

**การตรวจสอบคุณภาพของถุงปูนด้วยวิธีการประมวลผลภาพ
โดยใช้โครงข่ายประสาทเทียมคอนโวลูชัน: กรณีศึกษากระบวนการ
ผลิตถุงปูนซีเมนต์**

**THE QUALITY DETECTION OF CEMENT BAGS BY USING IMAGE
PROCESSING WITH CONVOLUTIONAL NEURAL NETWORKS
CASE STUDY OF A MANUFACTURE PRODUCTION LINE OF
CEMENT BAGS**

วัชรชัย คงศิริวัฒนา* และสรัญญา สว่างศรี

Watcharachai Kongsiriwattana* and Sarunya Sawangsri

ภาควิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีและการจัดการอุตสาหกรรม

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ วิทยาเขตปทุมธานี

Department of Information Technology, Faculty of Industrial Technology and Management,

King Mongkut's University of Technology North Bangkok Prachinburi Campus

*corresponding author e-mail: watcharachai.k@fitm.kmutnb.ac.th

(Received: 3 March 2020; Revised: 12 April 2020; Accepted: 17 April 2020)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการเรียนรู้เครื่องจักรในการตรวจและแยกคุณภาพถุงปูนบนสายการผลิต ประกอบด้วย 3 แบบจำลอง คือ 1) แบบจำลองตรวจสอบถุงปูนตัวอักษร เครื่องหมายการค้าขาดหายและสีไม่คมชัด 2) แบบจำลองตรวจสอบถุงปูนตัวอักษรและเครื่องหมายการค้าขาดหาย และ 3) แบบจำลองตรวจสอบแนวการของถุงปูน ซึ่งใช้วิธีประมวลผลภาพโดยใช้โครงข่ายประสาทเทียมคอนโวลูชัน (CNN) และโครงข่ายประสาทเทียม VGG 16 โดยใช้ภาษาไพธอนในการตรวจสอบรูปภาพของถุงปูน กำหนดการศึกษาปัญหาที่เกิดขึ้น ซึ่งมีรายละเอียดในการพิจารณา 3 กรณี ได้แก่ กรณีถุงปูนแบบที่ 1 พิจารณาที่ตัวอักษรและเครื่องหมายการค้าของถุงปูน กล่าวคือ ตัวอักษรและเครื่องหมายการค้าขาดหายและสีไม่คมชัด กรณีถุงปูนแบบที่ 2 พิจารณาที่ตัวอักษรไม่สมบูรณ์และเครื่องหมายการค้าขาดหาย และกรณีถุงปูนแบบที่ 3 พิจารณาการตรวจสอบแนวการของถุงปูนที่ไม่ต่อเนื่องกัน จากนั้นทำการเก็บข้อมูลรูปภาพถุงปูนในกระบวนการผลิต และทำการพัฒนาแบบจำลองโดยใช้ภาษาไพธอน ผลการทดสอบ พบว่าแบบจำลองตรวจสอบถุงปูนแบบที่ 1 สามารถทำการตรวจสอบรูปถุงปูนที่สมบูรณ์ได้มีค่า F1-Score

95% และรูปถุงปูนที่ไม่สมบูรณ์มีค่า F1-Score 92% ขณะที่แบบจำลองตรวจสอบถุงปูนแบบที่ 2 การตรวจสอบรูปถุงปูนที่สมบูรณ์และไม่สมบูรณ์มีค่า F1-Score 100% และแบบจำลองการตรวจสอบแนวกาวที่มีการตรวจสอบแนวกาวที่สมบูรณ์และไม่สมบูรณ์มีค่า F1-Score 100% ตามลำดับ

คำสำคัญ: การประมวลผลภาพ โครงข่ายประสาทเทียมคอนโวลูชัน การเรียนรู้เครื่องจักร

Abstract

The objective of this research aims to apply a machine learning model to detect and separate the quality of cement paper bags on the production line manufacture process. There are three proposed models to implement including 1) model for checking the unqualified and blurred trademark on cement paper bags, 2) model for checking incomplete letter and trademark on cement paper bags and 3) model for detecting unclear adhesive of the cement paper bag valve. This study has applied a convolutional neural network (CNN) and VGG 16, based on python programming language, to learn the types of an image from cement paper bags. There are three scenarios to consider in this study. The first scenario focuses on a letter and trademark on a cement paper bag, which is blurred and incomplete. The second scenario only pays attention to an incomplete letter and trademark. The third scenario considers unclear adhesive of the cement paper bag valve. The image of cement paper bags on the production line manufacture process was collected and the Python language programming was selected to implement proposed models. The results of this research revealed that the first scenario shows F1-Score 95% for qualified cement paper bags and F1-Score 92% for unqualified cement paper bags, the second scenario shows F1-Score 100%, and the third scenario shows F1-Score 100% for qualified and unqualified cement paper bags, respectively.

Keywords: Image processing, Convolutional neural network, Machine learning


บทนำ

ในปัจจุบันรัฐบาลมีการส่งเสริมนโยบาย Thailand 4.0 โมเดลเศรษฐกิจที่ขับเคลื่อนด้วยความคิดสร้างสรรค์ นวัตกรรม เทคโนโลยี และการบริการระดับสูง เพื่อผลักดันการเติบโตของรายได้ในประเทศให้สูงขึ้นภายใน 5 ปี (พ.ศ. 2560 – 2564) ดังนั้น Thailand 4.0 จึงเป็นแนวทาง

ในการพัฒนาเศรษฐกิจของประเทศที่สำคัญ (จิตรลดา และสุพัตรา, 2560) ซึ่งทำให้บริษัทผลิตถุงปูนในกรณีศึกษาจำเป็นต้องมีการปรับตัวตามนโยบายรัฐบาล หนึ่งในโรงงานผลิตถุงปูน มีอัตราการผลิตถุงปูน ประมาณ 300 ถุงต่อนาที จัดเรียงเป็นตั่งๆ ละ 50-60 ใบ ผลิตกะละ 1,920 ตั่ง วิธีตรวจจสอบใช้คนในการตรวจจสอบ 3 ตั่งแรกของการเริ่มเดินเครื่อง หลังจากนั้นจะใช้พนักงานสุ่มตรวจตั่งละ 1 ใบ ทำให้มีโอกาสที่จำนวนของถุงปูนที่ไม่ได้มาตรฐานถูกส่งไปยังขั้นตอนการบรรจุถุงลงถุงปูน ก่อให้เกิดความเสียหายในกระบวนการผลิตได้ จึงเป็นที่มาทำให้บริษัทดังกล่าวต้องการพัฒนาการตรวจจสอบถุงปูนในกระบวนการผลิตให้สอดคล้องกับนโยบาย Thailand 4.0 ที่มุ่งเน้นการทำงานแบบอัตโนมัติ และแนวคิดของการเรียนรู้เครื่องจักร (Machine learning) รวมถึงปัญญาประดิษฐ์ (Artificial intelligence)

โครงข่ายประสาทเทียม (Artificial neural network) เป็นระบบที่พัฒนาขึ้นโดยใช้แบบจำลองทางคณิตศาสตร์เลียนแบบการทำงานของสมองจำลองให้เหมือนกระบวนการเรียนรู้ของมนุษย์ (Russell et al., 2010) โดยมีเทคนิคกระบวนการสร้างความคิด เรียกว่า โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional neural network: CNN) ซึ่งมีความเหมาะสมสำหรับข้อมูลเชิงพื้นที่ การรู้จำวัตถุ และการวิเคราะห์ภาพโดยใช้โครงสร้างเซลล์ประสาทแบบหลายมิติ (Multidimensional neurons structures) (Adege et al., 2018; Behnke, 2003) นอกจากนี้ CNN และโครงข่ายประสาทเทียม VGG 16 (Visual geometry group: VGG 16) ได้ถูกนำมาประยุกต์สำหรับงานตรวจสอบและคัดแยกกล่องเหล็กที่มีข้อบกพร่องในกระบวนการผลิตแบบอัตโนมัติ (Essid et al., 2018) และงานวิจัยของ Jian et al. (2017) ได้นำมาประยุกต์เพื่อการตรวจสอบกระบวนการผลิตของหน้าจอโทรศัพท์มือถือที่มีข้อบกพร่อง เช่น รอยขีดข่วนระหว่างการผลิต โดยทั้งสองงานวิจัยแสดงให้เห็นถึงความสามารถของ CNN และ VGG 16 ในการนำมาวิเคราะห์ภาพที่มีความแตกต่างกัน เปรียบเทียบกับวิธีการอื่นๆ เช่น Support vector machine: SVM Single layer neural network และ Random forest: RF ซึ่ง CNN และ VGG 16 ให้ผลลัพธ์ที่ดีกว่า (มนัสกานต์, 2559) ได้ใช้แนวคิดของ CNN ทำนายอายุการใช้งานคงเหลือของเครื่องจักรในโรงงานและโรงไฟฟ้า รวมถึงใช้โครงข่าย VGG แบบจำลองโครงข่ายคอนโวลูชันสำหรับการรู้จำภาพ ถูกพัฒนาโดย Simonyan & Zisserman ซึ่งโครงข่าย VGG นี้มีความแม่นยำในการทดสอบสูงติดอันดับ 5 อันดับแรกด้วยความแม่นยำ เท่ากับ 92.7% ในคลังข้อมูลภาพขณะที่สถาปัตยกรรมของโครงข่าย VGG 16 ประกอบด้วย ชั้นคอนโวลูชัน จำนวน 16 ชั้น มีคอนโวลูชันตัวกรองแบบ 3x3 กับการก้าวข้าม (Stride) ที่ 1 ในชั้นคอนโวลูชันและใช้การเพิ่มเติม (Padding) เดียวกับชั้นพูลลิง (Pooling) ขนาด 2x2 กับการก้าวข้ามที่ 2 รวมถึงมีตัวกรอง (Filter) เพิ่มมากขึ้น ดังภาพที่ 1 ซึ่งแสดงโครงสร้างของ VGG 16 (Simonyan & Zisserman, 2014) เป็นการยกตัวอย่างชั้นภาพการนำเข้าที่มีขนาด 224x224x3 และใช้ชั้นคอนโวลูชัน ขนาด 3x3 ซ้อนกันบริเวณด้านบนในแต่ละชั้นในความลึกที่เพิ่มขึ้น ซึ่งมีชั้นผลลัพธ์เป็นการคาดการณ์ค่าสูงสุดซอฟต์แวร์แมกซ์ (Softmax) ใน 1,000 ชุดข้อมูล

แบบประเภท และมีชั้นเชื่อมต่อกันทั้งหมดถึง จำนวน 2 ชั้น แต่ละชั้นมี จำนวน 4,096 เพอร์เซ็ปตรอนตามด้วยชั้นแมกพูลลิง (Max pooling) ซึ่งมีหน้าที่ในการลดขนาดและถูกติดป้ายกำกับโดยมีขนาด $7 \times 7 \times 512$ ถือว่าเป็นส่วนของการตัดแยกคุณลักษณะของแบบจำลอง ซึ่งสอดคล้องกับงานวิจัยของ นพวัชร (2560) ที่ได้ใช้แนวคิด VGG 16 สำหรับการตรวจจับหน้าตัดของปลายท่อนซุงที่อยู่ในภาพถ่ายท้ายรถบรรทุกไม้ยูคาลิปตัส เพื่อแยกและนับหน้าตัดปลายท่อนซุง ดังนั้นโครงข่าย VGG 16 จึงเป็นทางเลือกที่ดีสำหรับงานในด้านการตัดแยกคุณลักษณะจากภาพ ซึ่งจากงานวิจัยดังกล่าวข้างต้นทำให้ทราบว่า CNN และ VGG 16 นั้นมีการใช้งานอย่างแพร่หลายและมีความเหมาะสมกับแบบจำลองสำหรับงานวิจัยนี้ที่มีความต้องการในการตรวจสอบตัวอักษรและเครื่องหมายการค้าที่ค่อนข้างละเอียด และนอกจาก CNN และ VGG 16 จะเป็นโครงข่ายการเรียนรู้พื้นฐานที่เป็นที่นิยมแล้ว มีความสามารถในการตรวจสอบภาพได้อย่างละเอียดในระดับที่ยอมรับได้ มีอัตราการผิดพลาด (Error rate) เท่ากับ 7.3% ในกรณี VGG 16 ซึ่งน้อยกว่าเมื่อเปรียบเทียบกับเทคนิค AlexNet ที่มีอัตราการผิดพลาด 15.3% (Khan et al., 2019) นอกจากนี้ยังสามารถพัฒนาร่วมกับภาษา Python ซึ่งสะดวกต่อการโปรแกรมและการทดสอบหาผลลัพธ์ของแบบจำลอง




ภาพที่ 1 โครงข่ายประสาทเทียม VGG 16

ดังนั้นผู้วิจัยจึงได้ทำการพัฒนาแบบจำลองบนพื้นฐานการทำงานโดยใช้ CNN และ VGG 16 ที่ให้ผลลัพธ์ของค่าความแม่นยำการตรวจสอบความแตกต่างของภาพใกล้เคียง 1.0 หรือ 100% มาสร้างแบบจำลองตรวจสอบถุงปูน 3 แบบ ประกอบด้วย แบบที่ 1 เป็นแบบจำลองตรวจสอบถุงปูนตัวอักษร เครื่องหมายการค้าขาดหายและสีไม่คมชัด โดยใช้รูปภาพถุงปูนที่สมบูรณ์ 1,150 รูป และถุงปูนที่ไม่สมบูรณ์ 796 รูป ขณะที่แบบจำลองตรวจสอบถุงปูนแบบที่ 2 เป็นแบบจำลองตรวจสอบถุงปูนตัวอักษรและเครื่องหมายการค้าขาดหาย โดยใช้รูปภาพถุงปูนที่สมบูรณ์ 409 รูป และถุงปูน

ที่ไม่สมบูรณ์ 409 รูป และแบบจำลองตรวจสอบถุงปูนแบบที่ 3 เป็นแบบจำลองตรวจสอบแนวการโดยใช้รูปภาพแนวการที่สมบูรณ์ 455 รูป และแนวการที่ไม่สมบูรณ์ 442 รูป มาเป็นข้อมูลในการพัฒนาแบบจำลองเพื่อการพยากรณ์คำตอบของถุงปูนที่อยู่ในกระบวนการผลิต ซึ่งการพัฒนาแบบจำลองทั้ง 3 แบบ จะมีการนำภาพเข้าที่ใช้ในการพัฒนาแบบจำลองมาสร้างเป็นไฟล์ภาพไบนารีและนำไฟล์เข้าสู่ CNN เพื่อพัฒนาเป็นแบบจำลองในการแยกคุณภาพถุงปูน และเพื่อเป็นแนวทางสำหรับหน่วยงานผลิตถุงปูนในการนำแบบจำลองดังกล่าวไปพัฒนาระบบการคัดแยกถุงปูนที่ไม่สมบูรณ์ออกจากกระบวนการผลิตถุงปูน โดยปราศจากการใช้พนักงานผู้ตรวจสอบอีกต่อไป

วิธีดำเนินการวิจัย

1. การสร้างไฟล์สำหรับการเรียนรู้ นำภาพถุงปูนมาสร้างเป็นภาพที่มีค่าความเข้มเท่ากับ 0 และ 1 ในแต่ละจุดภาพเท่านั้น และมีขนาด 1 บิตต่อจุดภาพ ดังภาพที่ 2 ที่เป็นการแสดงภาพรวมของการทำงานตั้งแต่เริ่มต้นจนสิ้นสุด โดยมีการนำภาพนำเข้าเพื่อการเรียนรู้ และทำการสร้างเป็นภาพไบนารี จากนั้นตรวจสอบโดยใช้วิธีการ CNN เพื่อแยกประเภทรูปภาพ และหาผลลัพธ์ในท้ายที่สุด ซึ่งแบบจำลองทั้ง 3 แบบ จะถูกดำเนินการในแนวทางเดียวกัน



ภาพที่ 2 แผนภาพแสดงภาพรวมการดำเนินงาน

1.1 แบบจำลองตรวจสอบถุงปูนแบบที่ 1 คือ ชุดข้อมูลภาพขนาด 640x480x3 และนำมาแปลงภาพเป็นเมทริกซ์ เป็นไฟล์นามสกุล Pickle เพื่อเตรียมในขั้นตอนการแยกประเภทถุงปูนโดยเป็นข้อมูลรูปภาพที่เก็บจากกระบวนการผลิต ในการดำเนินงานนี้ทำบนข้อมูลทั้งหมด 2 ชุด ได้แก่ ชุดข้อมูลสำหรับการเรียนรู้ 1 ชุด และชุดข้อมูลสำหรับทดสอบ 1 ชุด โดยชุดข้อมูลสำหรับการเรียนรู้จะถูกแบ่งออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลภาพที่สมบูรณ์ ดังภาพที่ 3 ที่เป็นตัวอย่างภาพที่สมบูรณ์ของแบบจำลองแบบที่ 1 ประกอบด้วย ตัวอักษรที่มีสีที่ชัดเจนและสมบูรณ์ สัญลักษณ์เครื่องหมายการค้าชัดเจน และชุดข้อมูลภาพที่ไม่สมบูรณ์ ดังภาพที่ 4 ที่เป็นตัวอย่างภาพที่ไม่สมบูรณ์ของแบบจำลองแบบที่ 1 ประกอบด้วย ตัวอักษรที่ไม่สมบูรณ์ สีไม่ชัดเจน และสัญลักษณ์เครื่องหมายการค้าไม่ชัดเจน



ภาพที่ 3 ตัวอย่างรูปถุงปูนที่สมบูรณ์ของแบบจำลองแบบที่ 1



ภาพที่ 4 ตัวอย่างรูปถุงปูนที่ไม่สมบูรณ์ของแบบจำลองแบบที่ 1

1.2 แบบจำลองตรวจสอบถุงปูนแบบที่ 2 คือ ชุดข้อมูลภาพขนาด 510x14x3 และนำมาแปลงภาพเป็นเมทริกซ์เป็นไฟล์นามสกุล Pickle เพื่อเตรียมในขั้นตอนการแยกประเภทถุงปูน

โดยในการดำเนินงานนี้ทำบนข้อมูลทั้งหมด 2 ชุด ได้แก่ ชุดข้อมูลสำหรับการเรียนรู้ 1 ชุด และชุดข้อมูลสำหรับทดสอบ 1 ชุด ซึ่งชุดข้อมูลสำหรับการเรียนรู้ แบ่งออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลภาพที่สมบูรณ์ ดังภาพที่ 5 ที่เป็นตัวอย่างภาพที่สมบูรณ์ของแบบจำลองแบบที่ 2 ประกอบด้วย ตัวอักษรสมบูรณ์ สัญลักษณ์เครื่องหมายการค้าชัดเจน และชุดข้อมูลภาพที่ไม่สมบูรณ์ ดังภาพที่ 6 ที่เป็นตัวอย่างภาพที่ไม่สมบูรณ์ของแบบจำลองแบบที่ 2 ประกอบด้วย ตัวอักษรที่ไม่สมบูรณ์และสัญลักษณ์เครื่องหมายการค้าไม่ชัดเจน



ภาพที่ 5 ตัวอย่างรูปทรงปูนที่สมบูรณ์ของแบบจำลองแบบที่ 2




ภาพที่ 6 ตัวอย่างรูปทรงปูนที่ไม่สมบูรณ์ของแบบจำลองแบบที่ 2

ภาพตัวอย่างรูปทรงปูนที่ไม่สมบูรณ์แบบที่ 1 และแบบที่ 2 ดังภาพที่ 4 และภาพที่ 6 เป็นตัวอย่างกรณีศึกษาที่เกิดขึ้นบ่อยครั้งในกระบวนการผลิตรูปปูนในสถานประกอบการที่ทำการวิจัย ซึ่งโดยปกติจะเกิดเหตุการณ์ของความไม่สมบูรณ์ของภาพในลักษณะดังกล่าวเสมอ คือ ตัวอักษรที่ไม่สมบูรณ์ ตัวอักษรสีไม่ชัดเจน และสัญลักษณ์เครื่องหมายการค้าไม่ชัดเจน ดังนั้นการระบุเป็นเปอร์เซ็นต์ของความผิดพลาดในแต่ละประเภทของเหตุการณ์ไม่สามารถทำได้ ผู้วิจัยจึงแบ่งประเภทของกลุ่มที่มักเกิดขึ้นพร้อมกันเป็นรูปทรงปูนที่ไม่สมบูรณ์แบบที่ 1 และแบบที่ 2 ตามลำดับ

1.3 แบบจำลองตรวจสอบแนวการ คือ ชุดข้อมูลภาพขนาด 997x250x3 และนำมาแปลงภาพเป็นเมทริกซ์แปลงเป็นไฟล์นามสกุล Pickle เพื่อเตรียมในขั้นตอนการแยกประเภทรูปปูน โดยในการดำเนินงานนี้ทำบนข้อมูลทั้งหมด 2 ชุด ได้แก่ ชุดข้อมูลสำหรับการเรียนรู้ 1 ชุด และชุดข้อมูลสำหรับทดสอบ 1 ชุด ซึ่งชุดข้อมูลสำหรับการเรียนรู้ แบ่งออกเป็น 2 ชุดด้วยกัน ได้แก่ ชุดข้อมูลภาพที่สมบูรณ์ ดังภาพที่ 7 ที่เป็นตัวอย่างภาพแนวการที่สมบูรณ์ ประกอบด้วย แนวการที่ชัดเจนตลอดทั้งแนว โดยไม่มีรอยขาดหรือมีสิ่งผิดปกติใดๆ และชุดข้อมูลภาพที่ไม่สมบูรณ์ ดังภาพ

ที่ 8 ที่เป็นตัวอย่างภาพแนวการที่ไม่สมบูรณ์ ประกอบด้วย แนวการที่ไม่ต่อเนื่องตลอดทั้งแนว มีรอยขาดปรากฏให้เห็นได้ชัด



ภาพที่ 7 ตัวอย่างรูปทรงปูนด้านแนวการที่สมบูรณ์



ภาพที่ 8 ตัวอย่างรูปทรงปูนด้านแนวการที่ไม่สมบูรณ์

2. การแยกประเภทรูปทรงปูน จำเป็นต้องมีการสร้างการเรียนรู้ และการทดสอบให้กับแบบจำลอง ซึ่งจะมีการสอนและทดสอบแบบจำลองอยู่ 3 ประเภท ดังนี้

2.1 การสอนแบบจำลองตรวจสอบรูปทรงปูน

2.1.1 การสอนแบบจำลองตรวจสอบรูปทรงปูนแบบที่ 1 โดยเลือกชุดข้อมูลภาพรูปทรงปูนที่สมบูรณ์ 1,150 รูป และรูปทรงปูนที่ไม่สมบูรณ์ 796 รูป โดยสอนกับอัลกอริทึม (Algorithm) CNN 23 Layer กำหนดขนาดแต่ละรุ่น (Batch size) เท่ากับ 50 จำนวนรอบการเรียนรู้ 10 รอบ ฟังก์ชันกระตุ้น คือ ReLu และ Softmax การหาค่าที่เหมาะสมที่สุด (Optimizer) คือ Adam ซึ่งจะหยุดการเรียนรู้เมื่อแบบจำลองมีความคลาดเคลื่อนบนชุดข้อมูลการเรียนรู้ไม่มีแนวโน้มเพิ่มขึ้นหรือมีค่าคงที่ สาเหตุที่ใช้แบบจำลอง CNN 23 Layer เพียงแบบจำลองเดียวเนื่องจากทำการทดสอบโดยเพิ่มขนาด และลดขนาดจำนวน Layer ปรับค่าพารามิเตอร์ในฟังก์ชันกระตุ้น และค่า Optimizer ประเภทต่างๆ แล้ว รวมถึงทดลองเทียบกับแบบจำลองมาตรฐาน VGG 16 ก็ยังไม่ได้ผลลัพธ์ค่าความแม่นยำ (Accuracy) ที่ใกล้เคียง 1.00 เหมือนกับ CNN 23 Layer รายละเอียดของผลลัพธ์อยู่ในส่วนของผลการวิจัย

2.1.2 การสอนแบบจำลองตรวจสอบรูปทรงปูนแบบที่ 2 ชุดข้อมูลภาพรูปทรงปูนที่สมบูรณ์ 409 รูป และรูปทรงปูนที่ไม่สมบูรณ์ 409 รูป โดยใช้ Algorithm ในการสอนแบบจำลอง 3 แบบ ดังนี้

1) **CNN 23 Layer** กำหนดขนาดแต่ละรุ่น เท่ากับ 50 และจำนวนรอบการเรียนรู้ 100 รอบ ฟังก์ชันกระตุ้น คือ ReLu และ Softmax การหาค่าเหมาะสมที่สุด ใช้เทคนิค Adaptive moment estimation: adam เพื่อปรับอัตราการเรียนรู้ของพารามิเตอร์ ใน Training set

2) **CNN 12 Layer** กำหนดขนาดแต่ละรุ่น เท่ากับ 128 และจำนวนรอบการเรียนรู้ 100 รอบ ฟังก์ชันกระตุ้น คือ ReLu LeakyReLU และ Softmax การหาค่าเหมาะสมที่สุด คือ adam

3) **VGG 16** กำหนดขนาดแต่ละรุ่นเท่ากับ 16 จำนวนรอบการเรียนรู้ 100 รอบ ฟังก์ชันกระตุ้น คือ ReLu และ Softmax การหาค่าเหมาะสมที่สุด จะใช้เทคนิค Stochastic gradient descent: SGD คือ อัลกอริทึมในการอัปเดตพารามิเตอร์ใน Training set

โดยสาเหตุที่การสอนแบบจำลองตรวจสอบถุงปูนแบบที่ 1 และแบบที่ 2 มีรายละเอียดที่แตกต่างกัน เนื่องจาก CNN 23 Layer ของแบบจำลองตรวจสอบถุงปูนแบบที่ 2 ให้ค่า Accuracy ที่ต่ำกว่า 1.00 ค่อนข้างมาก ทำให้มีการปรับแบบจำลองเป็น CNN 12 Layer แทน และใช้ตัวแบบจำลองมาตรฐาน VGG 16 เป็นตัวทดสอบอ้างอิงอีกครั้งหนึ่ง ซึ่งได้ค่า Accuracy เท่ากับ 0.8 รายละเอียดของผลลัพธ์อยู่ในส่วนของผลการวิจัย

2.1.3 แบบจำลองตรวจสอบแนวการ เป็นชุดข้อมูลภาพถุงปูนที่สมบูรณ์ 455 รูป และถุงปูนที่ไม่สมบูรณ์ 442 รูป โดยใช้ Algorithm ในการสอนแบบจำลอง 2 แบบ ดังนี้

1) **CNN 12 Layer (Enhanced)** เป็นการปรับปรุงประสิทธิภาพของ CNN 12 Layer ที่ใช้ในแบบจำลองตรวจสอบถุงปูนแบบที่ 2 โดยกำหนดขนาดแต่ละรุ่น เท่ากับ 16 จำนวนรอบการเรียนรู้ 150 รอบ ฟังก์ชันกระตุ้น คือ ReLu และ Softmax การหาค่าเหมาะสมที่สุด คือ SGD

2) **VGG 16** กำหนดขนาดแต่ละรุ่น เท่ากับ 16 จำนวนรอบการเรียนรู้ 100 รอบ ฟังก์ชันกระตุ้น คือ ReLu และ Softmax การหาค่าเหมาะสมที่สุด คือ SGD

การไม่เลือกใช้ CNN 23 Layer และ CNN 12 Layer ในการสอนแบบจำลองเหมือนกับแบบจำลองถุงปูนแบบที่ 1 และแบบที่ 2 เนื่องจากแบบจำลองดังกล่าวให้ค่า Accuracy ที่ต่ำกว่า 1.00 ค่อนข้างมาก จึงทำการปรับมาใช้เป็น CNN 12 Layer (Enhanced) โดยปรับค่าพารามิเตอร์ในชั้นกระตุ้นเทียบเท่ากับ VGG 16 ซึ่งเป็นแบบจำลองมาตรฐาน ทำให้ผลลัพธ์ของ Accuracy ได้เท่ากับ 1.00 รายละเอียดของผลลัพธ์อยู่ในส่วนของผลการวิจัย

2.2 การทดสอบแบบจำลองตรวจสอบถุงปูน

2.2.1 การทดสอบแบบจำลองตรวจสอบถุงปูนแบบที่ 1 จะใช้แบบจำลองมาทดสอบกับชุดข้อมูลทดสอบ โดยทำการทดสอบบนชุดข้อมูลที่แบ่งมาจากชุดข้อมูลการเรียนรู้ ในอัตราส่วน 80 : 20 ซึ่งในชุดข้อมูลทดสอบมีรูปถุงที่สมบูรณ์ 237 รูป และรูปถุงปูนที่ไม่สมบูรณ์

153 รูป หลังจากนั้นทำการทดสอบกับแบบจำลองที่ได้จาก Algorithm CNN 23 Layer กับชุดข้อมูลที่ได้แบ่งไว้ตอนต้น

2.2.2 การทดสอบแบบจำลองตรวจสอบถุงปูนแบบที่ 2 ทำการทดสอบบนชุดข้อมูลที่แบ่งมาจากชุดข้อมูลการเรียนรู้ในอัตราส่วน 80 : 20 ซึ่งในชุดข้อมูลทดสอบมีรูปถุงปูนที่สมบูรณ์ 221 รูป และรูปถุงที่ไม่สมบูรณ์ 215 รูป หลังจากนั้นทำการทดสอบกับ Algorithm ทั้ง 3 แบบ ได้แก่ CNN 23 Layer CNN 12 Layer และ VGG 16 กับชุดข้อมูลที่ได้แบ่งไว้ตอนต้น

2.2.3 การทดสอบแบบจำลองตรวจสอบแนวการ ทำการทดสอบบนชุดข้อมูลที่แบ่งมาจากชุดข้อมูลการเรียนรู้ในอัตราส่วน 80 : 20 ซึ่งในชุดข้อมูลทดสอบมีรูปถุงปูนที่สมบูรณ์ 125 รูป และรูปถุงที่ไม่สมบูรณ์ 113 รูป หลังจากนั้นจะทำการทดสอบกับ Algorithm ทั้ง 2 แบบ ได้แก่ CNN 12 Layer (Enhanced) และ VGG 16 กับชุดข้อมูลที่ได้แบ่งไว้ตอนต้น

ทำการวิเคราะห์ชุดข้อมูลภาพใบนารี นามสกุลไฟล์ Pickle และข้อมูลคำตอบประเภทถุงปูน ซึ่งจะแบ่งเป็น 2 ประเภท คือ ถุงปูนที่สมบูรณ์และถุงปูนที่ไม่สมบูรณ์ และทำการศึกษาการเรียนรู้และการทดสอบแบบจำลองในการทดสอบแยกคุณภาพถุงปูนที่สมบูรณ์และไม่สมบูรณ์ของแบบจำลองตรวจสอบถุงปูนแบบที่ 1 และแบบที่ 2 และแบบจำลองตรวจสอบแนวการ โดยเริ่มจากภาพนำเข้าๆสู่กระบวนการประมวลผลการเรียนรู้ และผลลัพธ์ที่ได้ คือ คำตอบประเภทของถุงปูนซีเมนต์ โดยผลการเรียนรู้จะถูกแสดงออกมาในรูปของค่าความแม่นยำของแบบจำลองในภาพรวม (Accuracy) ความแม่นยำที่สนใจในส่วนการทำนาย (Precision) ความแม่นยำที่สนใจในส่วนของการเป็นจริง (Recall) และค่า F1-Score คือ ค่าเฉลี่ยของ Precision และ Recall ซึ่งควรมีค่ามากกว่า 0.80 ขึ้นไป และมีค่าใกล้ 1.00 ถือว่า สามารถเข้าสู่กระบวนการเลือกใช้ Algorithm ได้ต่อไป

ผลการวิจัย

1. ผลการทดลองการเรียนรู้และการทดสอบแบบจำลองตรวจสอบถุงปูนแบบที่ 1

จากผลการเรียนรู้ของโครงข่ายประสาทเทียมคอนโวลูชัน CNN 23 Layer ได้ค่า Accuracy ประมาณ 0.94 ในการเรียนรู้รอบที่ 10 และค่า Loss ซึ่งหมายถึง โอกาสการผิดพลาดเมื่อใช้แบบจำลองนี้ ประมาณ 0.20 ซึ่งค่า Accuracy มีค่าตามเกณฑ์ที่กำหนดไว้ คือ มากกว่า 0.80 และใกล้เคียง 1.00 จึงถือว่า CNN 23 Layer นี้สามารถใช้กับแบบจำลองตรวจสอบถุงปูนแบบที่ 1 ได้ จากนั้นทำการทดสอบโดยใช้ข้อมูลภาพใบนารีในการทดสอบ ผลการทำนายชุดข้อมูลทดสอบรูปถุงปูนที่สมบูรณ์ 237 รูป และรูปถุงปูนที่ไม่สมบูรณ์ 153 รูป โดยผลการทดลองภาพถุงปูนที่สมบูรณ์มีค่า Precision 91% ค่า Recall 100% และค่า F1-Score 95% และรูปถุงปูนที่ไม่สมบูรณ์มีค่า Precision 100% Recall 85% และค่า F1-Score 92% ดังตารางที่ 1

ตารางที่ 1 ผลการทดสอบตรวจสอบถุงปูนแบบที่ 1 โดยใช้ CNN 23 Layer

ข้อมูล	Precision	Recall	F1-Score
ถุงปูนที่ไม่สมบูรณ์	1.00	0.85	0.92
ถุงปูนที่สมบูรณ์	0.91	1.00	0.95

หมายเหตุ 0.85 = 85% 0.91 = 91% 0.92 = 92% 0.95 = 95% และ 1.00 = 100%

2. ผลการทดลองการเรียนรู้และการทดสอบแบบจำลองตรวจสอบถุงปูนแบบที่ 2

การทดลองกับโครงข่ายประสาทเทียมคอนโวลูชัน CNN 23 Layer CNN 12 Layer และ VGG 16 ตามลำดับ จากผลการทดลองพบว่า ผลการเรียนรู้ของ CNN 23 Layer ได้ค่า Accuracy ประมาณ 0.54 ในการเรียนรู้รอบที่ 70 และค่า Loss ประมาณ 0.69 ซึ่งเป็นค่าที่สูงมาก และค่า Accuracy มีค่าไม่ถึงเกณฑ์ที่กำหนดไว้ จึงถือว่า CNN 23 Layer นี้ไม่สามารถใช้กับแบบจำลองตรวจสอบถุงปูนแบบที่ 2 ได้ ส่วนผลการเรียนรู้ของ CNN 12 Layer ได้ค่า Accuracy ประมาณ 1.00 ในการเรียนรู้รอบที่ 100 และค่า Loss ประมาณ 0.00 ซึ่งค่า Accuracy มีค่าตามเกณฑ์ที่กำหนดไว้ จึงถือว่า CNN 12 Layer นี้สามารถใช้กับแบบจำลองตรวจสอบถุงปูนแบบที่ 2 ได้ และผลการเรียนรู้ของ VGG 16 ได้ค่า Accuracy ประมาณ 0.80 ในการเรียนรู้รอบที่ 100 และค่า Loss ประมาณ 0.50 ซึ่งค่า Accuracy มีค่าตามเกณฑ์ที่กำหนดไว้ จึงถือว่า VGG 16 นี้สามารถใช้กับแบบจำลองตรวจสอบถุงปูนแบบที่ 2 ได้

จากนั้นทำการทดสอบโดยใช้ข้อมูลภาพไบนารีในการทดสอบ จากการทดสอบชุดข้อมูลทดสอบรูปถุงปูนที่สมบูรณ์ 221 รูป และรูปถุงปูนที่ไม่สมบูรณ์ 215 รูป โดยทำการทดสอบทั้ง 2 Algorithm คือ CNN 12 Layer และ VGG 16 ผลการทดลองภาพถุงปูนที่สมบูรณ์มีค่า Precision ค่า Recall และค่า F1-Score 100% และรูปถุงปูนที่ไม่สมบูรณ์มีค่า Precision ค่า Recall และค่า F1-Score 100% ดังตารางที่ 2

ตารางที่ 2 ผลการทดสอบตรวจสอบถุงปูนแบบที่ 2 โดยใช้ทั้ง 2 Algorithm

Algorithm	ตัววัดผล	ถุงสมบูรณ์	ถุงไม่สมบูรณ์
CNN 12 Layer	Precision	1.00	1.00
	Recall	1.00	1.00
	F1-Score	1.00	1.00
VGG 16	Precision	1.00	1.00
	Recall	1.00	1.00
	F1-Score	1.00	1.00

หมายเหตุ 1.00 = 100%

3. ผลการทดลองการเรียนรู้และการทดสอบแบบจำลอง ตรวจสอบแนวทาง

3.1 CNN 12 Layer (Enhanced) ผลการเรียนรู้ของ CNN 12 Layer (Enhanced) ได้ค่า Accuracy ประมาณ 1.00 ในการเรียนรู้รอบที่ 150 และค่า Loss ประมาณ 0.00 ซึ่งค่า Accuracy มีค่าตามเกณฑ์ที่กำหนดไว้ จึงถือว่า CNN 12 Layer (Enhanced) นี้สามารถใช้กับแบบจำลองตรวจสอบแนวทางได้

3.2 VGG 16 ผลการเรียนรู้ของ VGG 16 ได้ค่า Accuracy ประมาณ 1.00 ในการเรียนรู้รอบที่ 200 และค่า Loss ประมาณ 0.00 ซึ่งค่า Accuracy มีค่าตามเกณฑ์ที่กำหนดไว้ จึงถือว่า VGG 16 นี้สามารถใช้กับแบบจำลองตรวจสอบแนวทางได้ ซึ่งทำการทดสอบโดยใช้ข้อมูลภาพใบนารีในการทดสอบ จากการทดสอบชุดข้อมูลทดสอบรูปถุงปูนที่สมบูรณ์ 125 รูป และรูปถุงปูนที่ไม่สมบูรณ์ 113 รูป โดยทำการทดสอบทั้ง 2 Algorithm คือ CNN 12 Layer (Enhanced) และ VGG 16 ผลการทดสอบภาพถุงปูนที่สมบูรณ์มีค่า Precision 99% ค่า Recall 100% และค่า F1-Score 100% และรูปถุงปูนที่ไม่สมบูรณ์มีค่า Precision 100% ค่า Recall 99% และค่า F1-Score 100% ดังตารางที่ 3

ตารางที่ 3 ผลการทดสอบตรวจสอบแนวทาง โดยใช้ทั้ง 2 Algorithm

Algorithm	ตัววัดผล	ถุงสมบูรณ์	ถุงไม่สมบูรณ์
CNN 12 Layer (Enhanced)	Precision	0.99	1.00
	Recall	1.00	0.99
	F1-Score	1.00	1.00
VGG 16	Precision	0.99	1.00
	Recall	1.00	0.99
	F1-Score	1.00	1.00

หมายเหตุ 0.99 = 99% และ 1.00 = 100%

อภิปรายผล

จากผลการศึกษาพบว่า แบบจำลองตรวจสอบถุงปูนแบบที่ 1 เลือกใช้ CNN 23 Layer ในการทดสอบความแม่นยำของ Algorithm จะใช้ค่า F1-Score พิจารณาค่าการวัดประสิทธิภาพโดยรวมของทั้งค่า Precision และค่า Recall โดยถุงปูนที่สมบูรณ์มีค่า 95% และถุงปูนที่ไม่สมบูรณ์ มีค่า 92% ขณะที่แบบจำลองตรวจสอบถุงปูนแบบที่ 2 ผลการทดสอบภาพถุงปูนที่สมบูรณ์และถุงปูนที่ไม่สมบูรณ์ได้ค่า Precision ค่า Recall และค่า F1-Score 100% ทั้งหมด ในการเลือกใช้ Algorithm จะใช้ค่า F1-Score คือ ค่าการวัดประสิทธิภาพโดยรวมทั้งค่า Precision และค่า Recall ซึ่งทั้งสองค่ามีค่าที่เท่ากัน จึงใช้รอบที่ใช้ในการเรียนรู้และขนาดของไฟล์แบบจำลองในการเลือกใช้ Algorithm ซึ่ง CNN 12 Layer

และ VGG 16 มีรอบในการเรียนรู้ที่เท่ากัน แต่ CNN 12 Layer มีขนาดโพลีโมเดลที่เล็กด้วยขนาด 159 MB สำหรับแบบจำลองตรวจสอบแนวทแยง ผลการดำเนินงานจัดทำแบบจำลองแนวทแยง ภาพที่ใช้เป็นตัวอย่างสำหรับการสอนใน CNN 12 Layer (Enhanced) และ VGG 16 มีข้อมูลภาพรูปวงปวงที่สมบูรณ์ 455 รูป และรูปวงปวงที่ไม่สมบูรณ์ 442 รูป และข้อมูลภาพสำหรับทดสอบรูปวงปวงที่สมบูรณ์ 125 รูป และรูปวงปวงที่ไม่สมบูรณ์ 113 รูป สามารถแยกรูปวงปวงแนวทแยงที่สมบูรณ์ได้โดยมีความแม่นยำ (Precision) 99% และระบบสามารถแยกรูปวงปวงแนวทแยงที่ไม่สมบูรณ์ได้โดยมีค่า Precision 100% งานวิจัยที่นำเสนอมีการใช้เทคนิค CNN Layer และ VGG ในการเรียนรู้และตรวจสอบภาพเป้าหมาย และใช้เทคนิคการป้องกันการเรียนรู้มากเกินไปด้วยวิธีดรอปเอาต์ (Dropout) รวมถึงการหาค่าเหมาะสมที่สุด เพื่อทำหน้าที่ในการปรับปรุงค่าน้ำหนักและค่าเบี่ยงเบนของเส้นเชื่อมในโครงข่ายประสาทเทียม สอดคล้องกับงานวิจัยของ นพวัชร (2560) และ มนัสกานต์ (2559) ในการทำนายอายุการใช้งานคงเหลือของเครื่องจักร และการตรวจจับภาพหน้าตัดของปลายท่อนซุงจากภาพถ่ายด้านท้ายรถบรรทุกไม้ยูคาลิปตัส ขณะที่งานวิจัยของ Li et al. (2018) ทำการตรวจสอบการผลิตของอุปกรณ์อิเล็กทรอนิกส์ที่มีความสมบูรณ์หรือมีข้อบกพร่องหรือไม่ ผ่านเทคนิค CNN Layer เช่นเดียวกัน แต่นำเทคโนโลยีของเครือข่ายก่อนแมช ทำงานร่วมกับ Fox computing และมีเซนเซอร์คอยตรวจจับอุปกรณ์อิเล็กทรอนิกส์ หากตรวจเจอข้อบกพร่องก็จะทำการแจ้งเตือนได้ทันที ซึ่งเมื่อเปรียบเทียบกันแล้ว งานวิจัยที่นำเสนอยังขาดขั้นตอนนี้อยู่ ดังนั้นเพื่อให้รองรับแนวคิด Thailand 4.0 ซึ่งเป็นการให้ความสำคัญกับ 10 อุตสาหกรรมเป้าหมาย หนึ่งในนั้น คือ ปัญญาประดิษฐ์ และเทคโนโลยีสมองกลฝังตัว การทำให้การทำงานของระบบตรวจสอบรูปวงปวงซีเมนต์บนรางการผลิตแบบอัตโนมัติครบวงจร จึงเป็นสิ่งที่ควรพิจารณา

สรุปผลการวิจัย

งานวิจัยนี้ได้นำเสนอแบบจำลองการแยกคุณภาพรูปวงปวงซีเมนต์ที่ได้คุณภาพและไม่ได้คุณภาพ โดยใช้ CNN และ VGG 16 ในการพัฒนาแบบจำลองทั้ง 3 แบบจำลอง ซึ่งให้ผลการทดสอบค่า Accuracy ของ Algorithm ที่เลือกใช้ต้องมีค่าอยู่ระหว่าง 0.80 – 1.00 ค่า Precision Recall และ F1-Score ในการแยกคุณภาพของรูปวงปวงที่สมบูรณ์ และไม่สมบูรณ์ อยู่ในช่วงระหว่าง 80 – 100% ดังนั้นแบบจำลองเหล่านี้จึงมีคุณสมบัติที่สามารถถูกนำไปประยุกต์ใช้เพื่อการพัฒนากระบวนการคัดแยกคุณภาพรูปวงปวงในกระบวนการผลิตรูปวงปวงซีเมนต์แบบอัตโนมัติผ่านกล้องวิดีโอความเร็วสูงได้ในขั้นตอนต่อไป โดยสามารถนำไปใช้เป็นแนวทางสำหรับการพัฒนาระบบการคัดแยกรูปวงปวงที่ไม่สมบูรณ์ออกจากกระบวนการผลิตที่มีประสิทธิภาพและลดขั้นตอนสู่ตรวจโดยพนักงานต่อไปในอนาคตได้

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับความร่วมมือจากบริษัท ปูนซีเมนต์ไทย (ท่าหลวง) จำกัด และได้รับเงินสนับสนุนในการนำเสนองานวิจัยจากคณะเทคโนโลยีและการจัดการอุตสาหกรรม มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ วิทยาเขตปราจีนบุรี

เอกสารอ้างอิง

- จิตรลดา พิศาลสุพงศ์ และสุพัตรา ศรีภูมิเพชร. (2560). **การพัฒนาวิทยาศาสตร์ เทคโนโลยี วิจัย และนวัตกรรม**. สืบค้นเมื่อ 5 มกราคม 2563, จาก <https://waa.inter.nstda.or.th/stks/pub/2018/20181106-st-research-innovation-development-strategy.pdf>
- นพวัชร ลำแดงเดช. (2560). **การตรวจจับหน้าตัดของปลายท่อนซุงจากภาพถ่ายด้านท้ายรถบรรทุกไม้ยุคาลิปตัส**. (วิทยานิพนธ์ปริญญาโทมหาบัณฑิต). จุฬาลงกรณ์มหาวิทยาลัย, คณะวิศวกรรมศาสตร์.
- มนัสกานต์ เสน่หา. (2559). **การทำนายอายุการใช้งานคงเหลือของเครื่องจักรด้วยเน็ตเวิร์กคอนโวลูชันเชิงลึกที่เพิ่ม**. (วิทยานิพนธ์ปริญญาโทมหาบัณฑิต). จุฬาลงกรณ์มหาวิทยาลัย, คณะวิศวกรรมศาสตร์.
- Adege, A. B., Yen, L., Lin, H. P., Yayah, Y., Li, Y. R., Jeng, S. S., & Berie, G. (2018, April). Applying Deep Neural Network (DNN) for large-scale indoor localization using feed-forward neural network (FFNN) algorithm. **Proceedings of the 2018 IEEE International Conference on Applied System Invention (ICASI)**, Japan, 814–817.
- Behnke, S. (2003). **Hierarchical neural networks for image interpretation**, Vol. 2766. New York: Springer.
- Essid, O., Laga, H., & Samir, C. (2018). Automatic detection and classification of manufacturing defects in metal boxes using deep neural networks. **PloS one**, 13(11), e0203192.
- Jian, C., Gao, J., & Ao, Y. (2017). Automatic surface defect detection for mobile phone screen glass based a machine vision. **Applied Soft Computing**, 52, 348–358.
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2019). A survey of the recent architectures of deep convolutional neural networks. **arXiv**: 1901.06032.
- Li, L., Ota, K., & Dong, M. (2018). Deep learning for smart industry: Efficient manufacture inspection system with fog computing. **IEEE Transactions on Industrial Informatics**, 14(10), 4665–4673.
- Russell, S. J., Norvig, P., & Davis, E. (2010). **Artificial intelligence: a modern approach**. (3rd ed). Upper Saddle River, NJ: Prentice Hall.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. **arXiv**: 1409.1556.