

การคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึก Jujube Classification from Images Using Deep Learning Technique

สุขสันต์ พรหมบุญเรือง¹ ธรรมรัตน์ บุญรอด^{1*} พิรญา ระดาสัย¹ และ ศิรดา สุภาพันธุ์¹
Suksun Promboonruang¹ Thummarat Boonrod¹ Peeraya Radasai¹ and Sirada Suphaphan¹

¹สาขาวิชาเทคโนโลยีดิจิทัล คณะบริหารศาสตร์ มหาวิทยาลัยกาฬสินธุ์

¹Department of Digital Technology, Faculty of Administrative Science, Kalasin University

วันที่ส่งบทความ : 29 ธันวาคม 2565 วันที่แก้ไขบทความ : 19 กรกฎาคม 2566 วันที่ตอบรับบทความ : 30 พฤศจิกายน 2566

Received: 29 December 2022, Revised: 19 July 2023, Accepted: 30 November 2023

บทคัดย่อ

งานวิจัยนี้นำเสนอการคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึกเพื่อจำแนกพุทราจากภาพถ่ายโดยใช้อัลกอริทึม Inception V3 ชุดข้อมูลที่ใช้ในการวิจัย แบ่งออกเป็นสี่กลุ่ม (a,b,c และ d) กลุ่มละ 300 รูป ข้อมูลที่ใช้ทดสอบ กลุ่มละ 50 รูป และข้อมูลชุดที่ใช้ในการตรวจสอบคุณภาพโมเดล กลุ่มละ 40 รูป เพื่อฝึกเรียนรู้และทดสอบแบบจำลองโมเดล ผลการทดลองแสดงให้เห็นว่าอัลกอริทึม Inception V3 มีค่าความถูกต้องสูงที่สุด 97% เปรียบเทียบกับแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) มีค่าความถูกต้อง 89% และ MobileNet V2 มีค่าความถูกต้อง 86% สามารถนำไปใช้ในการคัดแยกพุทราซึ่งเป็นประโยชน์ต่อเกษตรกร จากผลการวิจัยสำหรับการจัดเตรียมข้อมูลการจัดหมวดหมู่ที่มีคุณภาพที่แตกต่างกันชัดเจน สามารถปรับปรุงความถูกต้องของแบบจำลองโมเดลการคัดแยกพุทรามากยิ่งขึ้นได้

คำสำคัญ : การประมวลผลภาพ การเรียนรู้เชิงลึก การคัดแยกพุทรา

Abstract

This research presents the extraction of jujubes from photographs using a deep learning technique identify jujubes from photographs using the Inception V3 algorithm. Data sets used in this research are separated into four groups: a,b,c, and d, each group contains 300 images. Test data contains 50 images and data sets used to validate model contains 40 images for training and test models. The experimental results show that Inception V3 has the highest accuracy of 97%, compared to the accuracy of the CNN model of 89% and MobileNet V2 of 86%. It can be used for jujube classification, which is beneficial to farmers.

*ที่อยู่ติดต่อ E-mail address: thummarat.bo@ksu.ac.th

The research findings for the classification data with different quality. The accuracy of the jujube classification model can be further improved.

Keywords: Image processing, Deep Learning, Jujube classification

1. บทนำ

จังหวัดกาฬสินธุ์เป็นจังหวัดที่ตั้งอยู่ในภาคตะวันออกเฉียงเหนือของประเทศไทยมีเนื้อที่ประมาณ 6,946.75 ตารางกิโลเมตร หรือประมาณ 4.4 ล้านไร่ [1] อาชีพส่วนใหญ่เป็นเกษตรกร และหน่วยงานทางภาครัฐมีการสนับสนุนเกษตรกรรายย่อย ตำบลโพธิ์ อำเภอก้ามกุ้ง จังหวัดกาฬสินธุ์มีชื่อเสียงในเรื่องของผ้าไหมแพรวา และพุทรา ซึ่งได้รับการส่งเสริมความเข้มแข็งเศรษฐกิจชุมชน โดยการยกระดับผลผลิตพุทรานมสดของกลุ่มเกษตรกร ตำบลโพธิ์ อำเภอก้ามกุ้ง ในจังหวัดกาฬสินธุ์ “พุทราหวานบ้านโพธิ์” ผลไม้เศรษฐกิจที่สำคัญของจังหวัดกาฬสินธุ์ ซึ่งกลุ่มเกษตรกรได้ร่วมกันพัฒนาสายพันธุ์เป็น “พุทรากางมุ้ง” ผลไม้ปลอดสารพิษที่ขึ้นชื่อในเรื่องของรสชาติ เนื้อกรอบร่อน และผลใหญ่ ถือเป็นของฝากที่ได้รับความนิยมของนักท่องเที่ยวที่มาเยือนจังหวัดกาฬสินธุ์ ช่วยให้เกิดการส่งเสริมและสนับสนุนเกษตรกร ผู้ประกอบการ ซึ่งเป็นการพัฒนาศักยภาพชุมชนบ้านโพธิ์ให้เกิดรายได้ และมีอาชีพที่มั่นคง ยกระดับผลผลิตพุทราหวานบ้านโพธิ์เป็นสินค้าของดีประจำจังหวัดกาฬสินธุ์ ผู้บริโภคทั่วประเทศ จากการศึกษาข้อมูลพบว่าเกษตรกรมีปัญหาในการคัดแยกพุทราที่เมื่อนำพุทราลงเครื่องคัดแยก เครื่องจะสามารถแยกได้เพียงขนาด ไม่สามารถแยกคุณภาพของผลพุทราได้ ซึ่งพุทราที่มีลักษณะรูปทรงวงรี ติดลาย หรือมีรอยยุบของผล ถือว่าเป็นพุทราที่ไม่ผ่านคุณภาพ การแบ่งคุณภาพของพุทราจะแบ่งออกเป็น 4 เกรด เกรดที่ 1 มีขนาดเส้นผ่าศูนย์กลาง 6 เซนติเมตร เกรดที่ 2 มีขนาดเส้นผ่าศูนย์กลาง 4 เซนติเมตร เกรดที่ 3 มีขนาดเส้นผ่าศูนย์กลาง 3 เซนติเมตร เกรดที่ 4 พุทราที่ไม่ได้คุณภาพเกิดจากลักษณะของผลพุทราเป็นรูปวงรี ติดลาย หรือมีรอยยุบ

การประมวลผลภาพ (Image processing) ด้วยเทคนิคการเรียนรู้เชิงลึก (Deep learning) ถูกนำมาใช้ในงานคัดแยกภาพ การรู้จำภาพใบหน้า และการวินิจฉัยโรค เป็นต้น ได้รับความนิยมอย่างมาก และพบว่ามีนักวิจัยประยุกต์ใช้การเรียนรู้เชิงลึกมาใช้ประโยชน์กันอย่างแพร่หลายทั้งในและต่างประเทศมาช่วยแก้ปัญหาการจำแนกภาพซึ่งมีจุดเด่นที่สามารถสกัดลักษณะเด่นและการจำแนกรูป (Image classification) ได้ในขั้นตอนวิธีสอดคล้องกับงานวิจัย [2]-[4]

ด้วยเหตุผลข้างต้นผู้วิจัยจึงมีแนวคิดในการวิจัยการคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึกเพื่อคัดแยกพุทรา ด้วยการพิจารณาสี และขนาดของพุทรา เพื่อสะดวกต่อการคัดแยกพุทราได้อย่างถูกต้องและมีคุณภาพเพื่อเพิ่มมูลค่าของพุทราให้กับของเกษตรกรมากยิ่งขึ้น

1.1. การประมวลผลภาพ

การประมวลผลภาพเป็นกระบวนการประมวลผลข้อมูลจากการนำข้อมูลที่อยู่ในรูปภาพมาประมวลผลให้ภาพมีความชัดเจนการทำให้ภาพเบลอ การจัดการสัญญาณรบกวน การแบ่งกลุ่มจากคุณลักษณะของภาพ การติดตามวัตถุ และการสร้างประโยชน์ในด้านอื่น ๆ [3]

1.2. การจำแนกรูปภาพ

เป็นกลุ่มของเครือข่ายที่ได้รับแรงบันดาลใจจากชีวภาพที่ออกแบบมาเพื่อเลียนแบบวิสัยทัศน์ของมนุษย์ พวกเขาแบ่งโลกออกเป็นพื้นที่เล็ก ๆ ที่ทับซ้อนกันและรวมเข้าด้วยกันเพื่อให้เข้าใจเนื้อหาโดยรวม กระบวนการนี้ช่วยให้มนุษย์สามารถระบุคุณลักษณะต่าง ๆ ภายในพื้นที่ย่อยเหล่านี้เช่นเส้นและขอบสี เพื่อให้สามารถตีความเนื้อหาของภาพได้ โครงข่ายประสาทแบบคอนโวลูชันใช้อัลกอริทึมเพื่อเรียนรู้ถึงคุณลักษณะภาพและจัดหมวดหมู่ข้อมูล การประมวลผลภาพในโครงข่ายประสาทแบบคอนโวลูชัน เริ่มต้นด้วยการกำหนดตัวกรองหรือค่าเคอร์เนลซึ่งจะช่วยให้การดึงคุณลักษณะที่เกี่ยวข้องสำหรับการรับรู้วัตถุ โดยปกติแล้วตัวกรองเดียวจะดึงคุณลักษณะเฉพาะและต้องใช้ตัวกรองหลายตัวเพื่อจับภาพคุณลักษณะต่าง ๆ ภายในภาพ ความสามารถพิเศษของระบบการมองเห็นของมนุษย์ในการวิเคราะห์ข้อมูลภาพที่ซับซ้อนได้รับแรงบันดาลใจจากโครงข่ายประสาทแบบคอนโวลูชัน โดยการแบ่งขอบเขตการมองเห็นออกเป็นพื้นที่เล็ก ๆ มนุษย์สามารถมุ่งเน้นไปที่พื้นที่ที่สนใจได้ โดเมนประสาทสัมผัสเหล่านี้แสดงให้เห็นถึงการแยกคุณลักษณะที่ช่วยให้มนุษย์สามารถแยกแยะคุณลักษณะของแต่ละบุคคล เช่นขอบและความแตกต่างของสี การบูรณาการข้อมูลจากพื้นที่ย่อยที่แบ่งแยกเหล่านี้ช่วยให้มนุษย์สามารถรับรู้เนื้อหาโดยรวมและระบุวัตถุตามลักษณะร่วมกันได้ และเป็นเครือข่ายประสาทเทียมที่สร้างแรงบันดาลใจทางชีวภาพซึ่งเลียนแบบความสามารถของระบบการมองเห็นของมนุษย์ในการรับรู้และจำแนกวัตถุตามลักษณะของวัตถุ โครงข่ายประสาทแบบคอนโวลูชันสามารถจับภาพ และวิเคราะห์ข้อมูลภาพได้อย่างมีประสิทธิภาพโดยการแยกภาพออกเป็นพื้นที่ย่อยที่เล็กกว่าและรวมคุณลักษณะที่สำคัญ ตัวกรอง/เคอร์เนลหลายตัวช่วยให้โครงข่ายประสาทแบบคอนโวลูชันสามารถระบุและรวมคุณลักษณะต่าง ๆ เพื่อเพิ่มความสามารถในการรับรู้วัตถุ ด้วยชั้นโครงข่ายประสาทแบบคอนโวลูชัน ใช้การสกัดคุณลักษณะเพื่อประมวลผลภาพและดึงข้อมูลที่มีความหมาย เครือข่ายประสาทเทียมเซลล์กลายเป็นเทคโนโลยีที่สำคัญสำหรับงานจดจำภาพและแสดงให้เห็นถึงศักยภาพในการมองเห็นด้วยคอมพิวเตอร์การถ่ายภาพทางการแพทย์และการประยุกต์ใช้ยานพาหนะที่ขับเคลื่อนด้วยตนเอง [3]

1.3. การเรียนรู้เชิงลึก


การเรียนรู้เชิงลึกเป็นกระบวนการประมวลผลทางคอมพิวเตอร์ที่ใช้โครงข่ายประสาทเทียม (Neural Network: NN) ที่มีความลึกเพื่อเรียนรู้และทำนายผลลัพธ์ กระบวนการนี้เริ่มต้นด้วยการฝึกอบรมแบบจำลองโมเดลโดยให้มีการเรียนรู้จากชุดข้อมูล โดยที่แบบจำลองโมเดลจะปรับปรุงตัวเองให้มีความแม่นยำในการทำนายผลลัพธ์ที่ดีขึ้น [3]

โครงข่ายประสาทแบบคอนโวลูชัน เป็นเทคนิคหนึ่งในการเรียนรู้เชิงลึกที่ใช้โครงสร้างของโครงข่ายประสาทเทียม โดยมีการใช้หลายชั้นที่เรียกว่าชั้นซ่อน (Hidden layers) เพื่อค้นหาคุณลักษณะและทำการประมวลผลซ้ำอย่างมาเพื่อให้ได้ความแม่นยำในการแยกแยะคุณลักษณะ โดยพิจารณาจากความสัมพันธ์ระหว่างคุณลักษณะและผลลัพธ์ที่มีความสอดคล้องกันมากที่สุด ประกอบไปด้วยการทำงาน 3 ส่วน ดังนี้ [5]

1) Input คือ ข้อมูลที่รับเข้าสู่ขั้นตอนวิธี

2) Hidden layer คือ ส่วนของการประมวลผลเหมือนกับสมองมนุษย์ ทำหน้าที่ในการเรียนรู้การคัดแยกประเภท

3) Output คือ ส่วนแสดงผลการคัดแยกซึ่งเป็นผลมาจากการใช้ชั้นซ่อนจำนวนหลายชั้น วิเคราะห์จนได้คำตอบแสดงคลาส (Class) ของวัตถุ แสดงดังรูปที่ 1



รูปที่ 1. โครงข่ายประสาทแบบคอนโวลูชัน ดัดแปลงจาก [6]

การจำแนกรูปภาพโดยใช้เทคนิคคอนโวลูชันเป็นวิธีการแยกคุณลักษณะของรูปภาพ (Feature extraction) และข้อมูลการจัดหมวดหมู่ (Classification) ในอัลกอริทึมเดียวกัน เสนอครั้งแรกโดย Yann LeCun [5] เสนอวิธีการ Backpropagation สำหรับการรู้จำลายมือในชุดข้อมูล MNIST และได้รับความสนใจจากนักวิจัยมาจนถึงปัจจุบัน อัลกอริทึม CNN ทำงานโดยใช้การปรับน้ำหนักเพื่อลดฟังก์ชันข้อผิดพลาดผ่านการเผยแพร่ข้อผิดพลาดแบบย้อนกลับ

ณัฐวดี หงส์บุญมี และธีรพงศ์ อ่อนคำ [2] เสนอเทคนิคการตรวจสอบคุณภาพน้ำที่ใช้การเรียนรู้เชิงลึกเพื่อจำแนกคุณภาพน้ำโดยอัตโนมัติบนแอปพลิเคชันแอนดรอยด์ กระบวนการเริ่มจากการเก็บรวบรวมรูปภาพจำนวน 480 ภาพซึ่งถูกแบ่งออกเป็นสี่ระดับของคุณภาพน้ำคือ A, B, C และ D ภาพถูกนำมาใช้สำหรับการฝึกอบรมโมเดลที่ใช้ในการจำแนกคุณภาพน้ำ และทำการเปรียบเทียบอัลกอริทึมสามตัว ได้แก่ MobileNet 0.5, MobileNet 0.75 และ MobileNet 1.0 การประเมินโมเดลได้ถูกดำเนินการโดยใช้ความถูกต้อง ความแม่นยำ และความระลึก จากนั้นนำโมเดลไปพัฒนาเป็นแอปพลิเคชัน ขั้นตอนสุดท้ายทดสอบประสิทธิภาพแอปพลิเคชัน ผลการทดสอบพบว่า (1) MobileNet 1.0 เป็นโมเดลที่เหมาะสมมากที่สุด มีความถูกต้อง ความแม่นยำ และความระลึกทั้งหมดที่ 100.00% และ (2) ผลการทดสอบแอปพลิเคชันแสดงให้เห็นว่ามีอัตราส่วนความสำเร็จในการจำแนกอยู่ที่ 82.50% และมีประสิทธิภาพความแม่นยำที่ดี การประเมินแอปพลิเคชันโดยผู้เชี่ยวชาญ มีค่าเฉลี่ย 4.33 อยู่ในระดับความเหมาะสม ผลการทดสอบแสดงให้เห็นว่าวิธีการและแอปพลิเคชันนี้สามารถนำไปใช้เป็นเครื่องมือสำหรับตรวจสอบคุณภาพน้ำจากรูปภาพได้อย่างมีประสิทธิภาพและง่ายต่อการใช้งาน

นพรุจ พัฒนสาร และณัฐวดี ศรีวิบูลย์ [3] เสนอการประมวลผลสำหรับการจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์โดยนำการเรียนรู้เชิงลึกมาประยุกต์ใช้กับการคัดแยกคุณภาพของมะม่วง โดยจำลองการมองเห็นของมนุษย์ เก็บภาพมะม่วงที่ได้คุณภาพแบ่งเป็น 4 ระดับ คือ เกรด A, B, C และ D (เน่า) ปรากฏว่า การประมวลผลภาพโดยใช้โครงข่ายประสาทแบบคอนโวลูชัน มีความแม่นยำสูงสุดถึง 99.79% ต่อมาได้มีการพัฒนาแบบจำลองเป็นระบบต้นแบบการจำแนกคุณภาพมะม่วง อัตราความสำเร็จ 100%

ณัฐวดี หงส์บุญมี และณัฐพงศ์ จันทะวงศ์ [4] งานวิจัยนี้นำเสนอการพัฒนาระบบอัตโนมัติสำหรับวิเคราะห์ความหวานและพันธุ์แตงโมด้วยภาพถ่าย โดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกสำหรับใช้งานบนสมาร์ทโฟนเพื่ออำนวยความสะดวกสำหรับบุคคลทั่วไปที่ต้องการทราบชื่อพันธุ์และความหวานแตงโม ส่วนประกอบหลักของระบบประกอบด้วย (1) การสร้างโมเดลจำแนกพันธุ์และระดับความหวานของแตงโมด้วยโครงข่ายประสาทเทียมการเรียนรู้เชิงลึกผ่านไลบรารี TensorFlow โดยนำอัลกอริทึม InceptionV3 และ MobileNet มาทำการทดลองเปรียบเทียบการจำแนกภาพ ซึ่งฝึกสอนให้สามารถจำแนกภาพจำนวน 4 ประเภท ประเภทละ 100 ภาพ ฝึกสอนจำนวน 500 รอบ ผลการทดลองพบว่าโมเดลจากอัลกอริทึม InceptionV3 มีค่าความถูกต้องที่เท่ากับโมเดลจากอัลกอริทึม MobileNet ค่าความถูกต้องเท่ากับ 97.20% แต่จากการพิจารณาขนาดของโมเดลที่ได้จากการเรียนรู้ พบว่า MobileNet มีขนาดของโมเดลเล็กกว่า InceptionV3 ดังนั้นจึงเลือกโมเดลจาก MobileNet ไปพัฒนาระบบต่อไป (2) การนำโมเดลจากอัลกอริทึม MobileNet ไปพัฒนาเป็นแอปพลิเคชันบนสมาร์ทโฟน ดำเนินการพัฒนาด้วยโปรแกรม Android Studio ผลการทดสอบความพึงพอใจการใช้แอปพลิเคชันจากผู้ใช้งานพบว่าความพึงพอใจเฉลี่ยเท่ากับ 4.4 ส่วนเบี่ยงเบนมาตรฐาน 0.2 อยู่ในเกณฑ์ระดับดี สามารถสรุปได้ว่าแอปพลิเคชันนี้มีประสิทธิภาพสามารถนำไปใช้งานจริง

เทอดศักดิ์ เงินมูล และคณะ [7] สร้างรูปแบบการจำแนกประเภทของสตรอว์เบอร์รี่สุกโดยใช้เทคโนโลยี Support Vector Machine (SVM) การใช้เครื่องเวกเตอร์สนับสนุนแกนฐานรัศมีเพื่อบ่งชี้คุณสมบัติที่โดดเด่นจาก HSV histogram ของสตรอว์เบอร์รี่ งานวิจัยชิ้นนี้เน้นสตรอว์เบอร์รี่ 3 ประเภท คือ สตรอว์เบอร์รี่สุกงอมสูง และสุกเล็กน้อย โดยใช้ตัวอย่างสตรอว์เบอร์รี่สายพันธุ์พระราชทาน 80 จำนวน 80 ตัวอย่าง รุ่นนี้ใช้สตรอว์เบอร์รี่ 150 ตัวอย่างในการฝึกอบรมเพื่อให้ได้ค่าโหนดสี่สามระดับของความสุกโดยการแปลงค่า HSV histogram และเปรียบเทียบกับวงล้อสี สตรอว์เบอร์รี่สุกงอมสูงมีโหนดสีในช่วง 0-20 และ 340-359 สตรอว์เบอร์รี่สุกอยู่ในช่วง 0-75 และสตรอว์เบอร์รี่สุกเล็กน้อยอยู่ในช่วง 25-100 แบบจำลองนี้ถูกออกแบบมาเพื่อจำแนกสตรอว์เบอร์รี่สุกได้อย่างมีประสิทธิภาพโดยการดึงคุณสมบัติที่โดดเด่นจาก HSV Histogram โดยใช้เทคโนโลยี SVM เพื่อให้กลุ่มตัวอย่างสตรอว์เบอร์รี่สุก

Okafor และคณะ [8] ศึกษาวิจัยเรื่องการเปรียบเทียบวิธีการที่ใช้สำหรับรู้จำสัตว์เปรียบเทียบระหว่างวิธีการเรียนรู้เชิงลึก CNN และวิธี Back of Word (BOW) การทดสอบวิธีการ BOW นั้นได้ทดสอบทั้งสี่รูปแบบคือวิธี BOW และ Histograms of Oriented Gradients BOW (HOG-BOW) ซึ่งได้ทดสอบทั้งภาพสีและภาพสีเทาและใช้วิธีการ L2-SVM ในการจัดหมวดหมู่ของรูปภาพสัตว์ สำหรับการทดสอบด้วยวิธี CNN นั้น ได้ทดสอบกับโครงสร้างแบบ AlexNet และ GoogLeNet โดยลดจำนวนของนิวรอน (Neurons) ในแต่ละชั้นของโครงสร้างลง โดยได้ทดสอบกับข้อมูลชุด Wild-Anim ซึ่งมีจำนวน 5 กลุ่ม และมีรูปภาพทั้งสิ้น 5,000 รูปภาพ ซึ่งรูปภาพทุกรูปเป็นภาพสีแบบ RGB และปรับให้มีขนาด 250x250 พิกเซล สำหรับการทดสอบ ได้แบ่งข้อมูลออกเป็น 5 ชุด ด้วยวิธีการของ Cross- Validation เพื่อทดสอบความถูกต้องและความเบี่ยงเบนมาตรฐาน จากงานวิจัยแสดงให้เห็นว่าวิธี CNN โดยใช้โครงสร้างของ GoogLeNet ให้ประสิทธิภาพที่ดีที่สุดโดยมีความถูกต้อง 99.93% เมื่อเทียบกับวิธี BOW มีอัตราความถูกต้องที่ 84% แต่เมื่อทำการลดจำนวนของนิวรอนลงปรากฏว่าอัตราการรู้จำด้วย GoogLeNet กลับลดลงเป็น 99.38%

Sladojevic และคณะ [9] ศึกษาวิจัยเรื่องการรู้จำพันธุ์พืชที่เป็นโรคโดยการจัดหมวดหมู่จากใบไม้ด้วยโครงข่ายประสาทเทียมเชิงลึก จำนวนทั้งสิ้น 13 ประเภทและรวมกับสภาพใบที่เป็นปกติอีก 2 ประเภท รวมเป็น 15 กลุ่ม โดยตรวจสอบจากใบไม้เป็นหลักด้วยวิธีโครงข่ายประสาทแบบคอนโวลูชัน ซึ่งรูปภาพใบไม้ที่นำมาใช้ในการทดสอบนั้นถูกนำไปประมวลผลเพื่อเพิ่มเติมข้อมูลในการเรียนรู้ (Augmented) โดยใช้วิธีการประมวลผลภาพ การนำภาพไปบิดให้ผิดรูปและการหมุนภาพ เป็นต้น ข้อมูลที่ใช้ในการทดสอบประกอบด้วยรูปภาพจำนวน 4,483 รูป และเมื่อนำไปผ่านกระบวนการ Data Augmentation จะได้รูปภาพเพิ่มขึ้นเป็น 30,880 รูป พบว่ามีอัตราความถูกต้อง 96.3%

Di Zang และคณะ [10] ศึกษาวิจัยเรื่องการเรียนรู้เชิงลึกมาประยุกต์ใช้การรู้จำป้ายทะเบียนรถยนต์โดยการแบ่งส่วนภาพป้ายทะเบียนออกเป็น 7 ส่วน และนำภาพแต่ละส่วนมาเข้ากระบวนการฮิสโตแกรมฟิกเชล เพื่อหาคุณสมบัติตัวอักษรด้วยการตรวจสอบช่วงการสะสมฟิกเชลจากฮิสโตแกรม และแบ่งแยกตัวอักษรป้ายทะเบียน จากนั้นทำการประมวลผลภาพด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อนำคุณลักษณะเด่นที่ได้มาเข้าสู่กระบวนการจำแนกประเภทข้อมูลแบบซัพพอร์ตเวกเตอร์แมชชีน ผลการทดลองโครงข่ายประสาทแบบคอนโวลูชันนั้น จะทำการแบ่งย่อยทดลองตามจำนวนระดับชั้นซ่อนเป็น 2 และ 3 ระดับชั้นซ่อน ซึ่งให้ผลการรู้จำตัวอักษรและตัวเลขได้ 94% - 97% ผลการทดลอง SVM รวมกับโครงข่ายประสาทแบบคอนโวลูชัน 3 ระดับชั้นซ่อนนั้น ให้ผลการรู้จำตัวอักษรและตัวเลขสูงถึง 97% - 98% ซึ่งเป็นผลลัพธ์ที่ดีกว่าการใช้การรู้จำแบบ SVM หรือโครงข่ายประสาทแบบคอนโวลูชันเพียงชนิดเดียว

2. วิธีการทดลอง

งานวิจัยนี้เสนอวิธีการคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึก ซึ่งประกอบด้วย 3 ขั้นตอนดังนี้ 1) การเตรียมข้อมูล 2) การสร้างแบบจำลอง และ 3) การวัดประสิทธิภาพ

2.1 การเตรียมข้อมูล


การเตรียมข้อมูลภาพได้เก็บรวบรวมข้อมูลภาพพุทราพันธุ์นมสด คณะผู้วิจัยจัดสภาพแวดล้อมในการถ่ายภาพพุทราพันธุ์นมสด โดยถือกล้องด้วยมือและเว้นระยะระหว่างจากผลพุทราพันธุ์นมสด 20 ถึง 30 เซนติเมตร เนื่องจากเวลานำไปใช้งานเกษตรกรไม่จำเป็นต้องมีขาตั้งกล้องแต่ถ่ายภาพในระยะระหว่าง 20 ถึง 30 เซนติเมตร โมเดลจะสามารถทำนายได้ถูกต้อง การถ่ายภาพจะวางพุทราพันธุ์นมสดไว้บนพื้นกระดาษสีขาว ในการถ่ายภาพพุทราพันธุ์นมสด 1 ลูกจะทำการถ่าย 5 ด้าน ได้แก่ ด้านหน้า ด้านข้าง-ซ้าย ด้านข้าง-ขวา ด้านหลัง และด้านบน แสดงดังรูปที่ 2 กำหนดขนาดของภาพ 500 x 600 พิกเซล ขั้นตอนการจัดกลุ่มคุณภาพพุทราพันธุ์นมสดดำเนินการโดยสอบถามการจำแนกคุณภาพของพุทราในแต่ละกลุ่มจากผู้เชี่ยวชาญที่เป็นเจ้าของสวนพุทราพันธุ์นมสด โดยมีการจัดกลุ่มไว้ดังนี้ เกรด A เกรด B เกรด C และ เกรด D เป็นพุทราที่ไม่ได้คุณภาพ ข้อมูลภาพพุทรา จำนวน 1,560 ภาพ แบ่งชุดข้อมูลข้อมูลเรียนรู้ (Training) จำนวน 1,200 ภาพ และชุดข้อมูลทดสอบ (Test) จำนวน 200 ภาพ และชุดข้อมูลตรวจสอบ (Validation) จำนวน 160 ภาพ แสดงดังรูปที่ 3-6




รูปที่ 2. ถ่ายภาพพุทราพันธุ์มสดทั้ง 5 ด้าน




รูปที่ 3. รูปภาพพุทราเกรด A จำนวน 300 รูป



รูปที่ 4. รูปภาพพุทราเกรด B จำนวน 300 รูป



รูปที่ 5. รูปภาพพุทราเกรด C จำนวน 300 รูป




รูปที่ 6. รูปภาพพุทราเกรด D จำนวน 300 รูป

2.2 การสร้างแบบจำลอง

การสร้างแบบจำลองงานวิจัยการคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึกใช้โครงข่าย CNN โดยใช้ภาษา Python เรียกใช้ไลบรารี Tensorflow 2.x และ Keras ผู้วิจัยได้ดำเนินการ 2 ขั้นตอน คือ ขั้นตอนการเรียนรู้ เพื่อสร้างแบบจำลองและขั้นตอนของการทดสอบแบบจำลอง การสร้างแบบจำลอง เป็นขั้นตอนการสร้างการเรียนรู้ โดยใช้ข้อมูลรูปภาพพุทราพันธุ์มสดีที่ได้จัดกลุ่มระดับเกรด A เกรด B เกรด C และเกรด D กลุ่มละ 300 รูป รวม 1,200 รูป สำหรับใช้ในการเรียนรู้ และสำหรับใช้ทดสอบ ใช้ ภาพพุทราเกรด A เกรด B เกรด C และเกรด D กลุ่มละ 50 รูป รวม 200 รูป โดยแต่ละภาพจะถูกลดขนาด

224 x 224 พิกเซล โดยงานวิจัยนี้ใช้การกำหนดการฝึกสอนให้แบบจำลองการเรียนรู้ จำนวน 50 รอบ จากนั้นเพื่อตรวจสอบคุณภาพโมเดลแบบจำลองจึงนำภาพพุทราใช้เป็นชุดตรวจสอบ โดยใช้ภาพพุทราเกรด A เกรด B เกรด C และเกรด D กลุ่มละ 40 รูป รวม 160 รูป แสดงดังรูปที่ 7



รูปที่ 7. การทำงานของโครงสร้างแบบจำลองการเรียนรู้ของงานวิจัย

2.3 การวัดประสิทธิภาพ

การวัดประสิทธิภาพแบบจำลองการคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึกเพื่อหาค่าความถูกต้องของโมเดล โดยใช้ค่าความแม่นยำเป็นตัวชี้วัดร้อยละของข้อมูลที่แบบจำลองทำนายได้ถูกต้องทั้งหมด ดังสมการที่ (1)

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

โดยที่ **TP** (True Positive) คือ ค่าที่พยากรณ์ถูก และอยู่ในคลาสที่ถูกต้อง

TN (True Negative) คือ ค่าที่พยากรณ์ถูก และอยู่ในคลาสที่ไม่ถูกต้อง

FP (False Positive) คือ ค่าที่พยากรณ์ผิดพลาด และอยู่ในคลาสที่ถูกต้อง

FN (False Negative) คือ ค่าที่พยากรณ์ผิดพลาด และอยู่ในคลาสที่ไม่ถูกต้อง

3. ผลการทดลองและวิจารณ์

3.1 สรุปผลการสร้างแบบจำลอง

การสร้างแบบจำลองโมเดลเพื่อจำแนกคุณภาพเกรดพุทราพันธุ์นวมสด ในการสร้างแบบจำลองโมเดลเพื่อใช้ในระบบการประมวลผลภาพโดยใช้ไลบรารี Keras และ Tensorflow โมเดล InceptionV3 เป็นโมเดลการเรียนรู้เชิงลึกที่ได้รับการฝึกฝนล่วงหน้าซึ่งใช้สำหรับงานจัดหมวดหมู่รูปภาพ ใช้ภาพอินพุตขนาด 224 x 224 พิกเซล และมีน้ำหนักที่ฝึกไว้ล่วงหน้าจากชุดข้อมูล Imagenet กำหนดให้ include_top เป็นค่า False เพื่อไม่รวมเลเยอร์การจัดหมวดหมู่ชั้นสุดท้ายของโมเดล

inception layers เป็นตัวแปรที่แสดงถึงเลเยอร์ทั้งหมดของโมเดล InceptionV3

layer.trainable เป็นพารามิเตอร์ที่กำหนดว่าน้ำหนักของเลเยอร์จะได้รับการอัปเดตระหว่างการฝึกหรือไม่ เลเยอร์ทั้งหมดของโมเดล InceptionV3 ถูกตั้งค่าเป็น False

GlobalAveragePooling2D เป็นเลเยอร์ที่ใช้เอาต์พุตของเลเยอร์ก่อนหน้า และคำนวณค่าเฉลี่ยสำหรับแต่ละคุณลักษณะ จากนั้นจะใช้เอาต์พุตของโมเดล InceptionV3 และคำนวณค่าเฉลี่ยสำหรับแต่ละคุณลักษณะตามมิติเชิงพื้นที่

Dense เป็นเลเยอร์ที่เชื่อมต่ออย่างสมบูรณ์ซึ่งรับเอาต์พุตของเลเยอร์ก่อนหน้าและใช้การแปลงเชิงเส้นกับเลเยอร์ ใช้เอาต์พุตของเลเยอร์ GlobalAveragePooling2D และใช้การแปลงเชิงเส้นกับหน่วยเอาต์พุต 256 หน่วยและใช้งานฟังก์ชัน relu

Dropout สุ่มตั้งค่า 20% ของหน่วยเป็น 0 หลังจากชั้น Dense กระบวนการข้างต้นของเลเยอร์ Dense และ Dropout ทำซ้ำสองครั้งโดยมีหน่วยเอาต์พุต 128 และ 64 หน่วย

การจำแนกเป็นเลเยอร์เอาต์พุตสุดท้ายซึ่งจะได้ Output ของเลเยอร์ Dropout สุดท้ายและใช้การแปลงเชิงเส้นที่มีเอาต์พุต 4 หน่วยและใช้งานฟังก์ชัน Softmax เพื่อส่งออกความน่าจะเป็นของการทำนายของแต่ละหมวดหมู่ใน 4 คลาส Pseudo Code แสดงดังรูปที่ 8 และโครงสร้างสถาปัตยกรรมของ InceptionV3 แสดงดังรูปที่ 9


```
inception_model = โมเดล InceptionV3 ตั้งค่า include_top = False
for layer in inception_model.layers:
    layer.trainable = False
global_pooling_layer = เลเยอร์ GlobalAveragePooling2D(inception_model.output)
dense_layer_1 = เลเยอร์ Dense(units=256,
activation='relu')(global_pooling_layer.output)
dropout_layer_1 = เลเยอร์ Dropout(rate=0.2)(dense_layer_1.output)
dense_layer_2 = เลเยอร์ Dense(units=128, activation='relu')(dropout_layer_1)
dropout_layer_2 = เลเยอร์ Dropout(rate=0.2)(dense_layer_2)
dense_layer_3 = เลเยอร์ Dense(units=64, activation='relu')(dropout_layer_2)
dropout_layer_3 = เลเยอร์ Dropout(rate=0.2)(dense_layer_3)
output_layer = เลเยอร์ Dense(units=4, activation='softmax')(dropout_layer_3)
model = โมเดล (inputs=inception_model.input, outputs=output_layer)
```

รูปที่ 8. Pseudo Code สถาปัตยกรรมของ InceptionV3

activation_85 (Activation)	(None, 5, 5, 320)	0	['batch_normalization_85[0][0]']
mixed9_1 (Concatenate)	(None, 5, 5, 768)	0	['activation_87[0][0]', 'activation_88[0][0]']
concatenate_1 (Concatenate)	(None, 5, 5, 768)	0	['activation_91[0][0]', 'activation_92[0][0]']
activation_93 (Activation)	(None, 5, 5, 192)	0	['batch_normalization_93[0][0]']
mixed10 (Concatenate)	(None, 5, 5, 2048)	0	['activation_85[0][0]', 'mixed9_1[0][0]', 'concatenate_1[0][0]', 'activation_93[0][0]']
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0	['mixed10[0][0]']
dense (Dense)	(None, 256)	524544	['global_average_pooling2d[0][0]']
dropout (Dropout)	(None, 256)	0	['dense[0][0]']
dense_1 (Dense)	(None, 128)	32896	['dropout[0][0]']
dropout_1 (Dropout)	(None, 128)	0	['dense_1[0][0]']
dense_2 (Dense)	(None, 64)	8256	['dropout_1[0][0]']
dropout_2 (Dropout)	(None, 64)	0	['dense_2[0][0]']
dense_3 (Dense)	(None, 4)	260	['dropout_2[0][0]']
=====			
Total params: 22,368,740			
Trainable params: 565,956			
Non-trainable params: 21,802,784			

รูปที่ 9. โครงสร้างสถาปัตยกรรมของ InceptionV3

กราฟแสดงผลค่าผิดพลาด (Loss) ที่เกิดจากโครงสร้างสถาปัตยกรรมของ InceptionV3 การสร้างแบบจำลองโมเดลที่ถูกคำนวณจากแต่ละรอบการเรียนรู้ของโมเดล InceptionV3 แสดงดังรูปที่ 10



รูปที่ 10. ผลการวัดค่า Loss ของแบบจำลองโมเดล InceptionV3

รูปที่ 10 แสดงกราฟค่าผิดพลาดจากการเรียนรู้จากชุดข้อมูล (Train loss) เปรียบเทียบกับกราฟแสดงผลค่าผิดพลาดจากการเรียนรู้จากชุดข้อมูล (Validation loss) มีแนวโน้มที่ได้โมเดลแบบจำลองที่มีการเรียนรู้ที่สามารถนำโมเดลแบบจำลองไปทำนายหรือจำแนกกับชุดข้อมูลใหม่ ๆ ได้ดี

3.2 การนำแบบจำลองไปใช้งาน

จากการสร้างแบบจำลองการคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึก ผู้วิจัยได้นำแบบจำลองโมเดลที่สร้างโดยใช้ภาษา Python เรียกใช้ไลบรารีจาก Tensorflow และ Keras จากนั้นได้นำโมเดลแบบจำลองไปทดสอบกับชุดข้อมูลทดสอบ ผู้วิจัยได้นำภาพพุทราพันธุ์มสดีในชุดทดสอบที่จัดกลุ่มคุณภาพเกรดไว้ 4 กลุ่ม กลุ่มละ 50 รูป ประกอบด้วย คุณภาพพุทราเกรด A จำนวน 50 รูป คุณภาพพุทราเกรด B จำนวน 50 รูป คุณภาพพุทราเกรด C จำนวน 50 รูป และคุณภาพพุทราเกรด D จำนวน 50 รูป รวมทั้งหมดจำนวน 200 ภาพ

3.3 คุณสมบัติทางกายภาพของพุทรา

พุทราที่นำมาคัดขนาด คือ พุทราพันธุ์มสดี โดยแบ่งเป็น 4 เกรดดังนี้

- 1) พุทราเกรดเล็ก ขนาด 2.90 – 3.49 เซนติเมตร
- 2) พุทราเกรดกลาง ขนาด 3.50 – 4.49 เซนติเมตร
- 3) พุทราเกรดใหญ่ ขนาด 4.50 – 6.50 เซนติเมตร
- 4) พุทราโดยที่ขนาดตกเกรด เป็นพุทราที่มีผลขนาดเล็ก ขนาดกลาง และขนาดใหญ่ ลักษณะผลเป็น

รูปวงรี ติดลายหรือมีรอยยุบขนาดเส้นผ่าศูนย์กลางของพุทราพันธุ์มสดีแปรผันโดยตรงกับขนาด และน้ำหนัก ซึ่งเป็นไปตามการจำแนกคุณภาพของพุทราแต่ละขนาดโดยผู้เชี่ยวชาญที่เป็นเจ้าของสวนพุทรา

3.4 การเปรียบเทียบประสิทธิภาพแบบจำลองโมเดล

ผู้วิจัยได้ทดลองเปรียบเทียบประสิทธิภาพแบบจำลองโมเดล จำนวน 3 โมเดล กำหนดให้เรียนรู้จำนวน 50 รอบ ผลการเปรียบเทียบพบว่า InceptionV3 มีความแม่นยำ 97% และค่าผิดพลาดจากการเรียนรู้จากชุดข้อมูล 0.08 ซึ่งมีประสิทธิภาพที่ดีกว่าแบบจำลองโมเดลอื่น ๆ CNN และ MobileNetV2 มีความแม่นยำ 89% และ 86% ตามลำดับและค่าผิดพลาดจากการเรียนรู้จากชุดข้อมูล คือ 0.23 และ 0.24 ตามลำดับ ดังตารางที่ 1

ตารางที่ 1. เปรียบเทียบประสิทธิภาพของแบบจำลองโมเดล

เทคนิควิธี	Epoch	Validation loss	Accuracy
CNN	50	0.23	89
MobileNetV2	50	0.24	86
InceptionV3	50	0.08	97


3.5 ผลการวัดประสิทธิภาพแบบจำลองโมเดล

บทวิจัยได้สร้างแบบจำลองโมเดลสำหรับคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึกนั้นสามารถประมวลผลในการดึงคุณลักษณะเด่นของภาพพุทราได้อย่างมีประสิทธิภาพ เนื่องจากอัลกอริทึม InceptionV3 มีจุดเด่นในการดึงลักษณะเด่นของภาพพุทราได้ ทั้งภาพสี การหาขอบภาพ ที่มีลักษณะแตกต่างกันได้ดี InceptionV3 จะหาความสัมพันธ์ของวัตถุได้จากแต่ละชั้นของเลเยอร์ทำให้ได้ผลลัพธ์ที่ดีที่สุดได้ ดังตารางที่ 2

ตารางที่ 2. ผลการวัดประสิทธิภาพความถูกต้องของการแยกพุทรา

คุณภาพ	จำนวนภาพ	ผลการจำแนกถูกต้อง (ภาพ)	ความถูกต้อง (ร้อยละ)
เกรด A	50	46	92
เกรด B	50	49	98
เกรด C	50	50	100
เกรด D	50	50	100
รวม	200	195	97

จากตารางที่ 2 แสดงให้เห็นถึงความถูกต้องของการจำแนกพุทราโดยใช้เทคนิคการเรียนรู้ลึก ผลการทดลองแสดงให้เห็นว่าทุกเกรดของพุทรามีความแม่นยำสูง ซึ่งเกรด C และ D มีค่าความถูกต้องสูง โดยค่าความถูกต้องของการจำแนกเป็น 100% ความถูกต้องโดยรวม 97% แสดงให้เห็นว่าเทคนิคการเรียนรู้ลึกที่ใช้ในการศึกษานี้มีประสิทธิภาพในการจำแนกพุทราจากภาพ และแสดงคลาสที่ทำนายถูกต้องและคลาสที่ทำนายผิดด้วยตาราง Confusion Matrix แสดงดังรูปที่ 11



รูปที่ 11. ผลการทำนายในแต่ละคลาสด้วย Confusion Matrix

จากตารางที่ 2 และรูปที่ 11 ผลการทำนายของคลาส เกรด C และเกรด D จากตารางที่ 2 และหมายเลข 2 และ 3 ในรูปที่ 11 มีความถูกต้องของการทำนายร้อยละ 100 เนื่องจากภาพพุทรามีคุณลักษณะที่ขนาดเล็ก กลาง ใหญ่และมีลายหรือมีรอยยุบบนพื้นผิวพุทราชัดเจน และคลาส เกรด A จากตารางที่ 2 และหมายเลข 0 ในรูปที่ 11 ผลการทำนายมีความถูกต้องน้อยที่สุด ร้อยละ 92 เนื่องจากภาพพุทราที่มีคุณลักษณะที่มีขนาดและสีบางภาพมีพิกเซลคล้ายกับคลาสจากเกรด B ทำให้ทำนายผิดพลาดจำนวน 4 ภาพ ดังนั้นหากเตรียมภาพพุทราให้มีคุณลักษณะของขนาดและสีที่แตกต่างกันจะทำให้การจำแนกค่าความถูกต้องสูงขึ้นได้

4. สรุปผลการทดลอง

งานวิจัยนี้ได้ทำการเตรียมข้อมูลเรียนรู้และชุดข้อมูลทดสอบที่เหมาะสมในการคัดแยกพุทราจากภาพถ่ายด้วยเทคนิคการเรียนรู้เชิงลึก จากผลการทดลองในงานวิจัยครั้งนี้ผู้วิจัยได้ใช้อัลกอริทึม Inception V3 สำหรับนำมาประมวลผลภาพสำหรับสร้างแบบจำลองโมเดลเพื่อคัดแยกและจำแนกพุทราพันธุ์มสดีจากภาพถ่าย โดยได้ดำเนินการเก็บรวบรวมข้อมูลภาพถ่ายพุทราจากเจ้าของสวนพุทราพันธุ์มสดีและเก็บรวบรวมข้อมูลข้อมูลรูปภาพพุทราพันธุ์มสดีที่ได้จัดกลุ่มระดับเกรด A เกรด B เกรด C และเกรด D กลุ่มละ 300 รูป รวม 1,200 รูป สำหรับใช้ในการเรียนรู้ และสำหรับใช้ทดสอบ ใช้ภาพพุทราเกรด A เกรด B เกรด C และเกรด D กลุ่มละ 50 รูป รวม 200 รูป โดยแต่ละภาพจะถูกลดขนาดเป็น 224×224 พิกเซล จากนั้นได้ทำการเปรียบเทียบประสิทธิภาพแบบจำลองโมเดล จำนวน 3 โมเดล ได้แก่ โครงข่ายประสาทแบบคอนโวลูชัน MobileNetV2 และ InceptionV3 กำหนดให้เรียนรู้จำนวน 50 รอบ ผลการเปรียบเทียบพบว่า InceptionV3 มีความแม่นยำ 97% และค่าผิดพลาดจากการเรียนรู้จากชุดข้อมูล 0.08 ซึ่งมีประสิทธิภาพที่ดีกว่าแบบจำลองโมเดลอื่น ๆ โดยที่ โครงข่ายประสาทแบบคอนโวลูชัน และ MobileNetV2 มีความแม่นยำ 89% และ 86% ตามลำดับ ค่าผิดพลาดจากการเรียนรู้จากชุดข้อมูล คือ 0.23 และ 0.24 ตามลำดับ ดังตารางที่ 2 แสดงให้เห็นถึงประสิทธิภาพของแบบจำลองโมเดลจำแนกภาพพุทราพันธุ์มสดีจากภาพถ่ายและพบว่า การนำเทคนิคการเรียนรู้เชิงลึกด้วยอัลกอริทึม InceptionV3 มาประยุกต์ใช้ในการวิจัยนั้น มีประสิทธิภาพในการจำแนกพุทราจากภาพถ่าย สามารถคัดแยกคุณภาพของพุทราได้จริง ผลการวิจัยแสดงให้เห็นว่าวิธีการที่เสนอมีความแม่นยำ 97% ซึ่งเน้นประสิทธิภาพของเทคนิคการเรียนรู้เชิงลึกที่ใช้ในการระบุพุทราจากภาพถ่าย นอกจากนี้ยังชี้ให้เห็นว่าการเตรียมข้อมูลการเรียนรู้ที่มีลักษณะที่แตกต่างชัดเจนและหลากหลายสามารถเพิ่มความแม่นยำของการจำแนกประเภทได้ แนวทางการเรียนรู้เชิงลึกที่พัฒนาขึ้นมีศักยภาพที่จะเป็นประโยชน์ต่อเกษตรกรและผู้ประกอบการ การวิจัยนี้ก่อให้เกิดความก้าวหน้าของเทคโนโลยีดิจิทัลสำหรับการใช้งานทางการเกษตร

สำหรับข้อเสนอแนะ ควรเตรียมข้อมูลเรียนรู้ให้มีคุณลักษณะที่แตกต่างกันชัดเจนและหลากหลายจะทำให้การจำแนกมีความแม่นยำมากยิ่งขึ้น และการทดลองควรทำแบบ 10 fold validation เพิ่มเติมเพื่อเพิ่มการเรียนรู้ที่ดีให้กับการสร้างโมเดล และแบบจำลองโมเดล สามารถนำไปประยุกต์ร่วมกับการพัฒนาเป็นแอปพลิเคชันบนสมาร์ตโฟนได้

เอกสารอ้างอิง (References)

- [1] สำนักงานแรงงานจังหวัดกาฬสินธุ์. 2564. ภูมิประเทศ. แหล่งข้อมูล : <https://kalasin.mol.go.th/>. ค้นเมื่อวันที่ 20 ตุลาคม 2564.
- [2] ณัฐวดี หงษ์บุญมี และธีรพงศ์ อ่อนคำ. 2565. การจำแนกระดับคุณภาพน้ำด้วยการเรียนรู้เชิงลึกผ่านแอปพลิเคชันระบบปฏิบัติการแอนดรอยด์. *วารสารวิทยาการและเทคโนโลยีสารสนเทศ*, 12(2), 31-41. [Nattavadee Hongboonmee and Thirapong Oonkham. 2022. Classification of Water Quality Level using Deep Learning on Android Application. *Journal of Information Science and Technology*, 12(2), 31-41. (in Thai)]
- [3] นพรุจ พัฒนสาร และณัฐวดี ศรีวิบูลย์. 2563. การประมวลผลภาพสำหรับการจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์โดยการจำลองการมองเห็นของมนุษย์ด้วยวิธีการเรียนรู้เชิงลึก. *วารสารวิทยาการและเทคโนโลยีสารสนเทศ*, 10(1), 24-29. [Nopparut Pattansarn and Nattavut Sriwiboon. 2020. Image Processing for Classifying the Quality of the Chok-Anan Mango by Simulating the Human Vision using Deep Learning. *Journal of Information Science and Technology*, 10(1), 24-29. (in Thai)]
- [4] ณัฐวดี หงษ์บุญมี และณัฐพงศ์ จันตะวงษ์. 2563. การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกเพื่อวัดระดับความหวานของแตงโมผ่าน สมาร์ทโฟน. *วารสารวิทยาการและเทคโนโลยีสารสนเทศ*, 10(1), 59-69. [Nattavadee Hongboonmee and Nutthapong Jantawong. 2020. Apply of Deep Learning Techniques to Measure the Sweetness Level of Watermelon via Smartphone. *Journal of Information Science and Technology*, 10(1), 59-69. (in Thai)]
- [5] Yann, L., Bottou, L., Bengio, Y. and Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [6] Arif, R.B., Siddique, M.A.B., Khan, M.M.R. and Oishe, M.R. 2018. Study and Observation of the Variations of Accuracies for Handwritten Digits Recognition with Various Hidden Layers and Epochs using Convolutional Neural Network. *Proceedings 4th IEEE International Conference on Electrical Engineering and Information & Communication Technology (iCEEICT 2018)*, 112-117.
- [7] เทอดศักดิ์ เงินมูล, พิเชษฐ เหมยคำ, วิโรจน์ ปงลังกา และวิวัฒน์ ทิพจร. 2560. การคัดแยกความสุกสตรอเบอร์รี่ด้วยซัพพอร์ตเวกเตอร์แมชชีน. *วิศวกรรมสาร มหาวิทยาลัยนครสวรรค์*, 12(2), 55-62. [Therdsak Ngermoon, Pichet Moeikham, Wirot Ponglanka and Wiwat Tippachon. 2017. Strawberry Ripeness Classification by Support Vector Machine. *Naresuan University Engineering Journal*, 12(2), 55-62. (in Thai)]
- [8] Okafor, E., et al. 2016. Comparative Study Between Deep Learning and Bag of Visual Words for Wild-Animal Recognition. *Proceedings IEEE Symposium Series on Computational Intelligence*, Athens, Greece, 1-8.
- [9] Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D. and Stefanovic, D. 2016. Deep

Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification.
Computational Intelligence and Neuroscience, 2016, 3289801.

- [10] Zang, D., Chai, Z., Zhang, J., Zhang, D. and Cheng, J. 2015. Vehicle license plate recognition using visual attention model and deep learning. *Journal of Electronic Imaging*, 24(3), 1-10.