

การพัฒนาแบบจำลองการจำแนกคุณภาพเกรดวุ้นมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN

Development of a Deep Learning-Based Model for Coconut Jelly Quality Grade Classification Using the Convolutional Neural Network (CNN) Algorithm

พันธิการ์ วัฒนกุล¹ กิตติพงษ์ ภูพัฒน์วิบูลย์^{1*} ขวัญยุพา ศรีสว่าง¹ และ เดช ธรรมศิริ¹

¹สาขาวิชาธุรกิจดิจิทัล คณะวิทยาการจัดการ มหาวิทยาลัยราชภัฏนครปฐม

phantiga@webmail.npru.ac.th kittipong@webmail.npru.ac.th* khuanyupa@webmail.npru.ac.th dech@webmail.npru.ac.th

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์ เพื่อพัฒนาแบบจำลองการจำแนกคุณภาพเกรดวุ้นมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN และเปรียบเทียบวิธีการจำแนกเกรดวุ้นมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN ซึ่งผู้วิจัยได้พัฒนาแบบจำลองสำหรับจำแนกคุณภาพเกรดวุ้นมะพร้าวของโรงงานวุ้นมะพร้าว การวิจัยฉบับนี้เป็นการทดสอบในสภาพการทำงานจริง โดยใช้ข้อมูลภาพจากการผลิตจริงของโรงงาน โดยเก็บรวบรวมข้อมูลจากโรงงานวุ้นมะพร้าว โดยการเก็บรวบรวมรูปภาพวุ้นมะพร้าวที่ใช้ในการเรียนรู้ที่คัดแยกเป็นคุณภาพวุ้นมะพร้าวเกรด A และคุณภาพวุ้นมะพร้าวเกรด D จำนวนทั้งหมด 615 รูป แบ่งเป็นคุณภาพวุ้นมะพร้าวเกรด A 408 รูป และคุณภาพวุ้นมะพร้าวเกรด D 207 รูป และกลุ่มละ 40 รูป ในการทดสอบแบบจำลองใช้การกำหนดค่าการตรวจสอบแบบไขว้ (k-fold cross validation) เพื่อให้ระบบสุ่มภาพในชุดข้อมูลการเรียนรู้ทั้ง 2 กลุ่ม ในการฝึกใช้ให้แบบจำลองเกิดการเรียนรู้ จำนวน 200 รอบ จากนั้นเมื่อได้แบบจำลองที่สมบูรณ์แล้วนำภาพ 80 ภาพ มาทดสอบความถูกต้องของการจำแนกคุณภาพของวุ้นมะพร้าวตามเกรดที่กำหนดไว้ จากนั้นวิเคราะห์และสร้างแบบจำลองด้วยเครื่องมือ TensorFlow และ Keras ซึ่งเป็นไลบรารีมาตรฐานในงานการเรียนรู้เชิงลึก การทดสอบใช้เทคนิค cross-validation เพื่อเพิ่มความน่าเชื่อถือของผลลัพธ์

ผลการวิจัย พบว่า การทดสอบรูปภาพกลุ่มคุณภาพวุ้นมะพร้าวเกรด A โดยใช้ Sigmoid อัตราความสำเร็จในการจำแนก คือ 100% และมีคุณภาพวุ้นมะพร้าวเกรด D โดยใช้ Sigmoid อัตราความสำเร็จในการจำแนกคือ 100% ซึ่งผลลัพธ์ของการทดสอบแสดงให้เห็นว่าแบบจำลองการจำแนกคุณภาพเกรดวุ้นมะพร้าวที่สร้างขึ้นโดยใช้วิธีการเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN มีประสิทธิภาพในการจำแนกคุณภาพเกรดวุ้นมะพร้าว สามารถนำผลการวิจัยเป็นต้นแบบในการพัฒนาระบบอัตโนมัติสำหรับคัดแยกคุณภาพเกรดวุ้นมะพร้าวเพื่อส่งเสริมความเชื่อมั่นให้กับ การจำหน่ายผลิตภัณฑ์วุ้นมะพร้าวต่อไป และงานวิจัยนี้แสดงให้เห็นว่าการพัฒนาอุตสาหกรรม 4.0 ที่มีข้อจำกัดด้านทุนและบุคลากร การนำโซลูชันที่พัฒนาขึ้นนี้ไปประยุกต์ใช้ในสถานประกอบการที่มีลักษณะการผลิตคล้ายกัน เช่น ผลไม้แปรรูปหรือผลิตภัณฑ์เยลลี่จะสามารถยกระดับมาตรฐานอุตสาหกรรมในภาพรวมได้อีกด้วย

คำสำคัญ: แบบจำลอง เกรดวุ้นมะพร้าว การจำแนก การเรียนรู้เชิงลึก เครือข่ายประสาทเทียมแบบคอนโวลูชัน

Abstract

This study aims to develop a deep learning-based model to classify the quality levels of coconut jelly using the Convolutional Neural Network (CNN) algorithm and to compare the performance of CNN-based models in the classification of coconut jelly. The model was specifically developed to support

the classification process in a real coconut jelly processing factory. The study was conducted under real working conditions, using image data taken directly from the production line. A total of 615 images of coconut jelly were collected and categorized into grades A (408 images) and D (207 images) for training purposes. A further 40 images of each grade were used for testing. The model was trained using k-fold cross-validation to ensure that the training data was randomly selected from both classes, allowing the model to learn effectively. The training process involved 200 epochs. After the model was fully trained, 80 images were used to evaluate its classification accuracy. The model development and training were performed using TensorFlow and Keras, two widely used libraries for deep learning. Cross-validation techniques were used to increase the reliability of the results.

The results show that the success rate of grades A and D coconut jelly image classification using the sigmoid activation function is 100%. These results indicate that the CNN-based deep learning model has high effectiveness in classifying coconut jelly quality grades. The results of this study can serve as a prototype for the development of automated quality assessment systems that could enhance consumer confidence and improve product marketability. Furthermore, this study emphasizes the potential of Industry 4.0 technologies - especially for companies with limited financial and human resources. The proposed solution can be adapted to other production environments with similar production characteristics, such as processed fruit or jelly-based products, thus contributing to the overall evolution of industry standards.

Keywords: Model, Coconut Jelly Grade, Classification, Deep Learning, Convolutional Neural Network (CNN)

1. บทนำ

ในภาคการแปรรูปอาหาร ปัญญาประดิษฐ์มีบทบาทเพิ่มขึ้นในการลดค่าใช้จ่ายและเพิ่มประสิทธิภาพ โดยเฉพาะอย่างยิ่งในการคัดแยกวัตถุดิบ โรงงานผลิตวุ้นมะพร้าวซึ่งมักเผชิญกับต้นทุนแรงงานที่สูงและระยะเวลาในการคัดแยกที่คาดเดาไม่ได้ จะได้รับประโยชน์อย่างมากจากระบบคัดแยกที่ใช้ระบบ CNN วิธีการดังกล่าวมีศักยภาพที่จะเปลี่ยนแปลงวิธีการปฏิบัติแบบดั้งเดิม โดยเพิ่มระบบอัตโนมัติ ความแม่นยำ และความสามารถในการปรับขนาดในอุตสาหกรรม ซึ่งในยุคที่มีการแข่งขันสูงและต้องรักษาคุณภาพและความสม่ำเสมอของผลิตภัณฑ์ ถือเป็นปัจจัยสำคัญที่สร้างความได้เปรียบ

*ผู้ประพันธ์บทความ

และความเชื่อมั่นจากผู้บริโภคจากการที่โรงงานสามารถส่งมอบสินค้าในระดับคุณภาพเดียวกันทุกครั้งให้แก่ผู้บริโภค

โรงงานวันมะพร้าวใช้วันมะพร้าว 2 เกรด คือ คุณภาพวันมะพร้าวเกรด A และคุณภาพวันมะพร้าวเกรด D เพราะวันแต่ละเกรดเนื้อผิวของวันมะพร้าวจะไม่เหมือนกัน ซึ่งทำให้การคัดแยกเกรดวัน เพื่อที่จะนำมาใช้ประโยชน์ที่ต่างกัน โดยใช้คุณภาพวันมะพร้าวเกรด A ในการผลิตวันเต๋าขนาดต่าง ๆ เช่น 0.5 มิลลิเมตร 8 มิลลิเมตร และ 15 มิลลิเมตร ส่วนคุณภาพวันมะพร้าวเกรด D จะนำไปแปรรูปเป็นวันปั่น โดยโรงงานวันมะพร้าวอภิชาติประสบปัญหาเรื่องค่าแรงที่สูง และเวลาที่ใช้ในการคัดแยกวันมะพร้าวที่ไม่สม่ำเสมอ ซึ่งการคัดแยกเกรดอย่างถูกต้องจะส่งผลต่อคุณภาพสินค้า และกระทบต่อรายได้โดยตรง โดยการทำงานของโรงงานวันมะพร้าวอภิชาติใช้แรงงานมนุษย์ในการคัดแยกวันมะพร้าวนั้น มีค่าแรงที่สูง และใช้ระยะเวลาในการคัดแยกเกรดวันมะพร้าวอาจทำให้เกิดความผิดพลาดที่เกิดจากปัจจัยมนุษย์ เช่น ความล้า ความเร่งรีบ หรือความไม่ชำนาญ

การประมวลผลภาพเป็นรากฐานทางเทคโนโลยีที่สำคัญในการตรวจสอบวัตถุ โดยทำหน้าที่เป็นเครื่องมือที่ใช้สำหรับการวิเคราะห์และตีความภาพที่ใช้อัลกอริทึมและเทคนิคขั้นสูงเพื่อตรวจสอบข้อมูลภาพอย่างละเอียด ระบบสามารถแยกแยะและดึงคุณลักษณะสำคัญต่าง ๆ ของภาพ เช่น รูปร่าง ขนาด สี และพื้นผิว ออกมาได้ โดยเทคโนโลยีนี้เป็นรากฐานสำหรับการพัฒนาระบบการจำแนกประเภทที่ซับซ้อน ช่วยให้ระบบอัตโนมัติสามารถตรวจจับข้อบกพร่อง ตรวจสอบข้อกำหนด และรักษามาตรฐานที่สอดคล้องกัน ช่วยลดข้อผิดพลาดของมนุษย์และเร่งปริมาณงาน โดยวิธีการ Convolutional Neural Network (CNN) เป็นเทคโนโลยีในกลุ่มการเรียนรู้เชิงลึกที่สามารถประมวลผลภาพอย่างลึกซึ้ง โดยการวิเคราะห์ลักษณะเฉพาะจากภาพถ่าย เช่น พื้นผิว สี ขนาด และรูปร่าง การฝึกให้โมเดลเรียนรู้จากภาพจริงที่ผ่านการจำแนกเกรดโดยผู้เชี่ยวชาญทำให้ระบบสามารถพัฒนาความสามารถในการจำแนกได้ใกล้เคียงกับมนุษย์ [1] จากปัญหาของโรงงานวันมะพร้าวดังกล่าวข้างต้นจึงมีแนวคิดในการพัฒนาแบบจำลองการจำแนกคุณภาพเกรดวันมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN เพื่อเป็นต้นแบบที่สามารถจำแนกเกรดวันมะพร้าวได้รวดเร็ว ถูกต้องแม่นยำ และลดต้นทุนในการจ้างแรงงานคน

2. วัตถุประสงค์ของงานวิจัย

1. เพื่อพัฒนาแบบจำลองการจำแนกคุณภาพเกรดวันมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN
2. เพื่อเปรียบเทียบวิธีการจำแนกเกรดวันมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN

3. เอกสารและงานวิจัยที่เกี่ยวข้อง

3.1 ทฤษฎีการประมวลผลภาพ

การประมวลผลภาพเป็นเทคโนโลยีที่วิเคราะห์ข้อมูลภาพผ่านเทคนิคที่ได้รับการพัฒนาหลากหลายรูปแบบ ซึ่งรวมถึงการเพิ่มความคมชัด ลดสัญญาณรบกวน และแบ่งส่วนวัตถุ เพื่อให้ได้ข้อมูลเชิงปริมาณที่แม่นยำ ข้อมูลอันทรงคุณค่านี้ทำหน้าที่เป็นรากฐานสำหรับการวิเคราะห์อย่างละเอียด และการพัฒนาอย่างเป็นระบบ ความสามารถรอบด้านของเทคโนโลยีนี้ช่วยให้สามารถนำไปประยุกต์ใช้ได้อย่างมีประสิทธิภาพในหลากหลายอุตสาหกรรม จึงเป็นเครื่องมือสำคัญในการพัฒนานวัตกรรมและความเป็นเลิศ เช่น งานวิจัย [2] การตรวจจับและจดจำโมเดลรถยนต์ด้วยข้อมูลเชิงจุดภาพ และงานวิจัย [3] เป็นระบบแยกประเภทไข่มุกโดยใช้การประมวลผลภาพ มี 3 ขั้นตอน คือ 1) นำรูปภาพเข้าสู่คอมพิวเตอร์และ

ประมวลผลโดยใช้ภาษาขั้นสูง 2) ใช้คอมพิวเตอร์พัฒนาและทดสอบอัลกอริทึมการประมวลผลภาพ และ 3) วัดประสิทธิภาพของอัลกอริทึม

3.2 ทฤษฎีโครงข่ายประสาทแบบคอนโวลูชัน

เครือข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs) เป็นเครือข่ายประสาทเทียมรูปแบบหนึ่งที่ยอมรับกันอย่างแพร่หลาย เครือข่ายนี้ใช้ตัวกรองหลายตัวที่คอนโวลูชันกับข้อมูลอินพุต และผ่านการปรับแต่งผ่านการฝึกอบรมเพื่อเพิ่มประสิทธิภาพการทำงาน เป้าหมายหลักของ CNNs คือ การระบุและดึงคุณลักษณะต่างๆ ออกจากภาพ โดยมีจุดประสงค์เพื่อสกัดฟีเจอร์จากภาพ โดยประยุกต์ใช้ในคอมพิวเตอร์วิทัศน์เป็นการจำแนกรูปภาพ ตรวจสอบวัตถุ และการรู้จำภาพ ฯลฯ โครงข่ายประสาทเทียมนี้เป็นวิธีหนึ่งที่จำลองการมองเห็นของมนุษย์ที่สามารถแยกคุณลักษณะของวัตถุ เช่น สี การตัดกันของสี ขอบภาพ และนำมาประกอบกัน เพื่อระบุคุณสมบัติในสิ่งที่มองเห็น ซึ่งการเรียนรู้เชิงลึกเป็นการประยุกต์ใช้โครงข่ายประสาทแบบคอนโวลูชันหลาย ๆ ชั้น สำหรับค้นหาหรือระบุคุณลักษณะ และทำซ้ำหลาย ๆ รอบ ทำให้ได้คำตอบที่มีความแม่นยำ โดยการทำงานของโครงข่ายประสาทเทียมนี้จะพิจารณาจากความสัมพันธ์ของผลลัพธ์กับคุณลักษณะที่สกัดได้ในแต่ละขั้นมากที่สุด

จากการวิเคราะห์วรรณกรรมที่เกี่ยวข้องกับการประมวลผลภาพนั้นมีหลายบทความดังต่อไปนี้ งานวิจัย [4] เป็นการพัฒนาแบบจำลองในการตรวจสอบและจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์ โดยใช้วิธีการเรียนรู้เชิงลึก ที่รวบรวมข้อมูลภาพถ่ายมะม่วงและเก็บข้อมูลการจำแนกคุณภาพเกรดมะม่วง แบ่งเป็น 4 ระดับ คือ เกรด A เกรด B เกรด C และ เกรด D (มะม่วงเน่า) ผลการวิจัย พบว่า แบบจำลองที่ใช้วิธีการเรียนรู้เชิงลึกด้วยอัลกอริทึม CNN ในการประมวลผลมีความแม่นยำสูงสุด คือ 99.79% จากนั้นนำมาสร้างต้นแบบสำหรับการจำแนกคุณภาพ มีอัตราการทำนายความสำเร็จ คือ 100% งานวิจัย [5] เป็นการพัฒนารูปแบบในการวิเคราะห์ขนาดของวัตถุ กรณีศึกษากล้วยปอกเปลือกโดยเทคนิคการประมวลผลภาพ ซึ่งได้พัฒนาโปรแกรมในการวิเคราะห์ขนาดของกล้วยปอกเปลือก โดยทำการเทียบขนาดของกล้วยน้ำว้าจริงกับขนาดของที่ได้จากโปรแกรมที่พัฒนา โดยมีการวิเคราะห์คุณภาพภาพถ่ายกล้วยน้ำว้า เมื่อเทียบขนาดกับการวัดจริง ในด้านการระบุขนาด มีความถูกต้อง 73.33% ซึ่งสามารถนำไปใช้ในการระบุขนาดของกล้วยปอกเปลือก และสร้างระบบอัตโนมัติต่อไป งานวิจัย [6] ในด้านภูมิศาสตร์โดยใช้การเรียนรู้เชิงลึกในการจำแนกข้อมูลถนนในเขตชนบทจากภาพถ่ายจากโดรน ที่นำไปใช้ในการทำงานด้านการสำรวจ และการประเมินการใช้ประโยชน์ที่ดิน ทำให้การทำงานมีความรวดเร็วขึ้น เมื่อเทียบกับการจำแนกประเภทแบบมีผู้สอน/ไม่มีผู้สอน ซึ่งงานวิจัยนี้ได้นำข้อมูลภาพถ่ายดาวเทียม Landsat-8 มาใช้กับการเรียนรู้เชิงลึกในส่วนของการเพิ่มข้อมูลถนนใน OSM ใช้โปรแกรม JOSM ในการอัปเดตข้อมูลและใช้ภาพถ่าย UAV ที่มีความละเอียดมากกว่าภาพถ่ายดาวเทียม โดยผลลัพธ์ที่ได้ คือ ข้อมูลถนน และข้อมูลประเภทอาคาร และสิ่งอื่น ๆ ที่อยู่ในภาพ สามารถนำไปใช้กับงานด้านต่าง ๆ ได้ งานวิจัยต่อมา [7] เป็นการจำแนกภาพถ่ายระบบบอร์จี้ด้วยเทคนิคการเรียนรู้เชิงลึกของโครงข่ายประสาทเทียม เพื่อใช้เทคโนโลยีมาทดแทนมนุษย์ในการจำแนกมะเขือเทศ โดยวิเคราะห์ค่าพารามิเตอร์สีด้วยเทคนิคการเรียนรู้ของโครงข่ายนิวรอลเน็ตเวิร์ค โดยกลุ่มตัวอย่างที่ใช้เป็นมะเขือเทศพันธุ์ใหม่ที่มีแบ่งกลุ่มสีมะเขือเทศเป็น 3 สี คือ Green Red และ Mature Red พบว่า การจำแนกสีมีความถูกต้องเท่ากับ 94.07% แต่ถ้าตัวอย่างมะเขือเทศที่อยู่ในระหว่างการเปลี่ยนสีทำให้เกิดเฉดสีที่ใกล้เคียงกันสามารถทำให้เกิดความผิดพลาดขึ้นได้ และงานวิจัย [8] เป็นการจำแนกรูปภาพพันธุ์ส้ม

จอบประสาทตา โดยวิธีการเรียนรู้เชิงลึก แบ่งความรุนแรงของโรคเป็น 4 ระดับ คือ ขั้นรุนแรง ขั้นปานกลาง ขั้นเบา และปกติ โดยนำภาพถ่ายพินดัสมาประมวลผลภาพด้วยหลักการการเรียนรู้เชิงลึก และสร้างแบบจำลองสำหรับการจำแนก พบว่า สามารถจำแนกระดับความรุนแรงของโรคเบาหวานเข้าจอบประสาทตา มีความแม่นยำถึง 95.65% ขณะที่งาน [9] ใช้อัลกอริทึม J48 มีความแม่นยำเพียง 85.50%

อีกทั้งจากที่ผู้วิจัยได้สำรวจบทความวิจัยที่ผ่านมา พบว่า มีหลายงานที่นำเทคนิคการประมวลผลภาพกับงานด้านอาหาร โดยมีผู้วิจัยนำเสนอไว้หลายเทคนิค (ดังตารางที่ 3.1) ซึ่งงานวิจัยฉบับนี้ได้นำเสนอเทคนิคการจำแนกข้อมูล โดยใช้เทคนิค 2D-CNN (Convolutional Neural Network แบบ 2 มิติ) สำหรับการจำแนกภาพคุณภาพเกรดรุ่นมะพร้าว

ตารางที่ 3.1 เทคนิคในการประมวลผลภาพกับงานด้านอาหาร

ชื่อเทคนิค	ข้อดี	ข้อเสีย	การประยุกต์ใช้	งานวิจัยอ้างอิง
1) SVM (Support Vector Machine)	เหมาะสำหรับข้อมูลตัวอย่างน้อยและมีความซับซ้อนสูง ช่วยป้องกันการ Overfitting ได้ดี	ใช้ได้เฉพาะในท้องปฏิบัติการ ไม่เหมาะกับข้อมูลขนาดใหญ่ และใช้หลักการประมวลผลสูงในการฝึกสอนโมเดล	ประเมินองค์ประกอบของอาหาร และตรวจจับการปนเปื้อน	[10] [11]
2) 1D-CNN (Convolutional Neural Network แบบ 1 มิติ)	ช่วยลดมิติข้อมูล ลดจำนวนพารามิเตอร์ ทำให้ประหยัดค่าใช้จ่ายและป้องกัน Overfitting	อาจทำให้ข้อมูลบางส่วนสูญหายไป กระบวนการลดมิติ	ตรวจจับเชื้อโรคหรือการปนเปื้อนที่มากับอาหาร	[12] [13] [14]
3) 2D-CNN (Convolutional Neural Network แบบ 2 มิติ)	มีความแม่นยำสูงในการรู้จำรูปแบบ และจัดการข้อมูลหลายมิติได้ดี	ต้องการข้อมูลตัวอย่างจำนวนมากและใช้เวลาในการฝึกสอนนาน	วิเคราะห์ภาพอาหารทั่วไป ประเมินความสุก และระบุสิ่งแปลกปลอม	[15]
4) PCA (Principal Component Analysis)	มีประสิทธิภาพในการลดความซับซ้อนของข้อมูล โดยที่สามารถรักษาคุณลักษณะที่สำคัญไว้ได้ มีความหลากหลายในการใช้งาน นอกเหนือจากการจำแนกประเภท	อาจเกิดการสูญเสียข้อมูล เนื่องจากจะให้ความสำคัญกับคุณลักษณะที่มีความแปรปรวนสูงสุด และอาจอ่อนไหวต่อสัญญาณรบกวน	ใช้ในการจำแนกประเภทรูปภาพ และการเตรียมข้อมูล เพื่อลดมิติและคัดเลือกคุณลักษณะ	[16] [17]

4. วิธีการดำเนินงานวิจัย

4.1 การเก็บรวบรวมข้อมูล

การวิจัยนี้ได้เก็บรวบรวมข้อมูลจากโรงงานวันมะพร้าว โดยเก็บรวบรวมภาพคุณภาพวันมะพร้าว ที่คัดแยกเป็นคุณภาพวันมะพร้าวเกรด A และคุณภาพวันมะพร้าวเกรด D

4.2 การเตรียมข้อมูล

ผู้วิจัยดำเนินการเก็บรวบรวมข้อมูลภาพวันมะพร้าวในแต่ละภาพที่มีขนาด 192 x 256 พิกเซล ซึ่งขั้นตอนการจัดกลุ่มคุณภาพของวันมะพร้าวดำเนินการโดยการสอบถามการจำแนกคุณภาพเกรดวันมะพร้าวในแต่ละระดับ โดยจัดกลุ่มหรือเกรดไว้ คือ 1) ระดับคุณภาพวันมะพร้าวเกรด A และ 2) คุณภาพวันมะพร้าวเกรด D (วันมะพร้าวที่รูปแบบเว้าแหว่งเป็นรอยบนหน้าวันมะพร้าว) ดังรูปที่ 4.1



(a) คุณภาพวันมะพร้าวเกรด A



(b) คุณภาพวันมะพร้าวเกรด D

รูปที่ 4.1 ตัวอย่างรูปภาพคุณภาพวันมะพร้าวเกรด A (a) และคุณภาพวันมะพร้าวเกรด D (b)

4.3 ขั้นตอนการประมวลผลภาพ

- 4.3.1 การนำรูปภาพเข้าสู่เครื่องคอมพิวเตอร์
- 4.3.2 การพัฒนาอัลกอริทึมเพื่อประมวลผลภาพ
- 4.3.3 การแสดงผลภาพ

4.4 การวัดประสิทธิภาพ

การวัดประสิทธิภาพเพื่อเปรียบเทียบค่าความแม่นยำเพื่อสร้างแบบจำลองที่ใช้การวัดค่าความแม่นยำ (Accuracy) เพื่อหาค่าพยากรณ์ความถูกต้องของข้อมูลเป็นอัตราส่วนร้อยละของจำนวนตัวอย่างที่โมเดลทำนายถูกต้องเมื่อเทียบกับจำนวนข้อมูลทั้งหมด ยิ่งมีค่าสูงเท่าใด แสดงให้เห็นว่าโมเดลสามารถจำแนกข้อมูลได้ถูกต้องมากขึ้น การใช้ค่า Accuracy เพียงอย่างเดียวอาจไม่เพียงพอ โดยเฉพาะอย่างยิ่งในกรณีที่ชุดข้อมูลมีความไม่สมดุล ควรพิจารณาตัวชี้วัดอื่น ๆ ร่วมด้วย เพื่อประเมินประสิทธิภาพของโมเดลได้อย่างครอบคลุมและแม่นยำยิ่งขึ้น โดยคิดเป็นค่าร้อยละ (%) มีสูตรการคำนวณ ดังนี้

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

โดย Accuracy คือ ค่าความแม่นยำ

- TP คือ ค่าที่พยากรณ์ถูกต้องคุณภาพวันมะพร้าวเกรด A
- TN คือ ค่าที่พยากรณ์ถูกต้องคุณภาพวันมะพร้าวเกรด D
- FP คือ ค่าที่พยากรณ์ผิดพลาดคุณภาพวันมะพร้าวเกรด A
- FN คือ ค่าที่พยากรณ์ผิดพลาดคุณภาพวันมะพร้าวเกรด D
- TP + TN คือ จำนวนที่ทำนายถูกทั้งหมด (ทั้งกรณีบวกและลบ)
- TP + TN + FP + FN คือ จำนวนข้อมูลทั้งหมดที่ใช้ทดสอบ

4.5 การพัฒนาแบบจำลอง

ในการพัฒนาแบบจำลอง มี 2 ขั้นตอน คือ ขั้นตอนของการทดสอบ (Train) เพื่อสร้างแบบจำลองและขั้นตอนของการทดสอบ (Test) แบบจำลองการสร้างแบบจำลองเป็นขั้นตอนการสร้างการทดสอบสำหรับใช้ในการเรียนรู้ (Training Dataset) โดยใช้ข้อมูลรูปภาพวันมะพร้าวที่ได้จัดกลุ่มคุณภาพวันมะพร้าวเกรด A และคุณภาพวันมะพร้าวเกรด D จำนวนทั้งหมด 615 รูป แบ่งเป็นคุณภาพวันมะพร้าวเกรด A 408 รูป และคุณภาพวันมะพร้าวเกรด D 207 รูป และสำหรับการทดสอบ (Testing Dataset) ใช้ข้อมูลรูปภาพวันมะพร้าวกลุ่มละ 40 รูป ซึ่งแบบจำลองนี้ใช้ในการกำหนดค่าการตรวจสอบแบบไขว้ (k-fold cross validation) คือ $k=10$ ในการทดลองเพื่อให้ระบบสุ่มภาพในชุดข้อมูลการเรียนรู้ทั้ง 2 กลุ่มเพื่อฝึกใช้ให้แบบจำลองเกิดการเรียนรู้ จำนวน 200 รอบ จากนั้นเมื่อได้แบบจำลองที่สมบูรณ์แล้วนำภาพ 80 ภาพ มาทดสอบความถูกต้องของการจำแนกคุณภาพของวันมะพร้าวตามเกรดที่กำหนดไว้ โดยค่าเฉลี่ยจากการทำ k-folds cross-validation เพื่อจัดการกับความแปรปรวน และจำนวนข้อมูลในแต่ละ fold ที่มีค่าไม่เท่ากัน

4.6 การวัดประสิทธิภาพของโมเดล

ในการวัดประสิทธิภาพของโมเดล (Evaluate Model) แบ่งเป็น 2 กรณี คือ แบบ Regression และแบบ Classification ที่จะเป็นการวัดประสิทธิภาพของโมเดลในครั้งนี้

4.6.1 การวัดประสิทธิภาพโมเดลแบบ Regression ในกรณีที่แบบ Regression หรือ Target ข้อมูลเป็นแบบ Scale หรือตัวการคัดแยกเกรด ซึ่งมีทั้งแบบ Discrete และ Continuous เป็นการพิจารณาจากค่า Error

4.6.2 Confusion Matrix มีรูปแบบ 2 แบบ คือ 1) แบบที่ค่า predict อยู่ซ้ายมือ actual อยู่ด้านบน และ 2) แบบที่ค่า actual อยู่ซ้ายมือ และ predict อยู่ด้านบน ตารางตัวอย่างที่ใช้ในการคัดแยกคุณภาพวันมะพร้าวเกรด A และคุณภาพวันมะพร้าวเกรด D ดังรูปที่ 4.2 และนำข้อมูล Confusion Matrix มาใช้คำนวณค่าต่าง ๆ เช่น Accuracy ดังรูปที่ 4.3

			Accuracy	=	$\frac{TP+TN}{TP+FP+TN+FN}$
			True Positive Rate	=	$\frac{TP}{TP+FN}$
			False Positive Rate	=	$\frac{FP}{FP+TN}$
			Recall	=	$\frac{TP}{TP+FN}$
			Precision	=	$\frac{TP}{TP+FP}$
			F_1 Measure	=	$\frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$
			F_β Measure	=	$\frac{(1+\beta) \times \text{Precision} \times \text{Recall}}{(\beta \times \text{Precision}) + \text{Recall}}$

รูปที่ 4.2 ตารางที่ใช้ในการคัดแยกคุณภาพวันมะพร้าวเกรด A และคุณภาพวันมะพร้าวเกรด D

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{TP+FN}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{TN+FP}$
		Precision Value $\frac{TP}{TP+FP}$	Negative Predictive Value $\frac{TN}{TN+FN}$	Accuracy $\frac{TP+TN}{TP+TN+FP+FN}$

รูปที่ 4.3 การคำนวณค่าความคลาดเคลื่อน

4.6.3 Classification Accuracy คือ สัดส่วนของจำนวนความถูกต้องในการ Predict ต่อเกรดที่นำมา Predict ทั้งหมด Accuracy คือ ผลจากการ Predict ถูกต้อง จากข้อมูลทั้งหมดที่นำมา Predict โดยใช้สูตรด้านล่าง ดังนี้

- 1) Accuracy = $(TP+TN)/(TP+TN+FP+FN)$
- 2) Precision = $TP/(TP+FP)$
- 3) Sensitivity/Recall = $TP/(TP+FN)$
- 4) Specificity = $TN/(TN+FP)$
- 5) $F1 = 2 * [(precision * recall) / (precision + recall)]$

Correct predictions/total predictions... คือ นำผลจากการ Predict ถูกต้องหารข้อมูลทั้งหมดที่นำมา Predict มีค่าเต็มได้แค่ 1 ($1=Accuracy$ ดีที่สุด) เป็นเกรด A ยิ่งน้อยกว่า 1 ยิ่งไม่ดี เป็นเกรด D

Classification accuracy = correct predictions / total predictions * 100... คือ ทำ Accuracy เป็นร้อยละ error rate = $(1 - \text{correct predictions} / \text{total predictions}) * 100$... จาก Accuracy คือ ความถูกต้อง เพราะหาค่าความผิดพลาดได้จาก $1 - \text{Accuracy} = \text{error}$ คือ ค่าผกผันกันในการคัดแยกเกรดวันมะพร้าว

กรณีที่ Model ที่ต้องดูทั้ง 2 ค่า Precision และ Recall ด้วย ลักษณะนี้ต้องนำ Precision และ Recall มาหาค่าเฉลี่ย แต่เนื่องจากตัวหารหรือหน่วยไม่เท่ากัน จึงไม่สามารถนำ Precision และ Recall มาบวกกันหาร 2 ได้ จึงต้องใช้ F1-score คือ การคำนวณค่าเฉลี่ยระหว่าง Precision และ Recall

4.7 การเก็บรวบรวมโครงสร้างโมเดล

การสร้างโมเดลการจำแนกคัดเกรดวันมะพร้าวด้วยการประมวลผลภาพ ตั้งแต่การเก็บรวบรวมข้อมูลและรูปภาพวันมะพร้าว จากนั้นคัดแยกคุณภาพเกรดวันมะพร้าว และนำมาเรียนรู้กับทั้ง 7 โมเดลเพื่อเปรียบเทียบประสิทธิภาพการทำงาน ดังนี้

4.7.1 การเก็บและเตรียมข้อมูล

- 1) เก็บรวบรวมภาพวันมะพร้าวจากโรงงาน
- 2) คัดแยกคุณภาพเกรดวันมะพร้าว ออกเป็น 2 เกรด คือ เกรด A (สามารถจำหน่ายได้) และ เกรด D (ไม่สามารถจำหน่ายได้)
- 3) ปรับขนาดภาพให้อยู่ที่ 192×256 พิกเซล
- 4) แปลงภาพเป็นรูปแบบ Gray Scale
- 5) เตรียมข้อมูลให้อยู่ในรูปแบบที่เหมาะสมกับการประมวลผลด้วยโมเดล

4.7.2 การแบ่งชุดข้อมูล จำนวนทั้งหมด 615 ภาพ ดังนี้

- 1) Training Data : ใช้สำหรับการฝึกโมเดล จำนวน 535 ภาพ (เกรด A จำนวน 408 ภาพ และ เกรด D จำนวน 207 ภาพ)
- 2) Testing Data : ใช้สำหรับการทดสอบโมเดล จำนวน 80 ภาพ (เกรด A จำนวน 27 ภาพ และ เกรด D จำนวน 53 ภาพ)

4.7.3 การพัฒนาโมเดล

- 1) ใช้สถาปัตยกรรม Convolutional Neural Network (CNN)
- 2) ทดสอบด้วย Activation Functions จำนวน 7 แบบ ได้แก่ ReLU, Tanh, Swish, Softmax, Linear, ELU และ Sigmoid

4.7.4 การประเมินผล

- 1) นำชุดข้อมูล Testing Data มาทดสอบกับโมเดลที่ผ่านการฝึกสอน
- 2) ประเมินผลลัพธ์ด้วย Confusion Matrix

3) คำนวณตัวชี้วัดประสิทธิภาพ (Accuracy, Precision, Recall และ F1-score)

4.7.5 สรุปผล


- 1) รวบรวมผลลัพธ์จากการทดลองทั้งหมด
- 2) เปรียบเทียบประสิทธิภาพของฟังก์ชันทั้ง 7 แบบ
- 3) เลือกฟังก์ชันที่ให้ผลลัพธ์เหมาะสมที่สุดสำหรับการจำแนก

คุณภาพวันมะพร้าว

5. ผลการดำเนินงานวิจัย

5.1 การพัฒนาแบบจำลองการจำแนกเกรดวันมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN

การพัฒนาระบบจำแนกเกรดวันมะพร้าวด้วยการประมวลผลภาพด้วยภาษา Python โดยใช้ไลบรารีสำหรับพัฒนาการเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN คือ Keras และ Tensorflow ร่วมกัน เพื่อสร้างแบบจำลอง และวิเคราะห์การจำแนกคุณภาพวันมะพร้าวเกรด A และคุณภาพวันมะพร้าวเกรด D ผลของการสร้างแบบจำลอง ประกอบไปด้วย 7 ฟังก์ชัน คือ Relu, tanh, Swish, Softmax, linear, elu และ Sigmoid จะเห็นว่าผลการทดสอบแบบจำลองในแต่ละรอบ มีความแม่นยำที่แตกต่างกัน โดยผลการทดลองได้ค่าความแม่นยำสูงสุด คือ 100% แสดงถึงประสิทธิภาพในการจำแนกคุณภาพเกรดวันมะพร้าว โดยใช้วิธีการเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN ดังรูปที่ 5.1



รูปที่ 5.1 แสดงค่าแสดงค่าความแม่นยำและค่าความผิดพลาดในการสร้างแบบจำลองจำแนกคุณภาพเกรดวันมะพร้าว

5.2 การเปรียบเทียบวิธีการจำแนกเกรดวันมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN

การเปรียบเทียบวิธีการจำแนกโดยนำแบบจำลองไปทดสอบกับภาพของเกรดวันมะพร้าวที่จัดกลุ่มคุณภาพไว้ 2 กลุ่ม จำนวน 80 รูป เป็นคุณภาพวันมะพร้าวเกรด A จำนวน 40 รูป และ คุณภาพวันมะพร้าวเกรด D จำนวน 40 รูป โดยผลการทดสอบแบบจำลองการจำแนกคุณภาพเกรดวันมะพร้าวโดยใช้วิธีการเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN ใช้ทดสอบทั้งหมด 7 ฟังก์ชัน ได้แก่ Relu, tanh, Swish, Softmax, linear, elu และ Sigmoid โดยใช้จำนวนในการทดสอบจำนวน 200 รอบ ผลลัพธ์ฟังก์ชันที่ทดสอบการจำแนกคุณภาพเกรดวันมะพร้าวได้ดีที่สุด คือ ฟังก์ชัน Sigmoid ผลการทดสอบรูปภาพกลุ่มคุณภาพวันมะพร้าวเกรด A อัตราความสำเร็จในการจำแนก คือ 100% และกลุ่มคุณภาพวันมะพร้าวเกรด D อัตราความสำเร็จในการจำแนก คือ 100% แบบจำลองการจำแนกคุณภาพเกรดวันมะพร้าวโดยใช้วิธีการเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN สามารถจำแนกคุณภาพเกรดวันมะพร้าวได้อย่างมีประสิทธิภาพ โดยใช้ฟังก์ชัน Sigmoid ดังตารางที่ 5.1

ตารางที่ 5.1 เปรียบเทียบผลลัพธ์วิธีการจำแนกเกรดวันมะพร้าวโดยใช้การเรียนรู้เชิงลึก ด้วยอัลกอริทึม CNN

Confusion Matrix	Activate Function						
	Relu	tanh	Swish	Softmax	linear	elu	Sigmoid
TRUE Positive	40	40	40	40	40	40	40
False Negative	35	36	35	35	36	35	0
TRUE Negative	5	4	5	5	4	5	40
FALSE Positive	0	0	0	0	0	0	0
Accuracy	56.25	55.00	56.25	56.25	55.00	56.25	100.00
Precision	100.00	100.00	100.00	100.00	100.00	100.00	100.00
Recall	53.33	52.63	53.33	53.33	52.63	53.33	100.00
F1	69.57	68.97	69.57	69.57	68.97	69.57	100.00

6. สรุปและอภิปรายผลการวิจัย

ผลการวิจัย พบว่า แบบจำลองการจำแนกคุณภาพเกรดวันมะพร้าวโดยใช้การเรียนรู้เชิงลึกด้วยอัลกอริทึม CNN สามารถจำแนกคุณภาพวันมะพร้าวได้อย่างมีประสิทธิภาพ โดยเฉพาะเมื่อใช้ฟังก์ชัน Sigmoid ซึ่งสามารถจำแนกคุณภาพวันมะพร้าวเกรด A และเกรด D ได้อย่างถูกต้อง 100% ในขณะที่ฟังก์ชัน Activation อื่น ๆ เช่น ReLU, Tanh, Swish, Softmax, Linear และ ELU ให้ค่าความแม่นยำ (Accuracy) ต่ำกว่า โดยอยู่ในช่วง 55.00-56.25% โดยเหตุผลที่ฟังก์ชัน Sigmoid ให้ผลลัพธ์ที่ดีที่สุด โดยมาจากลักษณะของปัญหาการจำแนกคุณภาพวันมะพร้าวใน

งานวิจัยนี้มีลักษณะใกล้เคียงกับ Binary Classification (เกรด A / เกรด D) ฟังก์ชัน Sigmoid จึงเหมาะสมที่สุด เนื่องจากสามารถแปลงค่าผลลัพธ์ของโครงข่ายประสาทเทียมเป็นรูปแบบความน่าจะเป็น (0-1) ที่ง่ายต่อการตีความและกำหนดเกณฑ์ตัดสิน (threshold) โดยสอดคล้องกับงานวิจัยของ [4] ได้แสดงให้เห็นว่าการใช้ฟังก์ชัน Sigmoid ในการจำแนกเชิงคุณภาพ และข้อจำกัดของฟังก์ชันอื่นดังนี้ 1) ฟังก์ชัน ReLU มีข้อจำกัดคือ อาจเกิดปัญหา Dying ReLU ทำให้บางนิวรอนไม่ตอบสนอง อีกทั้งผลลัพธ์ที่อยู่ในช่วง $[0, \infty)$ ไม่สามารถตีความเป็นค่าความน่าจะเป็นได้โดยตรง ซึ่งอาจไม่เหมาะสมกับปัญหาการจำแนกคุณภาพ งานวิจัย[18] ชี้ว่าความเสี่ยงนี้อาจทำให้ฟังก์ชัน ReLU ไม่เหมาะสมกับชั้น Output และ 2)

ฟังก์ชัน Tanh แม้จะให้ค่าผลลัพธ์ในช่วง $[-1, 1]$ และช่วยสร้างสมมาตรในการเรียนรู้ แต่ยังมีปัญหา Vanishing Gradient ได้ง่ายกว่าฟังก์ชัน Sigmoid อีกทั้งค่าที่เป็นลบไม่สามารถตีความได้โดยตรงในเชิงความน่าจะเป็น ซึ่งทำให้ไม่เหมาะกับปัญหาการจำแนกประเภทที่ต้องการผลลัพธ์ในเชิงความน่าจะเป็น

ผลการวิจัยนี้สอดคล้องกับ [1] ที่ใช้ Deep Learning เพื่อตรวจจับตำหนิบนพื้นผิวในอุตสาหกรรมการผลิต และ [2] ได้ยืนยันถึงประสิทธิภาพของ CNN ในการตรวจจับ และจำแนกรอยตำหนิจากข้อมูลภาพเชิงจุดที่สำคัญ นอกจากนี้ [3] ที่พัฒนาระบบแยกประเภทไข่มุกโดยใช้การประมวลผลภาพ ซึ่งทั้งสองงานสะท้อนถึงศักยภาพของ CNN ในการจำแนกข้อมูลที่ไม่มีโครงสร้างเฉพาะ งานของ [4] ในการจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์โดยเลียนแบบการมองเห็นของมนุษย์ด้วย CNN ที่มีความใกล้เคียงกับงาน [5] ที่วิเคราะห์ขนาดของกล้วยปอกเปลือก และ [6] ที่ใช้ Deep Learning จำแนกสภาพถนนจากภาพถ่ายโดรน รวมถึงงาน [7-8] ที่ใช้ CNN ในการจำแนกภาพ RGB และพื้นผิว ล้วนสะท้อนถึงการใช้ CNN กับข้อมูลภาพในหลายบริบท ทั้งหมดนี้สนับสนุนผลที่ว่า ฟังก์ชัน Sigmoid เป็นฟังก์ชันที่มีความเหมาะสมที่สุดสำหรับการจำแนกคุณภาพเกรดทุเรียนมะพร้าว เนื่องจากสอดคล้องกับลักษณะปัญหาเชิง Binary Classification และสามารถให้ผลลัพธ์ในรูปแบบความน่าจะเป็นที่ตีความได้ง่าย ข้อค้นพบนี้สอดคล้องกับแนวโน้มงานวิจัยที่เกี่ยวข้อง [1-9] และสามารถนำไปเป็นต้นแบบการพัฒนาซอฟต์แวร์สำหรับการคัดแยกคุณภาพวัตถุดิบหรือผลิตภัณฑ์ที่มีประสิทธิภาพในอุตสาหกรรมอื่น ๆ แม้การวิจัยนี้แสดงให้เห็นว่าฟังก์ชัน Sigmoid สามารถจำแนกได้อย่างแม่นยำสูงสุด แต่เพื่อให้มีความน่าเชื่อถือ และความเสถียรมากยิ่งขึ้นนั้น ควรเพิ่มความหลากหลายของข้อมูล เช่น การเก็บภาพจากหลายรอบการผลิต ภายใต้สภาพแสง มุมมอง และสภาพพื้นผิวที่แตกต่างกัน รวมถึงแก้ปัญหาความไม่สมดุลของจำนวนตัวอย่างในแต่ละคลาส นอกจากนี้ควรใช้วิธีการ Cross-validation เช่น k-fold cross-validation เพื่อตรวจสอบความเสถียรของโมเดล และรายงานค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของตัวชี้วัดหลัก (Accuracy, Precision, Recall, F1-score) ตลอดจนความเชื่อมั่นทางสถิติ (Confidence Interval) เพื่อยืนยันประสิทธิภาพของโมเดลได้อย่างรอบด้าน โดยสามารถนำผลการวิจัยเป็นต้นแบบหรือแนวทางในการพัฒนาระบบอัตโนมัติสำหรับการคัดแยกคุณภาพของภาพที่สามารถประยุกต์ใช้ในกระบวนการผลิตที่มีลักษณะที่คล้ายกัน เพื่อเพิ่มประสิทธิภาพ และยกมาตรฐานในภาพรวมได้

เอกสารอ้างอิง

- [1] T. Domen, Š. Samo, S. Jure, and S. Danijel, "Segmentation-based deep-learning approach for surface-defect detection", *Journal of Intelligent Manufacturing Article*, vol. 31, pp. 759-776, 2020.
- [2] อนุชา ตุงคชฐาน และ กัสมา ลีวัน, "การตรวจจับและจดจำโมเดลรอยตำหนิด้วยข้อมูลเชิงจุดภาพ," *วารสารวิศวกรรมศาสตร์ มหาวิทยาลัยสยาม*, ปีที่ 19, ฉบับที่ 1, หน้า 90-102, มกราคม - มิถุนายน 2561.
- [3] จิตรพงษ์ เจริญจิตร และ อภิรักษ์ พันธุ์พาสกุล, "ระบบแยกประเภทไข่มุกด้วยวิธีการประมวลผลภาพ," *การประชุมภาคใต้อาเซียนวิชาการระดับชาติและนานาชาติ* ครั้งที่ 9, 20-21 กรกฎาคม 2561, หน้า 1679-1691.
- [4] นพรุจ พัฒนสาร และ ณัฐภูมิ ศรีวิบูลย์, "การประมวลผลภาพสำหรับการจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์โดยการจำลองการมองเห็นของมนุษย์ด้วยวิธีการเรียนรู้เชิงลึก," *วารสารวิทยาการสารสนเทศและเทคโนโลยี*, ปีที่ 10, ฉบับที่ 1, หน้า 24-29, มกราคม - มิถุนายน 2563.
- [5] ภาณุวัฒน์ สกลวุฒิชัย และ สัณญา พันธุ์แพง, "การวิเคราะห์หาขนาดของวัตถุ กรณีศึกษา : กล้วยปอกเปลือก," *การประชุมวิชาการระดับปริญญาตรีด้านคอมพิวเตอร์ภูมิภาคเอเชีย* ครั้งที่ 10, 24-25 กุมภาพันธ์ 2565, หน้า 608-615.
- [6] ณัฐฐา ยงยิ่ง, "การประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึกในการจำแนกข้อมูลถนนจากภาพถ่าย Drone เพื่อการสำรวจถนนในเขตชนบท," *คณะเกษตรศาสตร์ ทรัพยากรธรรมชาติและสิ่งแวดล้อม มหาวิทยาลัยนเรศวร, วิทยานิพนธ์วิทยาศาสตรบัณฑิต*, 2562.
- [7] โยชิตา คำบุญมี สุขสวัสดิ์ ณัฐภูมิสิทธิ์ และปราณี มณีรัตน์, "การจำแนกภาพถ่ายระบบอาร์จีบีด้วยเทคนิคการเรียนรู้เชิงลึก," *Mahidol R2R e-Journal*, ปีที่ 5, ฉบับที่ 2, หน้า 1-9, กรกฎาคม-ธันวาคม 2561.
- [8] ทรงกรต พิมพ์ศาล และณัฐภูมิ ศรีวิบูลย์, "การประมวลผลภาพสำหรับการจำแนกรูปภาพพื้นผิวโดยใช้การเรียนรู้เชิงลึก," *วารสารวิทยาการสารสนเทศและเทคโนโลยี*, ปีที่ 10, ฉบับที่ 2, หน้า 19-25, กรกฎาคม-ธันวาคม 2563.
- [9] S. Phimpisan, "Application of Data Mining for Diabetic Retinopathy Using Decision Tree," *Journal of Srivinalai Vijai*, pp. 116-123, 2016.
- [10] H. Song, et al., "Detection of Aflatoxin B1 in Peanut Oil Using Attenuated Total Reflection Fourier Transform Infrared Spectroscopy Combined with Partial Least Squares Discriminant Analysis and Support Vector Machine Models," *Journal of Food Protection*, vol. 84, pp. 1315-1320, 2021.
- [11] J. A. Lopera-Rodríguez, et al., "Evaluation of Kernels Applied in Support Vector Machines in the Data Analysis of Organochlorines Exposure in Study of Biomarkers," in *VIII Latin American Conference on Biomedical Engineering and XLII National Conference on Biomedical Engineering*, Cham, pp. 784-791, 2020.
- [12] Wenjing Lv and X. Wang, "Overview of Hyperspectral Image Classification," *Journal of Sensors*, 2020.
- [13] O. Yaman, et al., "Image processing and machine learning-based classification method for hyperspectral images," *The Journal of Engineering*, vol. 2021, 2021.
- [14] S. M. Mansuri, et al., "Effect of germ orientation during Vis-NIR hyperspectral imaging for the detection of fungal contamination in maize kernel using PLS-DA, ANN and 1D-CNN modelling," *Food Control*, vol. 139, p. 109077, 2022.
- [15] F. Ghasemi, et al., "Neural network and deep-learning algorithms used in QSAR studies: merits and drawbacks," *Drug Discovery Today*, vol. 23, pp. 1784-1790, 2018.
- [16] F. Kherif and A. Latypova, "Chapter 12 - Principal component analysis," in *Machine Learning*, A. Mechelli and S. Vieira, Eds., ed: Academic Press, pp. 209-225, 2020.
- [17] D. Khamsoha, et al., "Utilizing near infrared hyperspectral imaging for quantitatively predicting adulteration in tapioca starch," *Food Control*, vol. 123, p. 107781, 2021.
- [18] Nair, V., & Hinton, G. E. Rectified Linear Units improve restricted Boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, pp. 807-814, 2010.