ที่ได้จากโมเดลการเรียนรู้แบบถ่ายโอน แต่ละโมเดลที่ถูกคัดเลือกมาศึกษา ซึ่งเลือกมาจากการพิจารณาคุณสมบัติ และจากการยอมรับและความนิยมใช้งานวิจัยก่อนหน้า [9-14] เพื่อพิจารณาหาโมเดลที่เหมาะสมที่สุดสำหรับการนำไปประยุกต์ใช้ในระบบที่สามารถตรวจจับและคัดแยกชิ้นงานที่มีข้อบกพร่อง ในระหว่างกระบวนการผลิตในอนาคต วิธีการดำเนินงานวิจัยนี้จึงได้นำเอาวิธีการที่ดำเนินการใน [2] มาประยุกต์ใช้ โดยขั้นตอนในการดำเนินการ ประกอบด้วย 7 ขั้นตอนหลัก ดังแสดงในรูปที่ 2 ซึ่งสามารถอธิบายกระบวนการได้ดังนี้

5.1 การเก็บรวบรวมภาพ: มุ่งเน้นไปที่ก๊อกรุ่นยอดนิยมหรือรุ่นขายดี (ดังรูปที่ 1) ที่ผลิตจากโรงงานกรณีศึกษานี้ โดยบันทึกภาพทั้งชิ้นส่วนที่ใช้งานได้ และชิ้นส่วนที่มีข้อบกพร่อง การศึกษานี้ครอบคลุมภาพก๊อกรุ่นที่มีการผลิตมากที่สุด ซึ่งประกอบด้วย 1) ภาพชิ้นงานดีด้านที่ระบุตราเครื่องหมายการค้า จำนวน 403 ภาพ 2) ภาพชิ้นงานดีด้านที่ระบุขนาด จำนวน 410 ภาพ 3) ภาพชิ้นงานเสียหรือมีตำหนิด้านที่ระบุตราเครื่องหมายการค้า จำนวน 404 ภาพ และ 4) ภาพชิ้นงานเสียหรือมีตำหนิด้านที่ระบุขนาด จำนวน 406 ภาพ

5.2 การทำเครื่องหมายกำกับภาพ: ภาพของชิ้นส่วนที่ดีและชิ้นส่วนที่มีตำหนิเป็นข้อมูลดิบของ 4 กลุ่มภาพหรือ คลาส (Class) ก่อนที่จะนำไปประมวลผลในขั้นตอนต่อไป

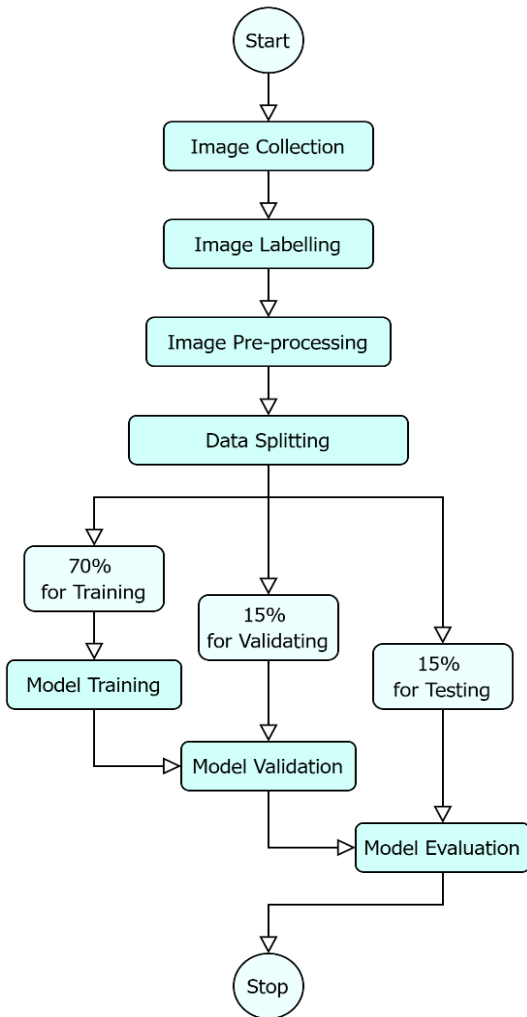
5.3 การประมวลผลภาพเบื้องต้น: ในขั้นตอนนี้ ใช้เทคนิคการครอบตัดและการแบ่งส่วนเพื่อทำให้ภาพที่ได้มามีมาตรฐานเดียวกัน โดยให้ทุกภาพมีอัตราส่วน 1:1 การครอบตัดแบบสม่ำเสมอนี้ช่วยแก้ไขความไม่สมมาตรเริ่มต้นโดยครอบคลุมทั้งส่วนบนและส่วนล่าง ซึ่งในขั้นตอนนี้ มีการจัดทำชุดข้อมูลภาพที่เป็นภาพสี เช่นเดียวกับต้นฉบับ และรูปภาพเดียวกันจัดทำเป็นภาพขาวดำ ดังแสดงในรูปที่ 3 และรูปที่ 4

5.4 การแบ่งข้อมูล: ในขั้นตอนนี้ ชุดข้อมูลที่เพิ่มขึ้นถูกแบ่งออกเป็นสามส่วนย่อย ประกอบด้วย ชุดข้อมูลสำหรับการเรียนรู้ (70%) ชุดข้อมูลสำหรับการตรวจสอบความถูกต้อง (15%) และชุดข้อมูลสำหรับการทดสอบ (15%) ซึ่งเป็นสัดส่วนที่เป็นที่ยอมรับและใช้อย่างกว้างขวางในงานวิจัยด้านปัญญาประดิษฐ์ [1-2] โดยชุดข้อมูลสำหรับการทดสอบถูกสำรองไว้สำหรับการประเมินโมเดลในขั้นตอนนี้สุดท้าย

5.5 การเรียนรู้โมเดล: ในขั้นตอนนี้ ใช้โมเดลการเรียนรู้แบบถ่ายโอน 6 โมเดลตามที่ได้อธิบายไว้ในหัวข้อที่ 4 โดยแต่ละโมเดลผ่านการฝึกฝนโดยใช้ชุดข้อมูลสำหรับการเรียนรู้ (70%) ที่ได้จากขั้นตอนในหัวข้อ 5.4



รูปที่ 1 ก๊อกรุ่นยอดนิยมที่นิยมติดตั้งในอาคาร



รูปที่ 2 แผนผังกระบวนการทำงาน

5.6 การตรวจสอบความถูกต้องของโมเดล: โมเดลที่ผ่านการฝึกฝนทั้งหมดได้รับการตรวจสอบความถูกต้องเพื่อยืนยันความแม่นยำ โดยใช้ชุดข้อมูลสำหรับการตรวจสอบความถูกต้องซึ่งประกอบด้วย 15% ของข้อมูลในขั้นตอนนี้

5.7 การประเมินโมเดล: ขั้นตอนสุดท้ายนี้เกี่ยวข้องกับ การทดสอบโมเดลทั้งหมดโดยใช้ชุดข้อมูลสำหรับการทดสอบ (15%) เพื่อให้ได้ค่าความแม่นยำ (Accuracy) ความเที่ยง (Precision) การเรียกคืน (Recall) และ ค่า F1-score โดยเมตริกเหล่านี้คำนวณโดยใช้สมการที่ให้ไว้ใน (1)-(4) [12]

หลังจากเสร็จสิ้นขั้นตอนสุดท้าย ผลลัพธ์จากการตรวจสอบความถูกต้องของโมเดลและการทดสอบ ซึ่งประกอบด้วยค่าความแม่นยำ (Accuracy) ความเที่ยง (Precision) การเรียกคืน (Recall) และค่า F1-score ได้ถูกรวบรวมและนำเสนอหัวข้อถัดไป

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - score = \frac{TP}{2TP + FP + FN} \quad (4)$$


เมื่อ

TN (True Negative) = สิ่งที่ทำนายว่าไม่จริง และ สิ่งที่เกิดขึ้นก็คือ ไม่จริง


FP (False Positive) = สิ่งที่ทำนายว่าจริง แต่สิ่งที่เกิดขึ้นก็คือ ไม่จริง

FN (False Negative) = สิ่งที่ทำนายว่าไม่จริง แต่ สิ่งที่เกิดขึ้นคือ จริง

หลังจากเสร็จสิ้นขั้นตอนสุดท้าย ผลลัพธ์จากการตรวจสอบความถูกต้องของโมเดลและการทดสอบ ซึ่งประกอบด้วยค่าความแม่นยำ ความเที่ยง การเรียกคืน และค่า F1-score ได้ถูกรวบรวมและนำเสนอหัวข้อถัดไป



รูปที่ 3 ภาพชิ้นงานที่เป็นภาพสี (ก) ชิ้นงานดีด้านที่ระบุตราเครื่องหมายการค้า (ข) ชิ้นงานดีด้านที่ระบุขนาด ค) ชิ้นงานเสียด้านที่ระบุตราเครื่องหมายการค้า และ ง) ชิ้นงานเสียด้านที่ระบุขนาด



รูปที่ 4 ภาพชิ้นงานที่เป็นภาพขาวดำ (ก) ชิ้นงานดีด้านที่ระบุตราเครื่องหมายการค้า (ข) ชิ้นงานดีด้านที่ระบุขนาด ค) ชิ้นงานเสียด้านที่ระบุตราเครื่องหมายการค้า และ ง) ชิ้นงานเสียด้านที่ระบุขนาด

6. ผลการดำเนินงานวิจัย

หลังจากดำเนินการตามกระบวนการที่นำเสนอในรูปที่ 2 ทุกโมเดลได้รับการฝึกฝนโดยใช้ภาพจาก 4 กลุ่มภาพของก๊อคน้ำที่อยู่ระหว่างกระบวนการผลิต จากนั้น จึงทำการทดสอบและหาค่าความแม่นยำ (Accuracy) ความเที่ยง (Precision) ความเรียกคืน (Recall) และค่า F1-score ของแต่ละโมเดลภายใต้แต่ละเงื่อนไขที่กำหนด จากนั้นผลลัพธ์จากการทดสอบทั้งหมดที่เกี่ยวข้องกับค่าความแม่นยำ ความเที่ยง การเรียกคืน และค่า F1-score จึงได้ถูกนำเสนอไว้ในตารางที่ 2 ซึ่งจะเห็นได้ว่า เมื่อพิจารณาค่าความแม่นยำ (Accuracy) ของโมเดลที่ประมวลผลภาพสีพบว่าโมเดลที่มีค่าความแม่นยำสูงที่สุดคือ

EfficientNetB0 คือ มีค่า 100% และในส่วนของโมเดลที่ประมวลผลภาพขาวดำพบว่าโมเดลที่มีค่าความแม่นยำมากที่สุดได้แก่ DenseNet121 InceptionV3 MobileNet และ Xception โดยมีค่าความแม่นยำ 100 % เท่ากันทั้ง 4 โมเดล และเมื่อพิจารณาค่าความเที่ยง ค่าการเรียกคืน และค่า F1-Score พบว่าได้ผลการประมวลผลที่สอดคล้องกันกับค่าความแม่นยำจึงอาจกล่าวได้ว่า ทั้ง 4 โมเดล มีสมรรถนะเหมาะสมสำหรับการนำไปประยุกต์ใช้ในระบบที่สามารถตรวจจับและคัดแยกชิ้นงานที่มีข้อบกพร่องในระหว่างกระบวนการผลิตก๊อคน้ำดังกล่าวได้ในอนาคต

อย่างไรก็ตาม สำหรับขนาดของโมเดล พบว่า MobileNet มีขนาดของโมเดลที่เล็กที่สุด คือมีขนาดเป็น



บทความวิจัย

38.70 MB รองลงมาคือ EfficientNetB0 ที่มีขนาดเป็น 48.80 MB และอันดับที่ 3 คือ DenseNet121 ซึ่งมีขนาดโมเดล 83.10 MB ดังแสดงในตารางที่ 2 แต่เนื่องจาก EfficientNetB0 ไม่เหมาะกับการประมวลผลภาพขาวดำ ดังนั้น จึงทำการวิเคราะห์เพิ่มเติมเฉพาะ DenseNet121 และ MobileNet เท่านั้น ดังแสดงในตารางที่ 3 ซึ่งจะเห็นได้ว่า เมื่อคำนวณด้วยจากสมการที่ (5) ประสิทธิภาพที่เพิ่มขึ้นจากการประมวลผลภาพขาวดำเทียบกับการประมวลผลภาพสีของโมเดล MobileNet มีค่าประมาณ 0.824% มีค่าสูงกว่าของโมเดล DenseNet121 ซึ่งมีค่าประมาณ 0.410% เล็กน้อย

$$Efficiency = \left(\frac{Accuracy_{Gray} - Accuracy_{Color}}{Accuracy_{Color}} \right) \times 100 \quad (5)$$

เมื่อ Efficiency = ประสิทธิภาพที่เพิ่มขึ้น

$Accuracy_{Gray}$ = ความแม่นยำเมื่อประมวลผลภาพขาวดำ

$Accuracy_{Color}$ = ความแม่นยำเมื่อประมวลผลภาพสี

7. การวิเคราะห์และอภิปรายผล

เมื่อทำการฝึกฝนและทดสอบโมเดลด้วยชุดข้อมูลที่เป็นภาพสี แล้วหาค่าความแม่นยำ ค่าความเที่ยง ค่าการเรียกคืน และค่า F1-score พบว่าโมเดล EfficientNetB0 ให้ผลการทดสอบทั้ง 4 ด้านสูงสุด 100% เท่ากัน อย่างไรก็ตาม เมื่อฝึกฝนและทดสอบด้วยชุดข้อมูลที่เป็นภาพขาวดำ กลับพบว่า ค่าความแม่นยำ ค่าความเที่ยง ค่าการเรียกคืน และค่า F1-score ลดลงเหลือประมาณ 98.7% -98.8% แสดงว่าโมเดล EfficientNetB0 มีแนวโน้มที่จะทำงานกับภาพสีซึ่งมีข้อมูลสำหรับการฝึกฝนปริมาณมากเนื่องจากเป็น

ข้อมูล 3 มิติที่เกิดจากการผสมของแสงสีแดง (R) สีเขียว (G) และสีน้ำเงิน (B) โดยแต่ละสีมีค่าระหว่าง 0-255 ต่างจากภาพขาวดำมีข้อมูลสำหรับการฝึกฝนน้อย เนื่องจากเป็นข้อมูล 1 มิติ โดย 0=สีดำ และ 255=สีขาว)

นอกจากนี้ยังพบว่า EfficientNetB0 ยังแตกต่างจากโมเดล DenseNet121, InceptionV3, MobileNet และ Xception ที่ฝึกฝนและทดสอบด้วยชุดข้อมูลที่เป็นภาพสีพบว่า ค่าความแม่นยำประมาณ 99.6%, 99.6%, 99.2% และ 99.6% ตามลำดับ แต่เมื่อทำการฝึกฝนและทดสอบโมเดลด้วยชุดข้อมูลที่เป็นภาพขาวดำแล้วหาค่าความแม่นยำ พบว่ามีสมรรถนะดีขึ้นโดยมีค่าความเที่ยง ค่าการเรียกคืน และค่า F1-score เพิ่มขึ้นเป็น 100% ทั้ง 4 โมเดล ทั้งนี้สันนิษฐานว่า โมเดลทั้งสี่นี้มีประสิทธิภาพลดลงเมื่อต้องประมวลผลกับข้อมูลภาพสีแบบ RGB ที่เป็นข้อมูล 3 มิติที่ซับซ้อนกว่าภาพขาวดำขาวดำที่เป็นข้อมูล 1 มิติ จึงสามารถนำโมเดลเหล่านี้ไปประยุกต์ใช้ในระบบที่สามารถตรวจจับและคัดแยกชิ้นงานที่มีข้อบกพร่องในระหว่างกระบวนการผลิตก็ก่น้ำดังกล่าวได้ในอนาคตได้ทั้ง 4 โมเดลเนื่องจากมีสมรรถนะสูงโดยเฉพาะอย่างยิ่งเมื่อประมวลผลกับภาพขาวดำ

อย่างไรก็ตาม เมื่อพิจารณาขนาดโมเดลที่เหมาะสมสำหรับการนำไปพัฒนาต่อ จะเห็นได้ว่า ด้วยค่าความแม่นยำ ความเที่ยง การเรียกคืน และค่า F1-score ที่สูงสุด 100% เท่ากัน โมเดล MobileNet มีขนาดโมเดลเพียง 38.7 MB ซึ่งเล็กกว่าของ DenseNet121, Xception และ InceptionV3 ที่มีขนาดของโมเดลประมาณ 83.1 MB, 242.0 MB และ 253.4 MB ตามลำดับโมเดล MobileNet ที่มีขนาดเล็กกว่าจึงย่อมใช้ทรัพยากรในการประมวลผลน้อยกว่า และมีแนวโน้มที่จะใช้เวลาในการ



ประมวลผลน้อยกว่า ดังนั้น MobileNet จึงเป็นโมเดลที่เหมาะสมที่สุดสำหรับการนำไปประยุกต์ใช้ในการพัฒนาระบบตรวจจับและคัดแยกชิ้นงาน ภายใต้เงื่อนไขและบริบทของอุตสาหกรรมกักน้ำตาลในการศึกษา

นอกจากนี้ เมื่อเทียบประสิทธิภาพของ MobileNet กับงานวิจัยก่อนหน้าที่ศึกษาในบริบทที่แตกต่างกัน

พบว่า ค่าความแม่นยำจากการศึกษานี้มีค่าสูงกว่าการศึกษาเหล่านั้น [10, 12] ซึ่งอาจมีสาเหตุมาจากจำนวนกลุ่มภาพหรือ คลาส ในการศึกษาที่มีลักษณะคล้ายคลึงกันจำนวนเพียง 4 กลุ่มภาพ ซึ่งแตกต่างจาก [12] ที่มีความหลากหลายของภาพมากกว่า ความแม่นยำจากการศึกษาดังกล่าวจึงน้อยกว่า

ตารางที่ 2 ผลการทดลองของแต่ละโมเดล

Model	Image Color	Test Result				Model Size (MB)
		Accuracy	Precision	Recall	F1-Score	
ResNet50	Color	99.180%	99.194%	99.153%	99.159%	273.40
	Gray	99.590%	99.590%	99.576%	99.580%	
DenseNet121	Color	99.590%	99.590%	99.576%	99.580%	83.10
	Gray	100.000%	100.000%	100.000%	100.000%	
EfficientNetB0	Color	100.000%	100.000%	100.000%	100.000%	48.80
	Gray	98.771%	98.763%	98.736%	98.740%	
InceptionV3	Color	99.590%	99.590%	99.576%	99.580%	253.40
	Gray	100.000%	100.000%	100.000%	100.000%	
MobileNet	Color	99.180%	99.194%	99.153%	99.160%	38.70
	Gray	100.000%	100.000%	100.000%	100.000%	
Xception	Color	99.590%	99.590%	99.576%	99.580%	242.00
	Gray	100.000%	100.000%	100.000%	100.000%	

ตารางที่ 3 ผลการวิเคราะห์ประสิทธิภาพโมเดล

Model	Image Color	Accuracy	Efficiency
DenseNet121	Color	99.592%	0.410%
	Gray	100.000%	
MobileNet	Color	99.183%	0.824%
	Gray	100.000%	



8. สรุปผล

หากพิจารณาถึงการประหยัดเวลาและค่าใช้จ่ายเป็นประเด็นสำคัญ ผลจากการศึกษานี้สามารถสรุปได้ว่า ควรเลือกใช้การประมวลผลภาพขาวดำ เพื่อลดค่าใช้จ่ายในการจัดหากำลังและเลือกใช้โมเดล MobileNet เพื่อพัฒนาต่อยอด สำหรับการสร้างสถานีงานอัตโนมัติที่ใช้สำหรับตรวจจับ และคัดแยกชิ้นงานที่บกพร่องหรือไม่เป็นไปตามมาตรฐานที่กำหนดออกจากสายการผลิต ยกตัวอย่างเช่น ในอุตสาหกรรมก๊อกร้า ที่ได้การทดสอบในครั้งนี้ รวมถึงอุตสาหกรรมอื่น ๆ ที่มีลักษณะใกล้เคียงกัน เพื่อช่วยในการลด ข้อผิดพลาดในการทำงานและยังช่วยในการประหยัดต้นทุนจากการผลิต เพราะชิ้นงานที่ไม่สมบูรณ์จะถูกคัดแยกออกก่อนสู่กระบวนการผลิตในสถานีต่อไป

9. ข้อเสนอแนะ

จากการศึกษานี้ มีประเด็นที่เป็นข้อเสนอแนะและประเด็นเกี่ยวกับข้อจำกัด ดังนี้

1) ในการศึกษา แม้จะสามารถวิเคราะห์เปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้แบบถ่ายโอนทั้ง 6 โมเดล จนสามารถสรุปได้ว่า MobileNet เป็นโมเดลที่เหมาะสมต่อการนำไปพัฒนาระบบอัตโนมัติเพื่อใช้งานในสายการผลิตมากที่สุด แต่การศึกษานี้ยังไม่ได้ทำการวิเคราะห์เชิงลึกเพื่อหาว่าเหตุใดโมเดลต่าง ๆ มีความแม่นยำแตกต่างกัน เนื่องจากอยู่นอกเหนือขอบเขตของการศึกษานี้ อย่างไรก็ตาม ประเด็นนี้ถือเป็นประเด็นที่มีความน่าสนใจ จึงควรมีการศึกษาวเคราะห์เพิ่มเติมต่อไปในอนาคต

2) แนวคิดนี้สามารถนำไปขยายผลกับเครื่องจักรในสายการผลิตได้ โดยอาจประยุกต์ใช้ร่วมกับแขนกลที่ทำหน้าที่ตรวจจับและหยิบจับชิ้นงานงานที่บกพร่องหรือมีตำหนิที่เสี่ยงไปบนสายพานลำเลียงออก เพื่อเพิ่มประสิทธิภาพโดยรวมหรือ OEE ของสายการผลิต ก๊อกร้าในโรงงาน อย่างไรก็ตามจำเป็นต้องศึกษาวิจัยเพิ่มเติมเพื่อพิสูจน์ประเด็นนี้ต่อไปในโครงการวิจัยที่คาดว่าจะดำเนินการในอนาคตอันใกล้

3) หากมีการนำไปพัฒนาต่อยอดเพื่อใช้งานจริงในอุตสาหกรรม อาจพบข้อจำกัดเรื่องความสว่างของแสงและการสั่นสะเทือนของเครื่องจักรในบริเวณสถานีงาน ซึ่งอาจทำให้ได้ภาพถ่ายชิ้นงานที่มีคุณภาพต่ำ ซึ่งจะส่งผลกระทบต่อความแม่นยำของโมเดลได้

4) แม้ว่าผลจากการศึกษานี้จะชี้ว่าโมเดล Mobilenet จะเป็นตัวเลือกที่เหมาะสมที่สุดสำหรับการตรวจจับ ก๊อกร้าที่มีข้อบกพร่องในสายการผลิตจากการประมวลผลภาพขาวดำ เนื่องจากมีค่าความแม่นยำ 100% และมีขนาดของโมเดลเล็กที่สุด แต่ความแม่นยำอาจลดลงหากดำเนินการกับชุดข้อมูลภาพอื่นจากงานลักษณะอื่นหรืออุตสาหกรรมอื่น จึงควรศึกษาและทดสอบกับชุดข้อมูลใหม่ทุกครั้งก่อนนำไปใช้งานในบริบทอื่น นอกจากนี้โมเดลอื่นๆ ก็ควรได้รับการพิจารณาใหม่ด้วย

7. กิตติกรรมประกาศ

ขอขอบคุณมหาวิทยาลัยเซาธ์อีสท์บางกอก มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ วิทยาเขตวังไกลกังวล มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร และบริษัท อาซาฮีไทย อัลลอย จำกัด



8. เอกสารอ้างอิง

- [1] A. Piyasinchart, P. Boonpoor, T. Thammachai and T. Daengsi, Detection of defects in work-in-process products using deep learning: A case of a water tap production line, 6th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), Proceeding, 2023, 369-372.
- [2] A. Piyasinchart, P. Sirawongphatsara, P. Boonpoor, N. Chantasen and T. Daengsi, Improving water tap production lines: A proof of concept for deep learning-based defect detection system development, *Journal of Applied Information Technology*, 2024, 10(1), 8-21.
- [3] T. Daengsi, K. Cheevanichapan, U. Soteyome and T. Thimthong, Irrigation management: A pilot study for automatic water level measurement and report system development using machine learning associated with modified images, 5th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), Proceeding, 2022, 543-547.
- [4] K.G. Dhal, A. Das, J. Gálvez, S. Ray, and S. Das, An overview on nature-inspired optimization algorithms and their possible application in image processing domain, *Pattern Recognition and Image Analysis*, 30, 2020, 614–631.
- [5] T. Benjawilaikul and T. Kaewwichit, Classification of carbon steels by automated spark test technique using feature extraction based on machine learning image processing, *The Journal of Industrial Technology*, 2022, 18(2), 203-216.
- [6] C. Rattanapoka, P. Jannet and T. Moonpanyo, A service system for estimation of gender and assessing the person's age from facial images by deep learning-based method, *The Journal of Industrial Technology*, 2022, 18(2), 165-179.
- [7] M.Y. Ansari and M. Qaraqe, MEFood: A large-scale representative benchmark of quotidian foods for the middle east, *IEEE Access*, 2023, 11, 4589-4601.
- [8] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu and H. Zhu, A Comprehensive Survey on Transfer Learning, *Proceedings of the IEEE*, 2021, 109(1), 43-76.
- [9] J. Yang, Z. Zeng, K. Wang, H. Zou, and L. Xie, GarbageNet: A Unified learning framework for robust garbage classification, *IEEE Transactions on Artificial Intelligence*, 2021, 2(4), 372–380.
- [10] B. Fu, S. Li, J. Wei, Q. Li, Q. Wang and J. Tu, A novel intelligent garbage classification system based on deep learning and an embedded linux system, *IEEE Access*, 2021, 9, 131134–131146.



- [11] S. Chatterjee, D. Hazra, and Y.-C. Byun, IncepX-ensemble: performance enhancement based on data augmentation and hybrid learning for recycling transparent PET bottles, *IEEE Access*, 2022, 10, 52280–52293.
- [12] P. Boonpoor, P. Wuttidittachotti, K. Puangnak, T. Thimthong and T. Daengsi, Accuracy improvement of transfer learning using hybrid approach: a case study of imbalanced Thai food image classification, 2023 International Conference on Artificial Intelligence, Blockchain, Cloud Computing, and Data Analytics (ICoABCD), *Proceeding*, 2023, 48-52,
- [13] R. R. Subramanian, M. Lakshmi, M. Lavanya, M. K. G. Roy and M. C. Manvitha, Detecting defects in manufacturing process using deep learning models, 4th International Conference on Data Engineering and Communication Systems (ICDECS), *Proceeding*, 2024, 1-6.
- [14] M. I. Faiz Mohd Derafi, S. F. Abdul Razak and M. S. Sayeed, Banana disease classification using transfer learning, *IEEE Symposium on Industrial Electronics and Applications (ISIEA), Proceeding*, 2024, 1-7.
- [15] T. Daengsi, P. Boonpoor, K. Puangnak, P. Pholchanngam, P. Wuttidittachotti and P. Unahalekhaka, Comparison of impacts from color-based and geometric augmentations for deep learning: A case of Thai food images, *IEEE 14th Symposium on Computer Applications and Industrial Electronics (ISCAIE), Proceeding*, 2024, 1-5.