



การจำแนกระดับความหวานของสับปะรดโดยใช้การเรียนรู้เชิงลึก Pineapple Sweetness Classification using Deep Learning

ศรัญญา กาญจนวัฒนา^{1*} วรวิทย์ ตีรวadhanaprapha¹ ปัญญชลิ ปราณีตพลกรัง²
และ กัญจน์ ภักดีสงคราม³

Sarunya Kanjanawattana^{1*} Worawit Teerawatthanaprapha¹ Panchalee Praneetpholkrang²
and Gun Bhakdisongkham³

สาขาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี¹

สาขาวิชาเทคโนโลยีการจัดการ สำนักวิชาเทคโนโลยีสังคม มหาวิทยาลัยเทคโนโลยีสุรนารี²

สาขาวิชาเวชศาสตร์ฟื้นฟู สำนักวิชาแพทยศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี³

School of Computer Engineering, Institute of Engineering, Suranaree University of Technology¹

School of Management Technology, Institute of Social Technology, Suranaree University of Technology²

School of Physical Medicine and Rehabilitation, Institute of Medicine, Suranaree University of Technology³

*Corresponding Author: sarunya.k@sut.ac.th

ข้อมูลบทความ	บทคัดย่อ
ประวัติบทความ: รับเพื่อพิจารณา: 29 ธันวาคม 2564 แก้ไข: 4 มีนาคม 2565 ตอบรับ: 23 เมษายน 2565	สับปะรดเป็นพืชเศรษฐกิจที่สำคัญของประเทศไทย โดยมูลค่าขึ้นอยู่กับความหวานของสับปะรด การหาความหวานของผลไม้สามารถทำได้โดยใช้เครื่องหาความหวานแบบส่องหรือเครื่องมืออื่นๆ แต่จำเป็นต้องใช้บุคลากรที่มีประสบการณ์ อีกทั้งการวัดความหวานผลไม้ที่ละลูกสิ้นเปลืองกำลังคนและเวลา ดังนั้นในการวิจัยนี้จึงได้พัฒนาวิธีการจำแนกระดับความหวานของสับปะรดโดยพิจารณาจากลักษณะทางกายภาพที่ปรากฏให้เห็นบนรูปภาพด้วยวิธีการวิเคราะห์ทางการเรียนรู้เชิงลึกชื่อว่า AlexNet ซึ่งทำงานร่วมกับข้อมูลรูปภาพสับปะรดที่มีผลสีเหลือง ได้ทำการแบ่งข้อมูลออกเป็น 4 คลาส ตั้งแต่ M1 ถึง M4 เรียงตามระดับความหวานจากน้อยไปมาก และแบ่งข้อมูลออกเป็นข้อมูลฝึกสอนร้อยละ 80 และข้อมูลทดสอบร้อยละ 20 การทดลองในงานวิจัยนี้แบ่งออกเป็น 5 การทดลองที่มีจำนวน epoch ต่างกันทำงานร่วมกับข้อมูลที่เตรียมไว้ จากผลการทดลองสามารถสรุปได้ว่าโมเดล AlexNet ที่ให้ผลลัพธ์ที่ดีที่สุดคือโมเดลที่มีการฝึกสอน 10 epoch ทำงานร่วมกับข้อมูลที่สมดุลและมีขนาด 120 รูปต่อคลาส โมเดลสามารถให้ความถูกต้อง 91.78% และได้ค่า F1 score อยู่ที่ 92.31%
คำสำคัญ: ความหวานของสับปะรด/การเรียนรู้เชิงลึก/การวิเคราะห์รูปภาพ/การเพิ่มปริมาณข้อมูลภาพสอน/ข้อมูลสมดุล	



Article Info	Abstract
Article History: Received: December 29, 2021 Revised: March 4, 2022 Accepted: April 23, 2022	Pineapple is an important economic crop in Thailand whose price depends on its sweetness. Determination of a fruit's sweetness can be done using an optical refractometer or another tool that requires expert judgment. Furthermore, measuring the sweetness of each fruit consumes manpower and time. This study employs the AlexNet deep learning model to classify sweetness levels of pineapple based on physical characteristics demonstrated through figures. The dataset is classified into 4 classes, i.e., M1 to M4, and sorted according to the level of sweetness in ascending order. Training accounts for 80% of the dataset, whereas testing accounts for 20%. The experiments of this study were conducted five times, each with a different epoch and working with prepared data. The experiment indicates the AlexNet model generates the best results when trained at 10 epochs with balance data and contains 120 figures per class. The accuracy of the model and F1 score is 91.78% and 92.31%, respectively.
Keywords: Pineapple Sweetness/Deep Learning/AlexNet/Data Augmentation/Balanced data	

1. บทนำ

สับปะรดจัดเป็นหนึ่งในพืชเศรษฐกิจที่สำคัญของไทย ในปี 2562 มีผลผลิตทั้งประเทศประมาณ 1,825,257 ตัน สับปะรดมีการปลูกมากที่สุดในภาคกลาง โดยคิดเป็น 69% ของเนื้อที่ปลูกสับปะรดทั้งหมด และมีผลผลิตประมาณ 1,324,691 ตัน [1] สับปะรดถือเป็นราชินีของผลไม้ [2] เนื่องจากมีรสชาติดีและมีประโยชน์ต่อสุขภาพ นอกจากนี้ยังสามารถใช้ประโยชน์ได้หลากหลาย เช่น บริโภคเป็นผลไม้สด นำไปประกอบอาหาร ทำเป็นเครื่องดื่ม หรือนำไปถนอมอาหาร เป็นต้น [3] ซึ่งโดยปกติแล้วผู้บริโภคนิยมรับประทานหรือใช้ประโยชน์สับปะรดที่มีรสหวาน เนื่องจากให้รสชาติที่ดีกว่าแบบเปรี้ยวหรือฝาด ดังนั้นการหาความหวานของสับปะรดจึงมีความสำคัญ โดยในปัจจุบันการหาความหวานของสับปะรดสามารถทำได้จากการดมกลิ่น การดูสี ความสดเก่าของสีใบรูปทรง การสัมผัสโดยการบีบหรือเคี้ยว หรือการใช้เครื่องหาความหวานแบบส่อง (Hand Refractometer) ซึ่งวิธีการเหล่านี้มีข้อเสียหลายประการ ได้แก่ ต้องใช้บุคลากรที่มีประสบการณ์ มีความไม่แน่นอนสูง สิ้นเปลืองกำลังคนและเวลา และมีความยุ่งยาก ดังนั้นจึงมีการนำเทคโนโลยีทางด้านปัญญาประดิษฐ์ (Artificial Intelligence) เป็นทางเลือกเพื่อแก้ปัญหาเหล่านี้ [4-6]

ในการเก็บเกี่ยวทางการเกษตร โดยเฉพาะผลไม้ มักมีการพิจารณาความสุกหรือความหวานของผลไม้ก่อนการเก็บเกี่ยวเนื่องจากรสชาติที่ได้ส่งผลต่อผลิตภัณฑ์โดยตรง ยกตัวอย่างเช่น บริษัททิปโก้ได้ปลูกสับปะรดหอมสุวรรณเพื่อนำไปเป็นวัตถุดิบในการทำน้ำสับปะรดหอมสุวรรณ ก่อนการเก็บเกี่ยวสับปะรดจะมีการสุ่มตรวจความ



หวานของสับปะรดก่อนโดยใช้เครื่องวัดความหวาน ซึ่งเป็นการเสียเวลาและต้องการผู้เชี่ยวชาญในการวิเคราะห์ ดังนั้นการหาวิธีการทางปัญญาประดิษฐ์ที่สามารถประมาณระดับความหวานของสับปะรดได้โดยใช้ปัจจัยที่มองเห็นภายนอกของสับปะรดจึงเป็นทางออกที่เหมาะสม เพื่อเพิ่มประสิทธิภาพการเก็บเกี่ยวผลผลิตของบริษัท ในปัจจุบันได้มีงานวิจัยที่ใช้เทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) หาความหวานของผลไม้ Sangsongfa et al. [7] ได้ทำการวิจัยโดยใช้ CNN-PPSM มาหาความหวานของสับปะรดจากรูปภาพ (image) โดยใช้รูปภาพสับปะรดจำนวน 4,860 รูป โดยมีความแม่นยำจากการเทรน (Training) และการทดสอบ (Testing) ประมาณ 72.38% และ 78.50% ตามลำดับ Nazulan et al [8] ได้ออกแบบวิธีการตรวจสอบพารามิเตอร์ความหวานสำหรับอัลกอริทึมการตรวจจับและจำแนกผลไม้ในการเรียนรู้ของเครื่อง เทคนิคการประมวลผลภาพเพื่อตรวจสอบสีและรูปร่างของผิวแตงโมเพื่อจัดระดับตามระดับความหวานโดยใช้วิธีการจัดกลุ่ม K-means แตงโมแต่ละลูกจะถูกจัดกลุ่มเป็นเกรด A (ระดับความหวานสูง) เกรด B (ระดับความหวานปานกลาง) และเกรด C (ระดับความหวานต่ำ) ตามผลการตรวจจับสีและรูปร่าง ผลการทดลองแสดงให้เห็นถึงความแม่นยำสูงถึง 84.62%

ในงานวิจัยนี้ คณะผู้วิจัยจึงได้พัฒนาวิธีการจำแนกระดับความหวาน โดยใช้ลักษณะทางกายภาพที่มองเห็นได้ของสับปะรด ด้วยการวิเคราะห์ทางการเรียนรู้เชิงลึก (Deep Learning) ซึ่งเราเลือกใช้แบบจำลองที่สร้างขึ้นและได้รับการฝึกฝนแล้ว (Pre-trained model) ชื่อว่า AlexNet ข้อมูลเข้าของวิธีการที่ถูกพัฒนานี้เป็นข้อมูลรูปภาพของสับปะรด โดยมีการนำข้อมูลรูปภาพที่สัมพันธ์กับข้อมูลลักษณะทางเคมีของสับปะรดที่ทราบค่าความหวาน AlexNet เป็นแบบจำลองที่มีการเรียนรู้จากชุดข้อมูล Coco ซึ่งประกอบด้วยชุดข้อมูลของผลไม้หลายประเภททำให้ AlexNet มีความแม่นยำสูงและเมื่อทำงานกับข้อมูลประเภทผลไม้ วัตถุประสงค์ของงานวิจัยนี้คือ การพัฒนาวิธีการด้วยการเรียนรู้เชิงลึกเพื่อจำแนกระดับความหวานของสับปะรดโดยใช้ลักษณะทางกายภาพ

2. วิธีดำเนินการวิจัย

2.1 กระบวนการเตรียมข้อมูล (Data preparation)


ชุดข้อมูลเข้าเป็นข้อมูลรูปภาพสับปะรด (รูปที่ 1) โดยนำมาจาก [9] ข้อมูลรูปภาพสับปะรดตั้งต้นประกอบด้วยรูปภาพผลสับปะรดที่ถูกถ่ายในห้องปฏิบัติการจำนวน 42 ลูก ซึ่งเป็นภาพสี RGB และมีนามสกุล JPG จากแหล่งข้อมูล ข้อมูลรูปสับปะรดสามารถถูกจับกลุ่มเข้าข้อมูลทางเคมีของสับปะรด (ผลิตภัณฑ์ไม่พบแหล่งการอ้างอิง) ที่สัมพันธ์กันเพื่อกำหนดคลาสเป้าหมายได้ จากผลิตภัณฑ์ไม่พบแหล่งการอ้างอิง ประกอบด้วย °Brix (องศาบริกซ์) คือ ปริมาณน้ำตาลในของเหลว (สารละลาย) ซึ่งเป็นหน่วยการวัดความหวาน และ Acidez คือ ปริมาณกรดในของเหลว โดยสับปะรดที่มีค่า Maturity Index (IM) มากกว่าจะมีความหวานมากกว่า ค่า IM เป็นค่าที่บ่งชี้ระดับความหวานซึ่งได้มาจากการคำนวณจาก สมการที่ 1

$$IM = \frac{^{\circ}\text{Brix}}{\text{Acidez}} \quad \text{สมการที่ 1}$$

จากงานวิจัยนี้ผู้วิจัยแบ่งเกณฑ์ความหวานของสับปะรดตามค่า IM ได้ทั้งหมด 4 คลาส ดังนี้

1. สับปะรด M1 คือสับปะรดที่มีค่า IM ตั้งแต่ 0-19
2. สับปะรด M2 คือสับปะรดที่มีค่า IM ตั้งแต่ 20-29
3. สับปะรด M3 คือสับปะรดที่มีค่า IM ตั้งแต่ 30-39
4. สับปะรด M4 คือสับปะรดที่มีค่า IM ตั้งแต่ 40 ขึ้นไป

ลำดับความหวานเรียงจากน้อยไปมาก คือ M1 M2 M3 และ M4 ในการทดลองนี้มีรูปสับปะรดที่ถูกจัดอยู่ในคลาส M1 จำนวน 88 รูป อยู่ในคลาส M2 จำนวน 20 รูป อยู่ในคลาส M3 จำนวน 32 รูปและอยู่ในคลาส M4 จำนวน 28 รูป



รูปที่ 1 ตัวอย่างรูปภาพสับปะรดที่ถูกจัดอยู่ใน M1 (หวานน้อยที่สุด) M2 M3 และ M4 (หวานมากที่สุด)

ตารางที่ 1 ตัวอย่างข้อมูลทางเคมีของสับปะรดที่ใช้ในการอ้างอิงคลาสกับรูปภาพที่สัมพันธ์กัน

	Muestra	Acidez Promedio	DE	pH Promedio	DE	°Brix Promedio	DE	IM
1	Cultivar 1 prueba 1	0.5045	0.008	3.3633	0.015	16.1333	0.058	32
2	Cultivar 1 prueba 2	0.7328	0.017	3.29	0.01	13.4	0.1	18.3
3	Cultivar 1 prueba 3	0.8907	0.009	3.2133	0.006	15.3333	0.153	17.2
4	Cultivar 1 prueba 4	0.7989	0.799	3.3267	0.006	13.4333	0.153	16.8
5	Cultivar 3 prueba 1	0.6901	0.69	3.2567	0.006	12.7667	0.208	18.5

อย่างไรก็ตาม จากการพิจารณาจำนวนข้อมูลในแต่ละคลาส ผู้วิจัยเห็นว่า ข้อมูลรูปภาพมีปริมาณข้อมูลไม่สัมพันธ์กัน โดยมีรูปภาพในคลาส M1 สูงกว่าคลาสอื่นๆ 2-3 เท่า ซึ่งเป็นสาเหตุสำคัญของปัญหาข้อมูลที่ไม่สมดุล (Imbalanced Dataset) ที่ส่งผลกระทบต่อประสิทธิภาพของการเรียนรู้ของแบบจำลอง ดังนั้นผู้วิจัยได้ใช้ เทคนิคในการเพิ่มปริมาณของข้อมูล (Data Augmentation) มาเพิ่มจำนวนข้อมูลรูปภาพโดยการหมุนรูปภาพ (Image Rotation) 90 องศา 180 องศาและ 270 องศา ให้ในแต่ละคลาสมีปริมาณข้อมูลใกล้เคียงกัน โดยสามารถเพิ่มรูปภาพได้ประมาณ 120 รูปต่อคลาส รวมทั้งหมดเป็น 488 รูป ดังที่แสดงใน


รูปที่ 2

2.2 กระบวนการทำงาน (Methodology)

หลังจากเตรียมข้อมูลเสร็จสิ้น ชุดข้อมูลที่ได้จะถูกนำไปแบ่งออกเป็นชุดข้อมูลฝึกฝน (Training Data) และชุดข้อมูลทดสอบ (Test Data) ออกเป็นร้อยละ 80 ต่อ 20 โดยการแบ่งเกิดการสุ่มให้มีจำนวนข้อมูลในแต่ละ



คลาสสมดุลกัน ขนาดของข้อมูลที่ถูกเตรียมคือ $227 \times 227 \times 3$ โดยแทนด้วย กว้าง $\times$ ยาว $\times$ ระดับสี ถ้าเป็น RGB จะแทนด้วย 3 ถ้าเป็น Grayscale จะแทนด้วย 1



รูปที่ 2 กระบวนการเตรียมข้อมูล

จากนั้นชุดข้อมูลฝึกฝนถูกนำมาใช้กับแบบจำลองที่ได้รับการฝึกฝนมาแล้ว (Pre-trained Model) ชื่อว่า AlexNet [10] ซึ่งถูกพัฒนามาจาก Convolutional Neural Network (CNN) ซึ่งจัดประเภทให้เป็นเครือข่ายแบบ Deep Convolutional ประกอบไปด้วย 25 ระดับชั้น และลึก 8 ชั้นสามารถรับข้อมูลเข้าขนาด $227 \times 227 \times 3$ ได้ สามารถฝึกสอนพารามิเตอร์ได้สูงสุด 62 ล้านพารามิเตอร์ AlexNet เป็นหนึ่งใน Pre-trained Model ที่ได้รับความนิยมอย่างมาก เนื่องจากความแม่นยำและความสามารถในการทำงานข้อมูลที่มีความซับซ้อน โดยได้รับการฝึกสอนกับข้อมูล ImageNet LSVRC-2010 [11] ที่เป็นรูปถ่ายที่มีความละเอียดสูง 1.2 ล้านพิกเซล มีจำนวนคลาสมากกว่า 1,000 คลาส และมีมากกว่า 10,000,000 รูปถ่าย ดังนั้น AlexNet เป็นโมเดลที่เหมาะสมที่จะทำงานร่วมกับข้อมูลรูปภาพที่มีความละเอียดสูงและสามารถทำงานกับข้อมูลจำนวนมากได้อย่างมีประสิทธิภาพ

โครงสร้างทั่วไปของ AlexNet (

รูปที่ 3) ประกอบด้วย 2 ส่วนคือ Feature learning และ Classification ซึ่ง Feature learning มีหน้าที่สกัดข้อมูลที่เป็นสำหรับการตรวจจับคุณลักษณะหรือการจัดประเภทจากข้อมูลเข้าและ Classification คือกระบวนการจำแนกประเภทของข้อมูล Feature learning มีระดับชั้นย่อยดังนี้


1) Convolutional layer มีหน้าที่ในการสกัดเพื่อเอาคุณสมบัติต่างๆออกมาจากภาพ โดยรับข้อมูลเข้าขนาด $227 \times 227 \times 3$ ทำงานร่วมกับ Filters 96 ตัว ขนาด 11×11 กำหนดให้มีการข้าม (Stride) ทีละ 4 ช่องและมีช่องว่างรอบขอบรูป (Padding) 2 ช่อง ทำให้เกิดรูปภาพ Tensor ที่เป็นข้อมูลออกจากระดับชั้นนี้ขนาด $55 \times 55 \times 96$ ที่ถูกส่งผ่าน Activate Function ที่ชื่อว่า ReLu

2) Pooling layer รับข้อมูลเข้ามาจาก Covolution Layer มีขนาด $55 \times 55 \times 96$ มีหน้าที่ดึงเอาคุณสมบัติที่สำคัญที่สุดออกมาจากข้อมูล ใน AlexNet จะใช้ Max pooling ขนาด 3×3 โดยจะเอาเฉพาะค่าที่มากที่สุดเก็บไว้ โดยมีค่า Stride คือ 2 ทำให้เกิด Tensor ที่เป็นข้อมูลออกขนาด $27 \times 27 \times 96$ ที่ถูกส่งต่อไปยังระดับชั้นต่อไป

3) ReLu เป็นฟังก์ชันที่จะเปลี่ยนค่าที่น้อยกว่า 0 (ค่าติดลบ) ให้กลายเป็น 0 โดยค่าที่เป็นผลลัพธ์ของ ReLu จะมากกว่าหรือเท่ากับ 0 เสมอ



- 4) Normalization layer มีเพื่อปรับช่วงของข้อมูลให้มีขอบเขตที่ต้องการ
- 5) Fully Connected layer เป็นระดับชั้นที่จะเชื่อมต่อทุก Neuron ในชั้นหนึ่งกับทุก Neuron ในอีกชั้นหนึ่ง
- 6) Dropout layer คือ การละเว้น Neuron ในแต่ละระดับชั้นของ Neural Network ออกแบบสุ่ม ซึ่งเป็นวิธีการที่ส่งผลให้มีความเป็น dependency ของ Neural Network ลดลง แก้ปัญหาแบบจำลอง Overfitting และ Overparameterization
- 7) Softmax layer คือ ฟังก์ชันที่รับข้อมูลเข้าเป็น Vector ของจำนวนจริง แล้วให้ผลลัพธ์ออกมาเป็นความน่าจะเป็น (Probability)



รูปที่ 3 โครงสร้างของ AlexNet [10]

3. ผลการวิจัย

ผู้วิจัยได้ออกแบบการทดลองออกเป็น 5 การทดลองกับข้อมูล 2 ชุด ดังนี้

- การทดลองที่ 1 คือ ใช้ AlexNet 5 epoch และข้อมูลที่ยังไม่มีการทำ data augmentation (ข้อมูล A)
- การทดลองที่ 2 คือ ใช้ AlexNet 6 epoch และข้อมูลที่ได้มีการทำ data augmentation มีจำนวน 80 รูปต่อคลาส (ข้อมูล B)
 - การทดลองที่ 3 คือ ใช้ AlexNet 12 epoch และข้อมูลที่ได้มีการทำ data augmentation มีจำนวน 80 รูปต่อคลาส (ข้อมูล B)
 - การทดลองที่ 4 คือ ใช้ AlexNet 11 epoch และข้อมูลที่ได้มีการทำ data augmentation มีจำนวน 120 รูปต่อคลาส (ข้อมูล C)
 - การทดลองที่ 5 คือ ใช้ AlexNet 10 epoch และข้อมูลที่ได้มีการทำ data augmentation มีจำนวน 120 รูปต่อคลาส (ข้อมูล C)



		Confusion Matrix				
Output Class	pineapple M1	26 52.0%	5 10.0%	9 18.0%	5 10.0%	57.8% 42.2%
	pineapple M2	0 0.0%	1 2.0%	0 0.0%	0 0.0%	100% 0.0%
	pineapple M3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	pineapple M4	0 0.0%	0 0.0%	1 2.0%	3 6.0%	75.0% 25.0%
		100% 0.0%	16.7% 83.3%	0.0% 100%	37.5% 62.5%	60.0% 40.0%
		pineapple M1	pineapple M2	pineapple M3	pineapple M4	
		Target Class				


รูปที่ 4 Confusion Matrix ของการทดลองที่ 1

ในการทดลองที่ 1 ใช้ AlexNet 5 epoch กับข้อมูลที่ยังไม่มีการทำ data augmentation (ข้อมูล A) จากการทดลองพบว่าจำนวนข้อมูลทดสอบมี 20% ของข้อมูลทั้งหมด โดยมีการแบ่งรูปในแต่ละคลาสเป็นสัดส่วน 20% จำนวนรูปในคลาส M1 มีจำนวน 26 รูป ในคลาส M2 มี 6 รูป ในคลาส M3 มี 10 รูป ในคลาส M4 มี 8 รูป เมื่อปริมาณข้อมูลในแต่ละคลาสไม่สัมพันธ์กัน ย่อมส่งผลต่อการฝึกสอนของโมเดล ในภาพรวมโมเดลให้ค่าความแม่นยำอยู่ที่ 60% ดังที่แสดงในรูปที่ 4


ในการทดลองที่ 2 ใช้ AlexNet 5 epoch กับข้อมูลที่ทำ data augmentation (ข้อมูล B) โดยมีการเพิ่มรูปในแต่ละคลาสเป็นประมาณ 80 รูป ซึ่งมีจำนวนพอๆ กัน เมื่อนำข้อมูลทดสอบ B มาประเมินโมเดล AlexNet ที่มีการฝึกสอนไปจำนวน 5 epoch ผลปรากฏว่า ในภาพรวมของการประเมินโมเดลได้ความแม่นยำอยู่ที่ 74.6% ดังที่แสดงในรูปที่ 5

		Confusion Matrix				
Output Class	pineapple M1	18 18.4%	6 6.1%	2 2.0%	2 2.0%	64.3% 35.7%
	pineapple M2	1 1.0%	18 18.4%	0 0.0%	0 0.0%	94.7% 5.3%
	pineapple M3	1 1.0%	0 0.0%	17 17.3%	1 1.0%	89.5% 10.5%
	pineapple M4	6 6.1%	0 0.0%	6 6.1%	20 20.4%	62.5% 37.5%
		69.2% 30.8%	75.0% 25.0%	68.0% 32.0%	87.0% 13.0%	74.5% 25.5%
		pineapple M1	pineapple M2	pineapple M3	pineapple M4	
		Target Class				

รูปที่ 5 Confusion Matrix ของการทดลองที่ 2



รูปที่ 6 Training process ของการทดลองที่ 3




รูปที่ 7 Training process ของการทดลองที่ 4

ในการทดลองที่ 3 ใช้ AlexNet 12 epoch กับข้อมูล B ผลปรากฏว่า ในภาพรวมของการประเมินโมเดล ได้ความถูกต้อง (Accuracy) อยู่ที่ 82.65% 89.73% อย่างไรก็ตามเมื่อพิจารณาผลการทำงานของการฝึกสอนโมเดล (รูปที่ 6) แล้ว เห็นได้ว่า โมเดล AlexNet จะทำงานได้ดีที่สุดเมื่อที่ epoch ที่ 11 ดังนั้นจึงเพิ่มการทดลองที่ 4 ขึ้นมา

ในการทดลองที่ 4 ใช้ AlexNet 11 epoch กับข้อมูล C โดยมีการเพิ่มจำนวนรูปภาพในแต่ละคลาสเป็น ประมาณ 120 รูปต่อคลาส จากการทดลองพบว่าค่าความถูกต้อง คือ 89.73% และจากการสังเกตในรูปที่ 7 สามารถวิเคราะห์ได้ว่า หากเปลี่ยนเป็น AlexNet 10 epoch จะได้ค่าความถูกต้องที่สูงขึ้น

ในการทดลองที่ 5 ใช้ AlexNet 10 epoch กับข้อมูล C พบว่าได้ค่าความถูกต้องเพิ่มเป็น 91.78% และได้ค่า F1 score อยู่ที่ 92.31% โดยค่า F1 score คือค่าที่ใช้วัดความสารถของโมเดลโดยเฉลี่ยระหว่างค่า precision กับค่า recall ดังที่แสดงในรูปที่ 8



Confusion Matrix						
Output Class	pineapple M1	30 20.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	pineapple M2	2 1.4%	36 24.7%	0 0.0%	0 0.0%	94.7% 5.3%
	pineapple M3	6 4.1%	0 0.0%	36 24.7%	2 1.4%	81.8% 18.2%
	pineapple M4	0 0.0%	0 0.0%	2 1.4%	32 21.9%	94.1% 5.9%
		78.9% 21.1%	100% 0.0%	94.7% 5.3%	94.1% 5.9%	91.8% 8.2%
		pineapple M1	pineapple M2	pineapple M3	pineapple M4	
Target Class						

รูปที่ 8 Confusion Matrix ของการทดลองที่ 5

4. อภิปรายผลการวิจัย

งานวิจัยนี้ได้พัฒนาวิธีการจำแนกระดับความหวานโดยวิเคราะห์จากรูปภาพสับปะรดด้วย AlexNet วัตถุประสงค์ของงานวิจัยนี้คือ พัฒนารูปแบบการเรียนรู้เชิงลึกเพื่อจำแนกระดับความหวานของสับปะรดโดยใช้ ลักษณะทางกายภาพ ดังนั้นเพื่อหาโมเดลที่เหมาะสมที่สุดในการจำแนกความหวานจากสับปะรด จึงได้ออกแบบการ ทดลองเป็น 5 การทดลอง โดยแต่ละการทดลองใช้โครงสร้างโมเดลเดียวกัน นั่นคือ AlexNet แต่มีจำนวน epoch ต่างกัน ข้อมูลที่นำมาใช้ในการทดลองมี 2 ชุดคือ 1) ข้อมูล A เป็นข้อมูลที่ยังไม่มีการทำ data augmentation และเป็น ข้อมูลไม่สมดุล 2) ข้อมูล B เป็นข้อมูลที่ได้มีการทำ data augmentation เรียบร้อยแล้วและเป็นข้อมูลสมดุล

จากผลการทดลองที่ 1 พบว่า ข้อมูลที่ถูกนำมาทดลองเป็นข้อมูลที่ยังไม่มีการจัดให้สมดุล (Imbalanced data) ซึ่งจำนวนของข้อมูลที่นำมาฝึกสอนมีผลต่อประสิทธิภาพและความแม่นยำของโมเดล คลาสที่มีจำนวนข้อมูลสูงสุด คือ M1 ดังนั้นจากรูปที่ 5 ทำให้ค่า True positive ของ M1 สูงมาก เมื่อเทียบกับ True positive ของคลาสอื่น คลาส M1 M2 และ M3 มีจำนวนข้อมูลน้อยมาก เมื่อโมเดลทำการทำนายคลาสเหล่านี้จึงให้ค่า recall ที่ต่ำ โดยในคลาส M3 โมเดลได้ True positive เป็น 0 คือ โมเดลไม่สามารถทำนายคลาส M3 ได้เลย วิธีแก้ไขปัญหามข้อมูลไม่สมดุล คือ ต้องเพิ่มจำนวนของข้อมูลในแต่ละคลาสให้สมดุลกัน โดยอาจจะหาจากแหล่งข้อมูลอื่นเพิ่มเติมหรือใช้วิธี Data augmentation

จากการทดลองที่ 2 เมื่อนำโมเดลทำงานร่วมกับข้อมูลสมดุล และมีการฝึกสอนไปจำนวน 5 epoch ได้ความแม่นยำอยู่ที่ 74.6% สามารถวิเคราะห์ได้ว่า การทำงานของ Model ร่วมกับข้อมูลสมดุลมีการทำงานที่ดีขึ้น แต่ยังไม่เพียงพอเนื่องจากความแม่นยำยังต่ำอยู่ จึงได้ทำการเพิ่มจำนวนการฝึกสอน เป็น 12 epoch ในการทดลองที่ 3 ทำให้ได้ความแม่นยำเพิ่มขึ้นเป็น 82.65% ดังนั้นจึงสามารถสรุปได้ว่าจำนวนการฝึกสอน (epoch) มีผลต่อประสิทธิภาพในการเรียนรู้ของโมเดลอย่างเห็นได้ชัด โดยยิ่งเพิ่มจำนวน epoch ยิ่งทำให้โมเดลสามารถเรียนรู้ได้มากขึ้น

ในการทดลองที่ 4 ได้มีการปรับจำนวน epoch ให้เป็นจำนวน 11 epoch เนื่องจากการวิเคราะห์ Training process ของการทดลองที่ 3 ทำให้ทราบว่าที่ epoch ที่ 11 ให้ผลลัพธ์ที่ดีกว่า epoch ที่ 12 อีกทั้งยังทำการเพิ่ม



จำนวนรูปภาพต่อคลาสเป็น 120 รูป ผลการทดลองปรากฏว่าความถูกต้องเพิ่มขึ้นเป็น 89.73% ทำให้สามารถสรุปได้ว่า นอกจากจำนวน epoch ที่เหมาะสม ขนาดของข้อมูลก็มีผลต่อการฝึกสอนโมเดลเช่นกัน โดยหากมีข้อมูลที่มีขนาดใหญ่ โมเดลสามารถเรียนรู้รูปแบบของข้อมูลให้ครอบคลุมมากขึ้น

ในการทดลองที่ 5 หลังจากปรับจำนวน epoch เป็น 10 และทำงานร่วมกับข้อมูลสมดุที่มีขนาด 120 รูปต่อคลาสแล้ว ได้ผลลัพธ์ที่น่าพอใจคือ โมเดลสามารถให้ความถูกต้อง 91.78% และได้ค่า F1 score อยู่ที่ 92.31% เมื่อนำผลการทดลองเปรียบเทียบกับงานวิจัยของ [7] ปรากฏว่า ผลจากการทดลองนี้ดีกว่าอย่างชัดเจน ถึงแม้ว่าจำนวนของรูปภาพมีน้อยกว่าในงานวิจัยเดิมถึง 10 เท่า เนื่องจากการใช้งาน Pre-trained model แต่เดิมมีการเรียนรู้ในการจำแนกภาพผลไม่อยู่บ้างแล้ว ทำให้เรามีหน้าที่เพียงเพิ่มรูปสับปะรดเพิ่มเข้าไปเท่านั้น ช่วยทำให้ลดกระบวนการฝึกสอนโมเดลใหม่ไปได้

วิธีการประเมินโมเดลในงานวิจัยนี้ ผู้วิจัยได้เลือกใช้วิธี Train-Test Split เนื่องจากเมื่อพิจารณาจำนวนข้อมูลที่นำเข้าเพื่อการฝึกสอนและทดสอบโมเดลแล้ว เห็นว่ามีจำนวนเพียงพอและเหมาะสม โดยมีหลักฐานเชิงประจักษ์คือ ผลการทดลองที่ได้ค่าความแม่นยำสูง วิธีการนี้มีข้อดีคือ เหมาะสมที่จะใช้กับข้อมูลขนาดใหญ่หรือเพียงพอต่อการฝึกสอนและทำงานเร็วกว่าวิธี k-fold cross validation ในส่วน k-fold cross validation เป็นตัวเลือกที่ดีในกรณีที่ข้อมูลที่ใช้ทดลองมีน้อย แต่ความเร็วในการทดสอบโมเดลจะช้า

ข้อจำกัดของงานวิจัยนี้คือโมเดลสามารถทำงานได้ดีกับข้อมูลรูปสับปะรดที่ถูกถ่ายในห้องปฏิบัติการ โดยมีสีและแสงสม่ำเสมอและไม่มีการพิจารณาฉากหลัง ดังนั้นเพื่อให้โมเดลนี้สามารถนำไปใช้งานในพื้นที่การเกษตรได้จริง จำเป็นต้องมีการพัฒนาในขั้นตอนการเตรียมข้อมูลให้สามารถแยกรูปสับปะรดออกจากพื้นหลังได้ และจำกัดเฉพาะรูปสับปะรดที่มีผลสีเหลืองเท่านั้น

5. สรุปผลการวิจัย

ในงานวิจัยนี้ ผู้วิจัยได้พัฒนาวิธีการจำแนกระดับความหวานโดยวิเคราะห์จากรูปภาพสับปะรดด้วย AlexNet เราได้ออกแบบการทดลองเป็น 5 การทดลอง โดยแต่ละการทดลองมีการกำหนดจำนวน epoch และข้อมูลที่ใช้ต่างกัน และจากการทดลองทั้งหมดสามารถสรุปได้ว่า โมเดล AlexNet ที่ดีที่สุดมาจากการทดลองที่ 5 โดยใช้จำนวน epoch เป็น 10 ทำงานร่วมกับข้อมูลที่สมดุล โดยแต่ละคลาสมีจำนวน 120 รูป โมเดลสามารถให้ความถูกต้อง 91.78% และได้ค่า F1 score อยู่ที่ 92.31% ในอนาคต งานวิจัยนี้สามารถพัฒนาให้มีความแม่นยำยิ่งขึ้น โดยสามารถเพิ่มขนาดของข้อมูลและจำนวน epoch ในการประยุกต์ใช้ โมเดลนี้สามารถนำไปประยุกต์ใช้กับผลไม้ที่เป็นพืชเศรษฐกิจชนิดอื่นได้ เพื่อความสะดวกรวดเร็วในการคัดแยกผลไม้ตามระดับความหวานจากการพิจารณาทางกายภาพ โดยไม่จำเป็นต้องใช้เครื่องมืออื่นวัดความหวาน

เอกสารอ้างอิง

- [1] สำนักงานเศรษฐกิจการเกษตร. (2564). สำนักงานเศรษฐกิจการเกษตร. สืบค้น 14 มิถุนายน 2565, จาก <http://mis-app.oae.go.th/product/สับปะรด>
- [2] Baruwa, OI. (2013). Profitability and constraints of pineapple production in Osun State, Nigeria. Journal of Horticultural research, 21(2).
- [3] Hossain, MF., Akhtar, S. and Anwar, M. (2015). Nutritional value and medicinal benefits of pineapple. International Journal of Nutrition and Food Sciences, 4(1), 84-88.
- [4] Behera, SK., Rath, AK., and Sethy, PK. (2021). Maturity status classification of papaya fruits based on machine learning and transfer learning approach. Information Processing in Agriculture, 8(2), 244-250.



- [5] Lee, CH. & Jhou, JC. (2021). A Non-Invasive Method to Classify the Sweetness Levels of Apples. In 5th International Conference on Artificial Intelligence and Virtual Reality (AIVR): 128–134.
- [6] Chawgien, K. & Kiattisin, S. (2021). Machine learning techniques for classifying the sweetness of watermelon using acoustic signal and image processing. Computers and Electronics in Agriculture, 181, 105938.
- [7] Sangsongfa, A., Am-Dee, N. and Meesad, P. (2020). Prediction of Pineapple Sweetness from Images Using Convolutional Neural Network. EAI Endorsed Transactions on Context-aware Systems and Applications, 7(21).
- [8] Nazulan, WNSW., Asnawi, AL., Ramli, HAM., Jusoh, AZ., Ibrahim, SN. and Azmin, NFM. (2020). Detection of Sweetness Level for Fruits (Watermelon) With Machine Learning. In 2020 IEEE Conference on Big Data and Analytics (ICBDA) (pp. 79-83). IEEE.
- [9] Mejia, NL., Lobaton, HF. and Morales-Posada, B. (2019). Pineapple classification images and measured properties. mendeley data.
- [10] Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 25.
- [11] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... and Fei-Fei, L. (2015). Imagenet large scale visual recognition challenge. International journal of computer vision, 115(3), 211-252.