

การทำนายระดับความสุกของผลอะโวคาโดด้วยวิธีการประมวลผลภาพ

PREDICTION OF THE RIPENESS LEVEL OF AVOCADO USING
IMAGE PROCESSING METHOD

นายสิริวิชญ์ เดชอธิราช

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมอุตสาหการและการผลิต

คณะวิศวกรรมศาสตร์

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

ปีการศึกษา 2566

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

การทำนายระดับความสุขของผลอะโวคาโดด้วยวิธีการประมวลผลภาพ

นายสิริวิชญ์ เดชอธิราช

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมอุตสาหการและการผลิต

คณะวิศวกรรมศาสตร์

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

ปีการศึกษา 2566

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

วิทยานิพนธ์ฉบับนี้เป็นงานวิจัยที่เกิดจากการค้นคว้าและวิจัย ขณะที่ข้าพเจ้าศึกษาอยู่ในคณะ
วิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี ดังนั้นงานวิจัยในวิทยานิพนธ์ฉบับนี้ถือเป็น
ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี และข้อความต่างๆในวิทยานิพนธ์ฉบับนี้ ข้าพเจ้า
ขอรับรองว่าไม่มีการคัดลอกหรือนำงานวิจัยของผู้อื่นมานำเสนอในชื่อของข้าพเจ้า

This thesis consists of research materials conducted at the Faculty of
Engineering, Rajamangala University of Technology Thanyaburi and hence the copyright
owner. I hereby certify that the thesis does not contain any forms of plagiarism.



ศิริวิญญ์ เดชอริราช
(นายศิริวิญญ์ เดชอริราช)

COPYRIGHT ©

FACULTY OF ENGINEERING

RAJAMANGALA UNIVERSITY OF TECHNOLOGY THANYABURI

ลิขสิทธิ์ พ.ศ. 2566

คณะวิศวกรรมศาสตร์

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

หัวข้อวิทยานิพนธ์

การทำนายระดับความสุกของผลอะโวคาโดด้วยวิธีการประมวลผลภาพ
Prediction of the Ripeness Level of Avocado Using Image
Processing Method

ชื่อ - นามสกุล

นายสิริวิชญ์ เดชอธิราช

สาขาวิชา

วิศวกรรมอุตสาหการและการผลิต

อาจารย์ที่ปรึกษา

รองศาสตราจารย์ระพี กาญจนะ, วศ.ด.

ปีการศึกษา

2566

คณะกรรมการสอบวิทยานิพนธ์

ประธานกรรมการ

(รองศาสตราจารย์กิตติพงษ์ กิมะพงศ์, Ph.D.)

กรรมการ

(รองศาสตราจารย์ประจวบ กล่อมจิตร, วศ.ด.)

กรรมการ

(ผู้ช่วยศาสตราจารย์ก้าวหน้า จงวัฒนารักษ์, วศ.ด.)

กรรมการ

(รองศาสตราจารย์ระพี กาญจนะ, วศ.ด.)

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี อนุมัติวิทยานิพนธ์ฉบับนี้เป็น
ส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณบดีคณะวิศวกรรมศาสตร์

(รองศาสตราจารย์สรพงษ์ ภาวสุปรีย์, Ph.D.)

วันที่ 5 เดือน กุมภาพันธ์ พ.ศ. 2567

หัวข้อวิทยานิพนธ์	การทำนายระดับความสุกของผลอะโวคาโดด้วยวิธีการประมวลผลภาพ
ชื่อ - นามสกุล	นายสิริวิชญ์ เดชอธิราช
สาขาวิชา	วิศวกรรมอุตสาหการและการผลิต
อาจารย์ที่ปรึกษา	รองศาสตราจารย์ระพี กาญจนะ, วศ.ด.
ปีการศึกษา	2566

บทคัดย่อ

ปัจจุบันอะโวคาโดเป็นผลไม้ที่ได้รับความนิยมจากผู้บริโภคที่รักสุขภาพเป็นอย่างมาก การเลือกซื้ออะโวคาโดมักจะสังเกตที่สีผิวของเปลือกอะโวคาโดหรือไม่ก็จากการบีบผลอะโวคาโดส่งทำให้เนื้อช้า ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อศึกษาหาความสัมพันธ์ของความแน่นเนื้อกับค่าสีของเปลือกผลอะโวคาโดและเพื่อวัดความสุกของผลอะโวคาโดด้วยวิธีการประมวลผลภาพร่วมกับโมเดลแบบจำลองทางคณิตศาสตร์มาช่วยในการทำนายระดับความสุกของผลอะโวคาโด

เทคนิคการประมวลผลภาพถูกนำมาประยุกต์ร่วมกับอัลกอริทึมโครงข่ายประสาทเทียมเพอร์เซปตรอนหลายชั้น (MLP), ซัพพอร์ตเวกเตอร์รีเกรสชัน (SVR) และเคเนียร์เรสเนเบอร์ (KNN) มาใช้ในการทำนายความสุกของผลอะโวคาโด ขั้นตอนการทดลองเริ่มต้นด้วยการประมวลผลภาพของผลอะโวคาโดเพื่อแยกองค์ประกอบค่าสีของเปลือกในระบบสี $L^*a^*b^*$ และส่งข้อมูลไปยังโมเดลที่ทำการแบ่งข้อมูลที่ใช้ฝึกกับข้อมูลที่ใช้ในการทดสอบโมเดลเป็น 70/30, 80/20 และ 90/10

ผลการทดลองพบว่าโมเดลที่เหมาะสมที่สุดในการทำนายความสุกของผลอะโวคาโดคือโมเดล MLP (90/10) ซึ่งมีค่า R^2 , RMSE และ MAE เท่ากับ 0.990, 0.341 และ 0.321 ตามลำดับ ต่อมาคือโมเดล KNN (80/20) มีค่า R^2 , RMSE และ MAE เท่ากับ 0.787, 6.953 และ 1.672 ตามลำดับ และสุดท้ายคือโมเดล SVR (90/10) มีค่า R^2 , RMSE และ MAE เท่ากับ 0.776, 8.310 และ 1.993 ตามลำดับ ทั้งนี้โมเดล MLP สามารถทำนายได้สูงถึงร้อยละ 99.4 ในขณะที่โมเดล KNN และโมเดล SVR สามารถทำนายได้ร้อยละ 95.2 และ 94.9 ตามลำดับ ผลการศึกษานี้สามารถใช้เป็นแนวทางในการพัฒนาโมเดลในการทำนายความสุกของผลอะโวคาโด

คำสำคัญ: อะโวคาโด การประมวลผลภาพ โครงข่ายประสาทเทียมเพอร์เซปตรอนหลายชั้น (MLP)

ซัพพอร์ตเวกเตอร์รีเกรสชัน (SVR) เคเนียร์เรสเนเบอร์ (KNN)

Thesis Title	Prediction of the Ripeness Level of Avocado Using Image Processing Method
Name - Surname	Mr. Sirawit Dejathirat
Program	Industrial and Manufacturing Engineering
Thesis Advisor	Associate Professor Rapee Kanchana, D.Eng.
Academic Year	2023

ABSTACT

Avocados have become a popular fruits among health-conscious consumers. People often choose ripe avocados based on the skin color of the avocado peel or from squeezing the avocado causing the flesh to bruise. Therefore, this research aimed to investigate the relationship of firmness with the color value of avocado peel, and to measure the ripeness of avocado fruits using image processing method and a mathematical model to predict the ripeness level of avocados.

Image processing techniques were applied in combination with the multi-layer perceptron (MLP), Support Vector Regression (SVR), and K-Nearest Neighbors (KNN) models to predict the ripeness of avocado fruits. The experiments started with extracting the color value from avocado peels using image processing in the $L^*a^*b^*$ color space. The extracted data were sent to a model that splits the training data and testing data into the ratios of 70/30, 80/20, and 90/10.

The results revealed that the most suitable model for predicting avocado ripeness was the MLP model (90/10) with R^2 , RMSE and MAE values of 0.990, 0.341, and 0.321, respectively. The R^2 , RMSE and MAE values of KNN model (80/20) were 0.787, 6.953, and 1.672, respectively. The R^2 , RMSE and MAE values of SVR model (90/10) were 0.776, 8.310, and 1.993, respectively. The MLP model could accurately predict up to 99.4%, while the KNN and SVR models were 95.2 and 94.9%, respectively. These results can be useful in developing models for predicting the ripening of avocados.

Keywords: avocado, image processing, multi-layer perceptron (MLP), support vector regression (SVR), k-nearest neighbors (KNN)


กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงอย่างสมบูรณ์ได้ด้วยความกรุณาของรองศาสตราจารย์ ดร.ระพี กาญจนะ อาจารย์ที่ปรึกษาวิทยานิพนธ์ และผู้ช่วยศาสตราจารย์ ดร.ก้าวหน้า จงวัฒนารักษ์ที่กรุณาให้คำปรึกษา คำแนะนำตลอดจนให้ความช่วยเหลือแก้ไขข้อบกพร่องต่าง ๆ เพื่อให้วิทยานิพนธ์ฉบับนี้มีความสมบูรณ์ จึงขอกราบขอบพระคุณอาจารย์เป็นอย่างสูงไว้ ณ ที่นี้ นอกจากนี้ขอขอบพระคุณ คณะอาจารย์ประจำภาควิชาวิศวกรรมอุตสาหการ และภาควิชาวิศวกรรมเกษตร คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรีทุกท่าน รวมถึงคณะกรรมการสอบวิทยานิพนธ์ทุกท่าน ที่ให้ความรู้จนสามารถนำความรู้มาใช้กับวิทยานิพนธ์ฉบับนี้

ขอขอบคุณผอ.ธนากร โพธิ์กำชัย ผู้อำนวยการศูนย์ส่งเสริมและพัฒนาอาชีพการเกษตรที่สูง จังหวัดตาก เกษตรกร และผู้ประกอบการที่สนับสนุนข้อมูลในการศึกษาวิจัยในครั้งนี้ ขอขอบคุณบิดา มารดา เพื่อน และขอขอบคุณผู้ที่อยู่เบื้องหลังความสำเร็จของการทำ วิทยานิพนธ์ฉบับนี้ทุกท่าน

คุณประโยชน์ของวิทยานิพนธ์ฉบับนี้ ขอมอบเพื่อบุชาพระคุณบิดา มารดา ครูอาจารย์ และผู้มีพระคุณทุกท่าน

สิริวิญญ์ เดชอธิราช



สารบัญ


	หน้า
บทคัดย่อภาษาไทย.....	(5)
บทคัดย่อภาษาอังกฤษ.....	(6)
กิตติกรรมประกาศ.....	(7)
สารบัญ.....	(8)
สารบัญตาราง.....	(9)
สารบัญภาพ.....	(10)
บทที่ 1 บทนำ.....	13
1.1 ความเป็นมาและความสำคัญของปัญหา.....	13
1.2 วัตถุประสงค์ของงานวิจัย.....	16
1.3 ขอบเขตของงานวิจัย.....	16
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	16
บทที่ 2 ทฤษฎีและผลงานวิจัยที่เกี่ยวข้อง.....	17
2.1 อะโวคาโดพันธุ์แฮส (Hass Avocado).....	17
2.2 การเก็บเกี่ยวอะโวคาโดและดัชนีที่ใช้ในการเก็บเกี่ยว.....	18
2.3 ดัชนีที่ใช้ในการวัดความสุขของอะโวคาโด.....	21
2.4 แบบจำลองสี (Color models).....	22
2.5 การประมวลผลภาพ (Image Processing).....	24
2.6 OpenCV.....	26
2.7 Scikit-learn.....	26
2.8 เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence : AI).....	27
2.9 การทดสอบประสิทธิภาพ.....	37
2.10 งานวิจัยที่เกี่ยวข้อง.....	39

สารบัญ(ต่อ)

	หน้า
บทที่ 3 วิธีดำเนินงานวิจัย.....	41
3.1 ศึกษาและรวบรวมข้อมูลของอะโวคาโด.....	43
3.2 กำหนดกลุ่มตัวอย่างและกำหนดตัวแปรที่ใช้ในงานวิจัย.....	44
3.3 กระบวนการประมวลผลภาพของอะโวคาโด (Image Processing)	46
3.4 สร้างโมเดลแบบจำลองทางคณิตศาสตร์ขั้นสูงในการพยากรณ์.....	49
3.5 ทดสอบโมเดลทางคณิตศาสตร์ เพื่อทำการเปรียบเทียบประสิทธิภาพ.....	52
บทที่ 4 ผลการทดลองและวิจารณ์.....	53
4.1 การทดสอบค่าสีของผลอะโวคาโด.....	57
4.2 การทดสอบค่าความแน่นเนื้อของผลอะโวคาโด.....	58
4.3 ความสัมพันธ์ระหว่างค่าสีของเปลือกกับค่าความแน่นเนื้อของผลอะโวคาโด.....	61
4.4 การทดสอบประสิทธิภาพของโมเดล.....	63
4.5 การทดสอบค่าความแม่นยำในการทำนายของโมเดล.....	66
บทที่ 5 สรุปผลการทดลองและข้อเสนอแนะ.....	69
5.1 สรุปผลการทดลอง.....	69
5.2 ข้อเสนอแนะ.....	70
บรรณานุกรม.....	71
ภาคผนวก.....	75
ภาคผนวก ก ภาพและผลการทดลองผลของผลอะโวคาโด.....	76
ภาคผนวก ข ตัวอย่างและ Code ของโปรแกรม.....	110
ภาคผนวก ค ผลการทดลองการทดสอบโปรแกรม.....	133
ประวัติผู้เขียน.....	140

สารบัญตาราง

	หน้า
ตารางที่ 2.1 แสดงระยะเวลาอายุผลที่เหมาะสม และลักษณะผลสำหรับการเก็บเกี่ยวผล อะโวคาโด.....	21
ตารางที่ 2.2 ข้อดีและข้อจำกัดของแบบจำลองสีในระบบ RGB, L*a*b*.....	22
ตารางที่ 2.3 ความแตกต่างระหว่าง Machine Learning และ Deep learning.....	36
ตารางที่ 3.1 แผนการดำเนินงานวิจัย.....	42
ตารางที่ 3.2 แสดงข้อมูลของเฉพาะและการตั้งค่าของกล้องสมาร์ทโฟน.....	47
ตารางที่ 4.1 ผลการทดลองของผลอะโวคาโดโดยเฉลี่ย.....	53
ตารางที่ 4.2 ผลการทดสอบประสิทธิภาพของโมเดล KNN.....	63
ตารางที่ 4.3 ผลการทดสอบประสิทธิภาพของโมเดล SVR.....	64
ตารางที่ 4.4 ผลการทดสอบประสิทธิภาพของโมเดล MLP.....	65
ตารางที่ 4.5 ค่าความแม่นยำของผลอะโวคาโดที่ได้จากโมเดลกับค่าความแม่นยำที่ได้จากการ ทดลอง.....	66




สารบัญรูป

	หน้า
รูปที่ 1.1 (a) อะโวคาโดที่ดิบ (b) อะโวคาโดที่สุก.....	13
รูปที่ 2.1 แสดงสัญญาณวิทยาของผลอะโวคาโด.....	17
รูปที่ 2.2 แสดงระดับความสุกของผลอะโวคาโดพันธุ์แฮสหลังการเก็บเกี่ยว.....	18
รูปที่ 2.3 แสดงการเปลี่ยนแปลงของสีผลอะโวคาโดพันธุ์แฮสจากสีเขียวเป็นสีม่วงเข้ม.....	19
รูปที่ 2.4 แสดงการเปลี่ยนแปลงผิวของผลของอะโวคาโดพันธุ์บัคคาเนียร์จากผิวเรียบเป็นผิว ขื่นนวล.....	19
รูปที่ 2.5 แสดงการเปลี่ยนสีที่ผิวผลของอะโวคาโดพันธุ์แฮสจากสีเขียวอ่อนเป็นสีน้ำตาลเข้ม.....	20
รูปที่ 2.6 แสดงค่าสีระบบ CIELAB 1976 color space.....	23
รูปที่ 2.7 แสดงตัวอย่างกระบวนการประมวลผลรูปภาพของการคัดแยกลูกพลัม.....	24
รูปที่ 2.8 แสดงขั้นตอนการประมวลผลภาพ.....	25
รูปที่ 2.9 แสดงการจัดกลุ่มของการเรียนรู้ของเครื่อง (Machine learning).....	27
รูปที่ 2.10 แสดงรูปแบบของ Support Vector Regression แบบ Linear และ Non-linear	30
รูปที่ 2.11 แสดงเคอร์เนลฟังก์ชันของ Support Vector Regression.....	30
รูปที่ 2.12 โครงสร้างระบบประสาท Neurons ของมนุษย์.....	31
รูปที่ 2.13 โครงสร้างของ Artificial Neural Network.....	32
รูปที่ 2.14 โครงข่ายประสาทเทียมแบบชั้นเดียว (Single layer).....	34
รูปที่ 2.15 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer).....	34
รูปที่ 2.16 แสดงกระบวนการของโครงข่ายประสาทเทียมแบบหลายชั้น.....	37
รูปที่ 3.1 ขั้นตอนการดำเนินงานวิจัย.....	41
รูปที่ 3.2 ผอ.ธนากร โพธิ์กำชัย ให้ความรู้เกี่ยวกับอะโวคาโดอำเภอบพพระ จังหวัดตาก.....	43
รูปที่ 3.3 สัมภาษณ์เกษตรกรที่อำเภอบพพระ จังหวัดตาก.....	44
รูปที่ 3.4 ร้านค้าผลไม้ในนาชาติในตลาดไทที่ติดตั้งห้องแช่เย็น.....	45
รูปที่ 3.5 การทดสอบผลอะโวคาโด.....	45
รูปที่ 3.6 กระบวนการได้มาของภาพ (Image Acquisition) ของผลอะโวคาโด.....	46
รูปที่ 3.7 ขั้นตอนการประมวลผลภาพ.....	48
รูปที่ 3.8 ขั้นตอนกระบวนการสร้างโมเดล KNN.....	49
รูปที่ 3.9 ขั้นตอนกระบวนการสร้างโมเดล SVR.....	50

สารบัญรูป(ต่อ)

	หน้า
รูปที่ 3.10 ขั้นตอนกระบวนการสร้างโมเดล MLP.....	51
รูปที่ 4.1 การเปลี่ยนแปลงของค่าสีในผลอะโวคาโดที่ในกระบวนการป่มรักษา (a) คือค่าสี ของ L* (b) คือค่าสีของ a* (c) คือค่าสีของ b*.....	56
รูปที่ 4.2 ค่าสีของผลอะโวคาโดแต่ละส่วน (a) คือค่าสีของ L* (b) คือค่าสีของ a* (c) คือค่าสีของ b*.....	58
รูปที่ 4.3 ค่าความแน่นเนื้อของผลอะโวคาโดในแต่ละส่วน.....	59
รูปที่ 4.4 การเปลี่ยนแปลงของค่าความแน่นเนื้อในผลอะโวคาโด.....	59
รูปที่ 4.5 ความสัมพันธ์ระหว่างค่าสีกับค่าความแน่นเนื้อของผลอะโวคาโด (a) L* กับ Firmness (b) คือค่าสีของ a* กับ Firmness (c) คือค่าสีของ b* กับ Firmness.....	62
รูปที่ 4.6 แสดงค่าความแม่นยำในการทำนายค่าความแน่นเนื้อระหว่างค่าที่โมเดลได้ทำการ ทำนายกับค่าที่วัดได้จากการทดลอง (a) โมเดล KNN (b) โมเดล SVR (c) โมเดล MLP.....	68



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

อะโวคาโด (*Persea americana* Mill.) เป็นไม้ผลที่มีถิ่นกำเนิดจากในทวีปอเมริกาบริเวณประเทศเม็กซิโก กัวเตมาลา และหมู่เกาะเวสอินดีส อะโวคาโดเป็นผลไม้ที่รับประทานกันมานานในอเมริกาและยุโรป [1] ซึ่งอะโวคาโดในประเทศไทยถูกนำมาทดลองปลูกโดยโครงการหลวงในพื้นที่ศูนย์พัฒนาโครงการหลวงทุ่งเริงเมื่อปี พ.ศ.2526 ผลปรากฏว่าผลผลิตของอะโวคาโดที่ได้มีคุณภาพดี จึงได้นำมาทดลองให้เกษตรกรทำการเพาะปลูก ซึ่งพันธุ์อะโวคาโดที่ปลูกในประเทศไทยจำแนกเป็น 6 สายพันธุ์ คือ จำแนกเป็น 6 สายพันธุ์ คือ ปีเตอร์สัน (Peterson), บูช 7 (Booth 7), บูช 8 (Booth 8), บัคคาเนีย (Buccaneer), พิงค์เคอตัน (Pinkerton), แฮสส์ (Hass) [2]

ผลอะโวคาโดมีแหล่งพลังงานที่มีประโยชน์ต่อร่างกาย เช่น กรดไขมันไม่อิ่มตัว แร่ธาตุ วิตามิน ทำให้ในปัจจุบันอะโวคาโดเป็นผลไม้ที่ได้รับความนิยมจากผู้บริโภคที่รักสุขภาพ ทั้งยังมีส่วนช่วยลดการเกิดโรคหัวใจ โรคเมะเร็ง และโรคเบาหวาน เป็นต้น เพราะมีสารต้านออกซิเดชันที่สูง และยังมีส่วนช่วยลดระดับของคลอเรสเตอรอลในเลือดอีกด้วย เนื่องจากผลอะโวคาโดที่ยังเป็นผลดิบจะมีสารแทนนินที่สูง ดังนั้นการบริโภคผลอะโวคาโดจะบริโภคได้เฉพาะผลที่สุกแล้วเท่านั้น ดังรูปที่ 1.1



รูปที่ 1.1 (a) อะโวคาโดที่ดิบ (b) อะโวคาโดที่สุก

ที่มา : ผู้วิจัย

ผลอะโวคาโดที่เจริญเติบโตถึงระยะความสุกที่พร้อมสำหรับการเก็บเกี่ยว เนื้อสัมผัสจะนุ่มและเนียนละเอียด แต่หากทำการเก็บเกี่ยวผลที่ยังอ่อนหรือผลที่ยังเจริญเติบโตไม่เต็มที่ เมื่อนำไปบ่มรักษาผลอะโวคาโดจะเกิดการเหี่ยว เนื้อสัมผัสจะเหนียวคล้ายยาง [3] ในงานวิจัยนี้จึงเลือกผลอะโวคาโดพันธุ์แฮสส์ในการศึกษา เนื่องจากผลอะโวคาโดพันธุ์แฮสส์ได้รับความนิยมในการบริโภคมากที่สุด

จากการศึกษาข้อมูลเบื้องต้นได้ทำการสำรวจพื้นที่เพาะปลูกอะโวคาโดที่ อ.พจนพระ จ.ตาก เมื่อตุลาคม พ.ศ. 2565 ได้สอบถามเจ้าหน้าที่ภาครัฐและเกษตรกรที่ทำการเพาะปลูกอะโวคาโด ทำให้ทราบว่าเกษตรกรในพื้นที่จะใช้ประสบการณ์ของแต่ละบุคคลในการเก็บเกี่ยวจากการสังเกตลักษณะภายนอกของผลอะโวคาโด หรือใช้วิธีการนับจำนวนวันหลังจากที่ดอกของต้นอะโวคาโดเริ่มบานหรือเริ่มติดผล ซึ่งไม่ได้สัมพันธ์กับระดับความสุกของผลอะโวคาโดโดยตรง ส่งผลให้การเก็บเกี่ยวผลอะโวคาโดมีคุณภาพที่ไม่สม่ำเสมอ และส่งผลให้การขนส่งผลอะโวคาโดมายังพ่อค้าคนกลางกับผู้บริโภคนั้นไม่ได้คุณภาพที่สม่ำเสมอเช่นกัน จึงยากที่จะตอบสนองความต้องการของตลาดและผู้บริโภค ดังนั้นจึงเป็นที่มาในการศึกษาและการนำเทคโนโลยีการประมวลผลภาพมาประยุกต์ใช้ เพื่อวิเคราะห์ระดับความสุกของ ผลอะโวคาโดเพื่อช่วยให้ผู้บริโภคสามารถเลือกผลอะโวคาโดที่สุกพร้อมรับประทานแทนวิธีเดิม เช่น การบีบเพื่อเลือกผลอะโวคาโดที่สุกกับดิบ เป็นต้น

ปัจจุบันเทคนิคการประมวลผลภาพถูกนำมาใช้ในการวิเคราะห์ความสุกของผลไม้หลากหลายชนิด เช่น เกรปต์ และคณะ [4] ได้ศึกษาการวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพโดยใช้ซอฟต์แวร์ NI Vision Builder ทำงานร่วมกับกล้องเว็บแคม โดยจะทำการเรียกรูปจากกล้อง (Acquire Image) แล้วทำการตรวจจับวัตถุ (Detect Objects) และทำการตั้งค่า Threshold เพื่อกำหนดค่าสีที่จะประมวลผลและทำการกำหนดค่าการสุกของผลไม้ในระบบสี RGB โดยมีความถูกต้องในการวิเคราะห์ความสุกเป็น 95% และอภิศักดิ์ และพิทักษ์ [5] ได้ทำการศึกษาระดับความสุกของทุเรียนพันธุ์หลงลับแลจากสีเปลือกด้วยการประมวลผลภาพ โดยได้ทำการเก็บตัวอย่างมาทำการวัดค่าความแน่นเนื้อแล้วจัดกลุ่มข้อมูลตามระดับความสุกด้วยวิธีการ Hierarchical Cluster Analysis และได้ทำการเก็บภาพของทุเรียนด้วยสมาร์ทโฟน นำมาประมวลผลภาพโดยการปรับภาพให้เป็นโทนสี HSL และปรับปรุงภาพโดยวิธีการ Median Kernel หลังจากนั้นทำการหาขอบภาพด้วยวิธีการ Sobel และทำการ Threshold เพื่อหาจุดกึ่งกลางภาพและสร้างกรอบ ROI และคำนวณหาค่าสีในระบบของ CIE $L^*a^*b^*$ และได้ทำการวิเคราะห์ความแปรปรวนระหว่างระดับความสุกกับค่าสี $L^*a^*b^*$ ที่ระดับความเชื่อมั่นที่ 95% พบว่าค่าสี b^* จะมีค่าเพิ่มขึ้นเมื่อระดับความสุกของทุเรียนเพิ่มขึ้น Mozaffari, Sadeghi & Asefi [6] ได้ศึกษาคุณสมบัติและระดับความสุกของผลแอปเปิ้ลด้วยวิธีการประมวลผลภาพจากการใช้ภาพการสะท้อนกลับของการกระจายของแสงเลเซอร์ที่ฉายไปที่ผลแอปเปิ้ลที่บันทึกได้ด้วยกล้อง CCD โดยจะทำการแยกภาพ (Image Segmentation) ของภาพพื้นหลังกับภาพ

การสะท้อนกลับการกระจายของแสงด้วยวิธีการ Thresholding และทำการแยกค่าความเข้มของแสงในส่วนที่กระจายกลับมาใช้ในการทำนายคุณสมบัติและระดับความสุกของผลแอปเปิ้ลด้วยการใช้โมเดล Artificial Neural Network (ANN) และได้ความแม่นยำถึง 97.4% นอกจากนี้ Sanaeifar, Bakhshipour & de la Guardia [7] ได้ศึกษาคุณสมบัติของกล้วยจากวิธีการประมวลผลรูปภาพโดยใช้ค่าสีในระบบ RGB, $L^*a^*b^*$, HSV โดยใช้โปรแกรม MATLAB v8.1 เริ่มจากการปรับปรุงภาพ (Image enhancement) โดยการลบสัญญาณรบกวน (Noise) และปรับความเข้มของแสง (Contrast) ของภาพก่อนที่จะทำการแยกภาพของกล้วยออกจากภาพพื้นหลัง และทำการแปลงค่าสีของภาพในระบบ RGB เป็น $L^*a^*b^*$, HSV เพื่อใช้ในการทำนายคุณสมบัติของกล้วยด้วยโมเดล Support Vector Regression (SVR) และ Artificial Neural Network (ANN) และ Sherafati, Mollazade, Koushesh Saba & Vesali [8] ที่ได้ทำการศึกษาการคุณภาพและระยะการสุกของผลมะเขือเทศจากการด้วยวิธีการประมวลผลภาพจากการใช้ภาพการสะท้อนกลับของการกระจายของแสงเลเซอร์ที่ฉายไปที่ผลมะเขือเทศที่บันทึกได้ด้วยสาร์ทโฟนในระบบสี RGB โดยจะทำการลดขนาดของรูปและทำการแยกค่าขององค์ประกอบของสีเพื่อส่งค่าสีไปใช้ในการทำนายคุณภาพและวัดระดับความสุกของผลมะเขือเทศด้วยโมเดล MLP และได้ทำการสร้างแอปพลิเคชัน TomatoScan ซึ่งสามารถทำนายคุณสมบัติได้อย่างความแม่นยำ Keramat-Jahromi, Mohtasebi, Mousazadeh, Ghasemi-Varnamkhasti, Rahimi-Movassagh [9] ได้ทำการศึกษาทำนายหาค่าความชื้นของผลอินทผลัมแบบเรียลไทม์ทางออนไลน์โดยใช้โมเดล K-Nearest Neighbors (KNN) และ โมเดล Random Forrest (RF) โดยจะใช้เครื่องอบแห้งด้วยความร้อนด้วยสนามแม่เหล็กไฟฟ้า (Electro-Hydrodynamic (EHD) dryers) โดยจะติดตั้งบนที่ชั่งน้ำหนักไว้และยังได้ทำการติดกล้องไว้ภายในเพื่อถ่ายภาพตามเวลาที่กำหนด และในการประมวลผลภาพนั้นจะเริ่มด้วยการแปลงรูปที่ได้จากระบบ RGB ไปเป็นระบบ $L^*a^*b^*$ แล้ว Thresholding เพื่อแยกพื้นหลังออกจากผลอินทผลัม และได้ทำการ Filtering ในส่วนที่หายไปแล้วนำภาพที่แยกผลอินทผลัมกับพื้นหลังออกมารวมกับภาพผลอินทผลัมในระบบสี $L^*a^*b^*$ หลังจากนั้นจะทำการแยกองค์ประกอบของค่าสีร่วมกับน้ำหนักของผล อินทผลัมที่เปลี่ยนไปในระหว่างการอบ มาใช้ในการทำนายความชื้น โดยจะใช้โมเดล KNN และ RF ทำนาย ซึ่งมีค่า R^2 เท่ากับ 0.959 และ 0.976 ซึ่งถือว่ามีความแม่นยำในการทำนายที่สูง

จากงานวิจัยที่ได้กล่าวไปข้างต้นจึงเป็นเหตุให้คณะผู้จัดทำได้นำเทคนิคนี้มาใช้งานวิจัยโดยมีวัตถุประสงค์เพื่อวัดความสุขของผลอะโวคาโดด้วยวิธีการประมวลผลภาพร่วมกับโมเดลแบบจำลองทางคณิตศาสตร์มาช่วยในการทำนายระดับความสุขของผลอะโวคาโด และจากการศึกษาข้อมูลพบว่าโมเดล Multi-layer perceptron (MLP), Support Vector Regression (SVR), K-Nearest Neighbors (KNN) เป็นโมเดลที่ใช้ในการวิเคราะห์ข้อมูล (Regression) ที่มีความแม่นยำในการทำนายที่สูงสำหรับการฝึกฝนและทดสอบจำนวนข้อมูลตัวอย่างที่น้อยได้ดี จึงนำมาประยุกต์ใช้ในงานวิจัยนี้

1.2 วัตถุประสงค์ของงานวิจัย

- 1.2.1 เพื่อสร้างและทดสอบแบบจำลองทางคณิตศาสตร์การทำนายความสุขของอะโวคาโด
- 1.2.2 เพื่อเปรียบเทียบแบบจำลองทางคณิตศาสตร์ที่เหมาะสมในการทำนายระดับความสุขของอะโวคาโด
- 1.2.3 เพื่อเป็นแนวทางการในพัฒนาแบบจำลองทางคณิตศาสตร์ในการทำนายความสุขของอะโวคาโด

1.3 ขอบเขตของงานวิจัย

- 1.3.1 ใช้อะโวคาโดพันธุ์แฮสในการทดสอบ
- 1.3.2 ใช้วิธีการประมวลผลภาพ (Image Processing)
- 1.3.3 ดัชนีที่ใช้ในการทำนายความสุขของอะโวคาโดในงานวิจัยนี้ คือ ค่าความแน่นของเนื้อ
- 1.3.4 โมเดลที่ใช้ในงานวิจัยคือ KNN, SVR, MLP
- 1.3.5 ใช้ภาษาไพทอน (Python) ในการเขียนโปรแกรม
- 1.3.6 ใช้ OpenCV ในการประมวลผลภาพ และใช้ Scikit-Learn ในการสร้างโมเดล
- 1.3.7 ใช้ Google Colab ในการ Run โปรแกรม

1.4 ประโยชน์ที่คาดว่าจะได้รับ


- 1.4.1 ได้แบบจำลองทางคณิตศาสตร์ที่เหมาะสมในการทำนายความสุขของอะโวคาโด
- 1.4.2 มีข้อมูลเพื่อเป็นแนวทางในการพัฒนาแอปพลิเคชัน ทำนายความสุขของอะโวคาโดโดยใช้แบบจำลองทางคณิตศาสตร์

บทที่ 2

ทฤษฎีและผลงานวิจัยที่เกี่ยวข้อง

2.1 อะโวคาโดพันธุ์แฮส (Hass Avocado)

ผลอะโวคาโดมีสัณฐานวิทยาแบ่งเป็น 2 ส่วน ได้แก่ ส่วนเมล็ด (Seed) และส่วนเพอร์ริคาร์ป (Pericarp) ที่ประกอบด้วยเอ็นโดคาร์ป (Endocarp), เมโซคาร์ป (Mesocarp) และเอ็กโซคาร์ป (Exocarp) ดังรูปที่ 2.1 [3] และอะโวคาโดพันธุ์แฮส (Hass) ผลเป็นรูปไข่ผิวขรุขระโดยมากผิวเมื่อผลอ่อนจะมีสีเขียวเข้ม และเมื่อผลสุกจะเปลี่ยนเป็นสีม่วงดำ ดังรูปที่ 2.2 ซึ่งอะโวคาโดพันธุ์นี้จะมีขนาดเล็ก น้ำหนักประมาณ 200–300 กรัม เนื้อจะมีสีเขียวอมเหลือง เมล็ดเล็กถึงขนาดกลางเปลือกผลค่อนข้างหนา ช่วงเก็บเกี่ยวผลจะอยู่ในช่วงเดือนธันวาคม–กุมภาพันธ์อะโวคาโดพันธุ์นี้เป็นพันธุ์การค้าที่สำคัญของโลก เพราะคุณภาพผลดีมากและอายุการวางจำหน่ายยาวนานมาก [10]



รูปที่ 2.1 แสดงสัณฐานวิทยาของผลอะโวคาโด

ที่มา : Magwaza & Tesfay (2015)



รูปที่ 2.2 แสดงระดับความสุกของผลอะโวคาโดพันธุ์แฮสหลังการเก็บเกี่ยว

ที่มา : ผู้วิจัย

2.2 การเก็บเกี่ยวอะโวคาโดและดัชนีที่ใช้ในการเก็บเกี่ยว

อะโวคาโดจะให้ผลผลิตได้เมื่ออายุประมาณ 4 ปีหลังจากทำการปลูก โดยจะออกดอกในช่วงปลายฤดูฝนและช่วงฤดูหนาว จะเริ่มติดผลในเดือนพฤศจิกายนถึงเดือนกุมภาพันธ์ แล้วจึงจะเริ่มเก็บเกี่ยวได้ในเดือนเมษายนถึงพฤศจิกายน ทั้งนี้ต้นอะโวคาโดจะติดดอกออกผลทุกปี ผลอะโวคาโดไม่เหมือนผลไม้ชนิดอื่นตรงที่ผลจะไม่สุกขณะที่ยังอยู่บนต้น ต้องเก็บผลที่แก่หรือสุกพอดีแล้วนำมาบ่มรักษา จึงจะสุกสมบูรณ์ ในการเก็บเกี่ยวอะโวคาโดควรเก็บเกี่ยวผลที่กิ่งด้านล่างรอบๆ ชายพุ่มก่อนแล้วจึงเก็บผลที่อยู่ในระดับสูงขึ้นไป ควรจับกันผลแล้วใช้กรรไกรตัดที่ขั้ว ต้องให้ขั้วติดมากับผลด้วยอย่างน้อย 1-2 นิ้ว จะทำให้สามารถเก็บไว้ในห้องเย็นได้นาน ผลที่อยู่สูงควรใช้ตะกร้อสอย และควรเก็บผลในเวลาเช้า [11] ดัชนีที่ใช้ในการเก็บเกี่ยวผลอะโวคาโดได้แก่

2.2.1 ลักษณะภายนอกของผล

2.2.1.1 การเปลี่ยนแปลงสีของผล

อะโวคาโดแต่ละพันธุ์จะมีการเปลี่ยนแปลงของสีไม่เหมือนกัน ผลอ่อนจะมีสีเขียว เมื่อสุกแก่แล้วมีสีเขียวเข้มๆ เช่น ฮอลล์ เฟอร์เต้ ฟิงเกอร์ตัน เป็นต้นและสีเขียวอมเหลือง เช่น รูเอิล ปีเตอร์สัน โซเคท ปากช่อง 28 เป็นต้น และสีม่วงอมแดงหรือม่วงเข้ม เช่น แฮสส์ แลมป์แฮสส์ เป็นต้น


ดังรูปที่ 2.3



รูปที่ 2.3 แสดงการเปลี่ยนแปลงของสีผลอะโวคาโดพันธุ์แฮสจากสีเขียวเป็นสีม่วงเข้ม
ที่มา : ผู้วิจัย

2.2.1.2 การเปลี่ยนแปลงผิวของผล

เมื่ออะโวคาโดสุกแก่ ผิวภายนอกจะมีการเปลี่ยนแปลงโดยเปลี่ยนจากผิวเรียบ มันวัด กลายเป็นมีสะเก็ดสีน้ำตาลนูนขึ้น เช่น ปีเตอร์สัน บูท 7 บูท 8 ปากช่อง 28 เป็นต้น และกลายเป็นผิวขรุขระ สัมผัสสาก เช่น ฟิงเกอร์ตัน เฟอร์โต้ แฮสส์ แลมป์แฮสส์ เป็นต้น และเป็นผิวเรียบ เช่น รูเอิล และเป็นผิวขื่นนวล เช่น บัคคาเนียร์ พันธุ์พื้นเมืองบางสายพันธุ์ เป็นต้น ดังรูปที่ 2.4



รูปที่ 2.4 แสดงการเปลี่ยนแปลงผิวของผลของอะโวคาโดพันธุ์บัคคาเนียร์จากผิวเรียบเป็นผิวขื่นนวล
ที่มา : ผู้วิจัย

2.2.1.3 การเปลี่ยนแปลงที่ชั่วผลหรือก้านดอก

เมื่อผลอ่อนชั่วผลจะมีสีเขียวอ่อน เมื่อสุกแล้วมีสีเขียวปนเหลือง เช่น ปีเตอร์สัน รูเอิล โซเควท เป็นต้น หรือแตกสะเก็ดสีน้ำตาลอ่อนหรือเข้ม เช่น ฟิงเคอร์ตัน แฮสส์ แลมป์แฮสส์ เป็นต้น ดังรูปที่ 2.5



รูปที่ 2.5 แสดงการเปลี่ยนสีที่ชั่วผลของอะโวคาโดพันธุ์แฮสจากสีเขียวอ่อนเป็นสีน้ำตาลเข้ม
ที่มา : ผู้วิจัย

2.2.3 การนับอายุผล

การนับอายุผลเป็นวิธีที่ดีที่สุดของเกษตรกรปัจจุบัน โดยจะเริ่มนับหลังจากดอกบาน 50 เปอร์เซ็นต์ของช่อดอกจนถึงช่วงเก็บเกี่ยว โดยอายุผลในการเก็บเกี่ยวจะขึ้นอยู่กับพันธุ์และสถานที่ปลูกซึ่งเกี่ยวข้องกับสภาพอากาศและอุณหภูมิ สำหรับดอกอะโวคาโดโดยปกติดอกย่อยภายในช่อดอกในแต่ละต้นจะบานไม่พร้อมกัน ทำให้อายุผลของแต่ละผลไม่เท่ากัน จึงต้องบันทึกวันและทำเครื่องหมายที่ช่อดอกไว้เมื่อดอกบานมากกว่า 50 เปอร์เซ็นต์ของช่อดอก เพื่อบันทึกวันของดอกและผลแต่ละรุ่น แสดงในตารางที่ 2.1 [2]

ตารางที่ 2.1 แสดงระยะเวลาอายุผลที่เหมาะสม และลักษณะผลสำหรับการเก็บเกี่ยวผลอะโวคาโด

พันธุ์อะโวคาโด	ช่วงระยะเวลา	อายุผล	ลักษณะ
1. ปีเตอร์สัน	มิถุนายน - กรกฎาคม	160	ผลแก่ผิวผลจะเปลี่ยนจากสีเขียวเป็นเขียวเหลือง เกิดจุดประสีน้ำตาล
2. บูช-7	กันยายน - ตุลาคม	170	ผลแก่จะมีนวลที่ผิวผล สีผิวผลเป็นสีเขียว
3. บูช-8	กันยายน - ตุลาคม	177	ผลแก่จะมีนวลที่ผิวผล สีผิวผลเป็นสีเขียว
4. บัคคาเนีย	กันยายน - ตุลาคม	180	ผลแก่จะมีนวลที่ผิวผล สีผิวผลเป็นสีเขียว
5. ฟิงค์เคอตัน	ตุลาคม - ธันวาคม	309	ผลแก่ผิวผลจะเปลี่ยนจากสีเขียวเป็นสีเขียวเข้ม
6. แฮส	พฤศจิกายน - กุมภาพันธ์	250	ผลแก่ผิวผลจะเปลี่ยนจากสีเขียวเข้มเป็นสีม่วงดำ

ที่มา : มูลนิธิโครงการหลวง สถาบันวิจัยและพัฒนาพื้นที่สูง (องค์การมหาชน) (2563). คู่มือการเก็บเกี่ยวอะโวคาโดบนพื้นที่สูง

2.3 ดัชนีที่ใช้ในการวัดความสุกของอะโวคาโด

การวัดความแน่นของผลไม้ (Firmness) เป็นหนึ่งในดัชนีที่เป็นที่ยอมรับในระดับสากล เป็นการวิเคราะห์ทางกายภาพ ซึ่งเป็นการวัดระดับสุกหลังการเก็บเกี่ยว โดยที่ค่าความแน่นของเนื้ออะโวคาโดจะลดลงเรื่อยๆ โดยค่าความแน่นของเนื้ออะโวคาโดที่ยังเป็นผลดิบจะลดลงอย่างช้าๆ และเมื่ออะโวคาโดเริ่มที่จะใกล้สุกเต็มค่าความแน่นของเนื้อจะลดลงไถ่ศูนย์ [12] เนื่องจากในระหว่างการสุกจะมีการเสื่อมสลายของผนังเซลล์หรือสารที่เชื่อมกับผนังเซลล์ จึงทำให้เนื้อผลอ่อนนุ่มลง ทำให้ผู้บริโภคสามารถที่จะแยกอะโวคาโดผลที่พร้อมรับประทานออกจากผลที่ยังไม่สุกได้

การบ่มเก็บรักษาอะโวคาโต้นั้นหากเก็บผลที่แก่หรือสุกพอดีเมื่อนำมาบ่มในอุณหภูมิห้องจะสุกได้ดีกว่า คือ ผิวของผลอะโวคาโดที่สุกจะไม่เหี่ยวย่นรสชาติดี เนื้อไม่แข็งและไม่ขม ผลอะโวคาโดที่ดิบเนื้อจะแข็งและมีแทนนินสูง ใช้เวลาในการบ่มนาน 3-9 วัน จึงจะสุก ผลที่บ่มจะสุกช้าหรือเร็วขึ้นอยู่กับอุณหภูมิและพันธุ์ ผลอะโวคาโดที่เก็บจากต้นเมื่อนำมาบ่มในอุณหภูมิ 10-18 องศาเซลเซียส จะเก็บไว้ได้นาน 20-21 วัน แล้วจึงจะทำให้ผลนิ่มหรือปล่อยให้สุกที่อุณหภูมิห้อง และถ้าเก็บรักษาผลอะโวคาโดที่อุณหภูมิ 2 องศาเซลเซียส จะสามารถเก็บผลอะโวคาโดได้ระยะเวลามากกว่า 40 วัน [11]


2.4 แบบจำลองสี (Color models)

ตารางที่ 2.2 ข้อดีและข้อจำกัดของแบบจำลองสีในระบบ RGB, L*a*b*

ระบบสี	ข้อดี	ข้อจำกัด
RGB	ใช้งานได้ง่ายเพราะเมื่อถ่ายรูปออกมา รูปจะอยู่ในระบบของระบบสี RGB	สีของภาพขึ้นกับอุปกรณ์เช่น กล้อง จอภาพ สแกนเนอร์
L*a*b*	สีของภาพมีความคงที่ไม่ขึ้นกับอุปกรณ์ เช่น กล้อง จอภาพ สแกนเนอร์และ เครื่องพิมพ์ เป็นมาตรฐานสีที่นิยมใช้ใน งานของอุตสาหกรรมอาหาร	ไม่สามารถอ่านค่าได้ทันทีต้อง แปลงค่าสีให้เป็น L* a* b* ก่อน

ในงานวิจัยนี้ได้เลือกใช้แบบจำลองสีในระบบ CIE L*a*b* มาใช้ในการทำนายระดับความสุขของอะโวคาโดเนื่องจากเป็นระบบสีที่นิยมใช้งานด้านการวิจัยอาหาร และสีของภาพคงที่ไม่ขึ้นกับอุปกรณ์การถ่ายรูป

ระบบ CIE L*a*b* เป็นระบบการวัดสีที่เป็นมาตรฐานสากล พัฒนาโดย Commission International de l' Eclairage (CIE) ระบบ CIE L*a*b* พัฒนามาจากระบบ CIE Tristimulus Value ค่าที่ได้ออกมาจะเป็น X, Y, Z โดยจะระบุเป็นค่าสีแดง สีเขียว และสีน้ำเงิน ตามลำดับ แต่ยังคงขาดความสัมพันธ์ระหว่างกันสีที่มองเห็น และระบบ CIE Chromaticity coordinate เป็นวิธีการที่ระบุความหมายของสีให้ชัดเจนขึ้น โดยที่ค่าจะระบุ x, y, Y ซึ่งค่า x และ y เป็นค่าที่ระบุความเป็นสี ส่วนความสว่างของสีเป็นค่า Y แต่วิธีการนี้ยังไม่เหมาะที่จะนำมาใช้ในการบอกค่าความแตกต่างของสีได้ดี จึงทำการพัฒนาปรับปรุงจนสามารถของความแตกต่างของสีได้ และมีความใกล้เคียงกับความแตกต่างของสีที่ตามองเห็น ปัจจุบันสมการที่ใช้ในการระบุสีเป็นที่ยอมรับกว้างขวางคือ CIELAB 1976 ซึ่งมีลักษณะเป็น Color space ดังรูปที่ 2.6 ซึ่งเป็นระบบที่วัดสีออกมาเป็นตัวเลขที่สามารถนำไปคำนวณและทำนายค่าสีที่ผสมได้ [13]



รูปที่ 2.6 แสดงค่าสีระบบ CIELAB 1976 color space

ที่มา : Agudo, J. E., Pardo, P. J., Sánchez, H., Pérez, Á. L., & Suero, M. I. (2014)

โดยกำหนด

L^* (Lightness) ค่าความสว่างมีค่าอยู่ระหว่าง 0 – 100

$L^* = 0$ สีจะไปทิศทางที่มีดเป็นสีดำ

$L^* = 100$ สีจะไปทิศทางที่สว่างเป็นสีขาว

แกน a^* ใช้กำหนดความเป็นสีแดงหรือสีเขียว

a^* เป็น + สีจะไปทิศทางของสีแดง

a^* เป็น - สีจะไปทิศทางของสีเขียว


แกน b^* ใช้กำหนดความเป็นสีเหลืองหรือสีน้ำเงิน

b^* เป็น + สีจะไปทิศทางของสีเหลือง

b^* เป็น - สีจะไปทิศทางของสีน้ำเงิน [14]

2.5 การประมวลผลภาพ (Image Processing)

การประมวลผลภาพ (image processing) คือ การนำข้อมูลรูปภาพเข้าคอมพิวเตอร์เพื่อให้คอมพิวเตอร์ทำการประมวลผลรูปภาพออกมา เป็นการเรียกใช้ขั้นตอนหรือกรรมวิธีใดๆ มากระทำกับภาพ เพื่อปรับปรุงคุณภาพของภาพให้ได้ภาพใหม่ที่มีคุณสมบัติตามต้องการเช่น ความคมชัด การประหยัดพื้นที่ในการเก็บข้อมูล หรือใช้สำหรับการประมวลผลในระดับสูงเช่น การจดจำรูปร่าง ลักษณะได้อย่างแม่นยำ เป็นต้น ดังรูปที่ 2.7




รูปที่ 2.7 แสดงตัวอย่างกระบวนการประมวลผลรูปภาพของการคัดแยกลูกพลัม

ที่มา : Mohammadi, Kheiralipour & Ghasemi-Varnamkhasti (2015) [15]

2.5.1 การประมวลผลภาพดิจิทัล (Digital Image Processing)

การประมวลผลภาพดิจิทัลเป็นกระบวนการที่ใช้ในการจัดการข้อมูลที่เกี่ยวข้องกับการแปลงข้อมูลที่เป็นรูปภาพต่างๆ จากสัญญาณอนาล็อกให้อยู่ในรูปของสัญญาณดิจิทัล เพื่อใช้ในการประมวลผลทางคอมพิวเตอร์ และยังสามารถนำมาใช้ในการลดปัญหาของภาพ อีกทั้งยังสามารถนำไปใช้ประโยชน์ในทางอื่น เช่น การตกแต่ง การส่งรูปไปตามสายนำสัญญาณจากที่หนึ่งไปยังอีกที่หนึ่ง เป็นต้น การแปลงภาพเป็นสัญญาณดิจิทัล เริ่มต้นจะนำรูปภาพอนาล็อกที่ได้ไปคำนวณโดยกระบวนการ sampling และ quantization แล้วส่งข้อมูลออกเป็นรูปแบบดิจิทัล จากนั้นจะเก็บข้อมูลลงหน่วยความจำบนคอมพิวเตอร์ โดยการจองหน่วยความจำภายในเครื่องในรูปแบบของอาร์เรย์ โดยค่าในแต่ละช่องของอาร์เรย์แสดงถึงคุณสมบัติของรูป และตำแหน่งของช่องอาร์เรย์ก็เป็นตัวกำหนดตำแหน่งของพิกเซลภายในภาพด้วยเช่นกัน

2.5.2 ขั้นตอนของการประมวลผลภาพโดยทั่วไปประกอบด้วย 4 ขั้นตอนดังรูปที่ 2.8



รูปที่ 2.8 แสดงขั้นตอนการประมวลผลภาพ

2.5.2.1 การได้มาของรูปภาพ (image acquisition) การรับสัญญาณจากอุปกรณ์ถ่ายภาพต่างๆ ซึ่งอยู่ในรูปสัญญาณอนาล็อก แล้วแปลงสัญญาณที่ได้ให้เป็นสัญญาณดิจิทัล เช่น กล้องถ่ายภาพดิจิทัล กล้องเว็บแคม เป็นต้น แสงสว่างเป็นสิ่งจำเป็นในการได้มาของรูปภาพสำหรับการประเมินคุณภาพของอาหาร สภาวะของแสงจะส่งผลกระทบต่อคุณภาพของรูปภาพ ซึ่งภาพถ่ายที่มีคุณภาพสูงจะช่วยลดเวลาและลดความซับซ้อนของขั้นตอนการประมวลผลภาพได้

2.5.2.2 การเตรียมภาพถ่าย (image pre-processing) คือขั้นตอนการปรับปรุงคุณภาพของภาพ เนื่องจากภาพจะมีสัญญาณรบกวน ซึ่งทำให้คุณภาพของภาพลดลง ซึ่งวัตถุประสงค์ของการเตรียมภาพถ่ายคือการปรับปรุงข้อมูลภาพ โดยลดการบิดเบือนและเพิ่มคุณสมบัติของภาพที่มีความสำคัญต่อการประมวลผลภาพในอนาคตต่อไป ซึ่งวิธีการประมวลผลภาพเบื้องต้นมี 2 ประเภทคือการประมวลผลพิกเซลเบื้องต้น (pixel pre-processing) สำหรับการประเมินคุณภาพอาหารจะนิยมใช้การเปลี่ยนแปลงระบบสี เช่น การเปลี่ยนเป็นระบบ HSI หรือระบบ $L^*a^*b^*$ เป็นต้น และการประมวลผลทั่วไปเบื้องต้น (local pre-processing) เช่น การปรับความสว่าง การกำจัดสัญญาณรบกวน เป็นต้น

2.5.2.3 การแยกส่วนของภาพ (image segmentation) เป็นการแยกวัตถุที่เราสนใจในภาพออกจากพื้นหลังของภาพ วิธีการที่ใช้ในการประเมินคุณภาพของอาหารแบ่งออกเป็น 4 วิธี ได้แก่ การแยกบริเวณโดยการกำหนดค่าขีดจำกัด (thresholding based segmentation) การแยกบริเวณโดยใช้ขอบของวัตถุ (region based) การแยกบริเวณโดยการหาเกรเดียนต์ (gradient-based segmentation) และการแยกบริเวณโดยการแบ่งประเภท (classification-based segmentation)

2.5.2.4 การวัดคุณลักษณะ (object measurement) หลังจากการแยกส่วนของภาพเพื่อให้ได้ส่วนของวัตถุที่เราสนใจ จากนั้นจะทำการวัดคุณลักษณะของวัตถุ สำหรับการประเมินคุณภาพของอาหารลักษณะของภาพแบ่งออกเป็น 4 กลุ่มคือ ขนาด รูปร่าง สี และผิวสัมผัส [16]

2.6 OpenCV

OpenCV (Open Source Computer Vision Library) เป็น Application Peripheral Interface (API) ที่พัฒนาโดย Intel ซึ่งสามารถใช้สำหรับการประมวลผลภาพและแอปพลิเคชันการมองเห็นของคอมพิวเตอร์ OpenCV เปิดตัวอย่างเป็นทางการในปี 1999 และเดิมทีโครงการนี้เป็นโครงการริเริ่มของ Intel Research เพื่อพัฒนาแอปพลิเคชันที่ใช้ CPU มาก ซึ่งเป็นส่วนหนึ่งของชุดโครงการต่างๆ ซึ่งรวมถึง Ray Tracing แบบเรียลไทม์และผนังแสดงผล 3 มิติ และไลบรารีของ OpenCV คือคอลเล็กชันของอัลกอริทึมและฟังก์ชัน C/C++ และบางคลาสที่ใช้การประมวลผลภาพและอัลกอริทึมการมองเห็นของคอมพิวเตอร์ มีการพัฒนาอินเทอร์เฟซ (interface) สำหรับ Python, Ruby, MATLAB และภาษาอื่นๆ อย่างต่อเนื่อง และหากมีความจำเป็นต้องเพิ่มประสิทธิภาพเพิ่มเติมบนสถาปัตยกรรมของ Intel จะต้องใช้ Intel's Integrated Primitives (IPP) คือไลบรารีซึ่งประกอบด้วยพฤติกรรมที่ปรับให้เหมาะสมในระดับต่ำในพื้นที่อัลกอริทึมต่างๆ มากมาย ซึ่งมีฟังก์ชันมากกว่า 500 ฟังก์ชันที่ครอบคลุมหลายด้านในด้านการมองเห็น รวมถึงการตรวจสอบผลิตภัณฑ์ในโรงงาน การสร้างภาพทางการแพทย์ การรักษาความปลอดภัย ส่วนติดต่อผู้ใช้ การปรับเทียบกล้อง [17]

2.7 Scikit-learn


Scikit-learn เป็น open source เป็นเครื่องมือหรือโมดูล ของภาษา Python ในการทำ machine learning ซึ่งมีความง่ายและมีประสิทธิภาพในการทำ predictive data analysis โดยสร้างขึ้นมาจากโมดูลหลายตัวทั้ง NumPy, SciPy และ matplotlib ส่งผลให้ scikit-learn มีความสามารถที่หลากหลาย จึงนำไปใช้งานได้หลายประเภททั้งในด้านวิชาการและเชิงพาณิชย์ [18]

2.8 เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence : AI)

ปัญญาประดิษฐ์ (AI) เป็นศาสตร์ทางด้านวิทยาศาสตร์และวิศวกรรมศาสตร์ในการสร้างความฉลาดให้กับเครื่องจักรหรือคอมพิวเตอร์ เพื่อให้สามารถคำนวณ คิดหาเหตุผล สร้างแบบจำลอง มีการเรียนรู้ได้เหมือนกับสมองของมนุษย์ เพื่อช่วยให้ระบบคอมพิวเตอร์สามารถทำงานแทนมนุษย์ได้อย่างมีประสิทธิภาพ [19]

2.6.1 การเรียนรู้ของเครื่อง (Machine learning)

การเรียนรู้ของเครื่อง (Machine learning) เป็นสาขาหนึ่งของปัญญาประดิษฐ์ที่เกี่ยวข้องกับการศึกษาและการสร้างอัลกอริทึมที่สามารถเรียนรู้ข้อมูลและทำนายข้อมูลได้ โดยอาศัยโมเดลแบบจำลองที่สร้างมาจากชุดข้อมูลตัวอย่างเข้าเป็นตัวอย่างเพื่อให้คอมพิวเตอร์เกิดการเรียนรู้ ดังนั้นผู้พัฒนาจะต้องเขียนโปรแกรมให้เครื่องเรียนรู้จากชุดข้อมูลและเครื่องจะทำหน้าที่เรียนรู้ตามวิธีที่ผู้พัฒนาได้กำหนด [20] โดยที่สามารถแบ่งออกเป็นกลุ่มได้ 3 กลุ่มดังรูปที่ 2.9



รูปที่ 2.9 แสดงการจัดกลุ่มของการเรียนรู้ของเครื่อง (Machine learning)

2.6.1.1 การเรียนรู้แบบมีผู้สอน (Supervised learning) การเรียนรู้ภายใต้การดูแล หรือผู้สอนเป็นเทคนิคการเรียนรู้ของเครื่องสำหรับการเรียนรู้ฟังก์ชันจากข้อมูลการฝึกอบรม (Training set) ข้อมูลการฝึกอบรมประกอบด้วยชุดของข้อมูลขาเข้า (Input) และผลลัพธ์ (Output) ออกมาแบบในที่ต้องการ โดยผลลัพธ์ของฟังก์ชันสามารถเป็นค่าต่อเนื่อง หรือค่าเลขจำนวนเต็ม เรียกว่า การถดถอย (Regression) หรือสามารถทำนายเป็นป้ายกำกับหรือคลาส (Label/Class) เรียกว่า การจัดประเภท (Classification)

2.6.1.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) การเรียนรู้แบบไม่มีผู้ดูแลคือการเรียนรู้ของเครื่องประเภทหนึ่งที่ไม่ได้ใช้ป้ายกำกับอินพุตด้วยตนเอง ซึ่งแตกต่างจากแนวทางการเรียนรู้แบบมีผู้สอนซึ่งเรียนรู้วิธีปฏิบัติงาน เช่น การจัดหมวดหมู่หรือการถดถอย โดยใช้ชุดตัวอย่างที่มนุษย์เตรียมไว้ให้ แต่การเรียนรู้แบบไม่มีผู้ฝึกสอนจะใช้วิธีการวิเคราะห์ข้อมูลของข้อมูลขาเข้า (Input) เพื่อทำการแบ่งกลุ่ม (Clustering) หรือจะเป็นการลดมิติของข้อมูล (Dimension Reduction) เพื่อหา Feature ของข้อมูล [21]

2.6.1.3 การเรียนรู้แบบเสริมกำลัง (Reinforcement learning) เป็นวิธีการเรียนรู้แบบหนึ่งโดยการเรียนรู้เกิดมาจากการปฏิสัมพันธ์ (interaction) ระหว่างผู้เรียนรู้ (agent) กับ สิ่งแวดล้อม (environment) โดยที่จะได้ผลจากการกระทำเป็นค่าตอบแทน (Reward) ในรูปแบบตัวเลข ผู้เรียนจะไม่ถูกบอกว่าจะต้องทำอะไรถึงจะได้ผลตอบแทนที่มากที่สุด จะต้องทำการเรียนรู้จากการกระทำของผู้เรียนเอง [22]

2.6.2 K-Nearest Neighbors (KNN)

หลักการทำงานของอัลกอริทึม K-Nearest Neighbors (KNN) คือการจัดกลุ่มหรือจำแนกประเภทข้อมูลใหม่โดยจะอ้างอิงจากข้อมูลที่ใกล้เคียงที่สุดกับข้อมูลทดสอบ เพื่อทำนายหรือจำแนกประเภทข้อมูลใหม่ โดยจะใช้กระบวนการคำนวณระยะทางยูคลิเดียน (Euclidean distance) เพื่อคำนวณระยะทางระหว่างข้อมูลทดสอบกับข้อมูลในชุดข้อมูลการฝึกฝน แสดงดังสมการที่ 2.1 และจะเลือกค่าที่ใกล้เคียงที่สุดตามที่ตั้งค่า K เอาไว้ แล้วจะทำการโหวตข้อมูลที่ใกล้เคียง หลังจากนั้นก็จะทำการทำนายผลลัพธ์ออกมา [23]

$$d_{\text{Euclidean}}(x) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.1)$$

2.6.3 Support Vector Regression (SVR)

Support Vector Regression (SVR) เป็นเทคนิคที่ใช้วิธีการของ Support Vector Machine (SVM) มาวิเคราะห์ความถดถอยระหว่างอินพุตเวกเตอร์ (Input vector) และตัวแปรเอาต์พุต (Output variables) ซึ่งนำมาใช้กับการพยากรณ์ได้ โดยจะเปลี่ยนจากการจำแนกคลาสด้วย SVM เป็นการทำนายค่าด้วย SVR ที่มีเป้าหมายคือการค้นหาความสัมพันธ์เชิงเส้นระหว่างอินพุตเวกเตอร์ในมิติ n ($X \in R^n$) และตัวแปรเอาต์พุต ($Y \in R$) ดังรูปที่ 2.10 และเพราะ SVR ดัดแปลงจาก SVM ดังนั้น สมการถดถอยของ SVR จึงมีคล้ายคลึงกับสมการไฮเปอร์เพลน (Hyperplane) ของ SVM แสดงดังสมการที่ 2.2

$$f(x) = w_0^T x + b = \sum_{j=1}^l (\alpha_j - \alpha_j^*) x_j^T x + b \quad (2.2)$$

โดยที่เวกเตอร์ถ่วงน้ำหนัก (w_0) เป็นดังสมการที่ 2.8

$$w_0 = \sum_{j=1}^l (\alpha_j - \alpha_j^*) x_j \quad (2.3)$$

สมการที่ 2.3 อยู่ในรูปแบบสมการถดถอยเชิงเส้น แต่ในกรณีที่เป็นการถดถอยแบบไม่เป็นเชิงเส้น สามารถส่งอินพุตเวกเตอร์ไปยังมิติที่สูงขึ้น โดยใช้เคอร์เนลฟังก์ชัน (Kernel function) ซึ่งเคอร์เนลฟังก์ชันที่นิยมใช้ใน SVR มีดังนี้ แสดงดังรูปที่ 2.11


$$(1) \text{ ลีเนียร์เคอร์เนล (Linear kernel) } k(x_i, x) = x_i^T x$$

$$(2) \text{ โพลีโนเมียลเคอร์เนล (Polynomial kernel) } k(x_i, x) = (1 + x_i \cdot x)^d$$


$$(3) \text{ เกาส์เซียนเคอร์เนล (Gaussian (RBF) kernel) } k(x_i, x) = \exp \left(- \frac{\|x_i - x\|^2}{2\sigma^2} \right)$$

ดังนั้น สมการที่ 2.2 สามารถเขียนใหม่ในรูปแบบ การถดถอยไม่เป็นเชิงเส้นโดยใช้เคอร์เนลฟังก์ชันได้ ดังสมการที่ 2.4 [24]

$$f(x) = \sum_{j=1}^l (\alpha_j - \alpha_j^*) k(x_i, x) + b \quad (2.4)$$




รูปที่ 2.10 แสดงรูปแบบของ Support Vector Regression แบบ Linear และ Non-linear
ที่มา : scikit-learn (2010).




รูปที่ 2.11 แสดงเคอร์เนลฟังก์ชันของ Support Vector Regression
ที่มา : scikit-learn (2010).

2.6.4 Artificial Neural Network (ANN)

โครงข่ายประสาทเทียม (Neural Network) หรือโครงข่ายประดิษฐ์ Artificial Neural Network (ANN) คือระบบการคำนวณที่เลียนแบบการทำงานของระบบสมองมนุษย์ ซึ่งในระบบประสาทของสมองมนุษย์ Dendrites ทำหน้าที่รับข้อมูลจากแหล่งต่าง ๆ แล้วส่งให้ Soma ประมวลผลข้อมูลเบื้องต้น หลังจากนั้น Axon จะแปลงข้อมูลต่าง ๆ เป็นผลลัพธ์แล้ว Synapses จะส่งผลลัพธ์ให้ Neurons อื่นเพื่อช่วยกันสร้างผลลัพธ์ขั้นสุดท้าย ดังรูปที่ 2.12 ซึ่งสามารถนำมาใช้ประโยชน์ในการทำนายจากข้อมูลที่มีอยู่ได้ เช่น การพยากรณ์หุ้นในตลาดหลักทรัพย์ การพยากรณ์อากาศ การพยากรณ์กระแสไฟฟ้า และยังสามารถนำมาใช้ในงาน Image Processing ได้อีกด้วย เช่น การจำแนกประเภทเกรดของผลไม้ การพยากรณ์ความสุกของผลไม้ เป็นต้น



รูปที่ 2.12 โครงสร้างระบบประสาท Neurons ของมนุษย์



รูปที่ 2.13 โครงสร้างของ Artificial Neural Network

หน่วยพื้นฐานของ ANN คือ Artificial Neurons (AN) ซึ่งจำลองการทำงานของฟังก์ชันทั้ง 4 ของ Neurons ของสมองมนุษย์แต่มีโครงสร้างการทำงานที่ง่ายกว่า โดยในการการทำงานจะแสดงดังรูปที่ 2.13 โดยกำหนดข้อมูลที่ป้อน คือ $X_1, X_2, \dots, X_n$ และข้อมูลแต่ละตัวจะคูณด้วยค่าน้ำหนัก (Weight) $W_1, W_2, \dots, W_n$ ตามลำดับ Artificial Neurons จะนำข้อมูลทั้งหมด n มารวมกันเรียกว่า Activation และจะทำการแปลงข้อมูล (Transfer) เป็นผลลัพธ์เพื่อส่งให้ Neurons ตัวอื่นนำไปประมวลผลเพื่อสร้างผลลัพธ์สุดท้าย

การประมวลผลเบื้องต้นของ Artificial Neurons จะทำการนำข้อมูลทั้งหมดมารวมกัน (Activation) ซึ่งแสดงในอยู่รูปของการหาผลรวม (Summation) ดังสมการที่ 2.5

$$I = \sum W_i \cdot X_i \quad (2.5)$$

หลังจากนั้น Artificial Neurons จะแปลงค่าผลรวม หรือ Activation (I) เป็นผลลัพธ์ (Y) โดยใช้ฟังก์ชันทางคณิตศาสตร์ เช่น Logistic, Linear, Gaussian เป็นต้น ดังสมการที่ 2.6

$$Y = f(I) \quad (2.6)$$

ฟังก์ชัน $f(I)$ คือ Transfer Function


ชั้นสุดท้าย Artificial Neurons ในส่วนผลลัพธ์ (Output Layer) จะนำ Y ที่ได้จาก Neurons ต่างๆ มาประมวลเป็นผลลัพธ์สุดท้าย (Z)

2.6.3.1 ลักษณะของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมจะประกอบด้วยเซลล์ประสาทเทียมหรือโหนดจำนวนมากที่เชื่อมต่อกันแบ่งออกเป็นกลุ่ม เรียกว่า ชั้น (layer) โดยที่ชั้นแรกจะเป็นชั้นที่นำข้อมูลเข้า เรียกว่า ชั้นรับข้อมูลเข้า (Input layer) ส่วนชั้นสุดท้าย เรียกว่า ชั้นส่งข้อมูลออก (Output layer) และชั้นที่อยู่ระหว่างชั้นข้อมูลที่ป้อนเข้าและชั้นส่งข้อมูลออก เรียกว่า ชั้นแอบแฝง (Hidden layer) โครงข่ายประสาทเทียมสามารถแบ่งออกเป็น 2 แบบได้แก่ โครงข่ายแบบชั้นเดียว (Single layer) และโครงข่ายแบบหลายชั้น (Multi-layer)

2.6.3.1.1 โครงข่ายแบบชั้นเดียว (Single layer)


โครงข่ายแบบชั้นเดียว เป็นโครงข่ายประสาทเทียมอย่างง่ายที่มีเพียงชั้นรับข้อมูลเข้าและชั้นส่งข้อมูลออกเท่านั้น โดยชั้นรับข้อมูลจะทำหน้าที่รับข้อมูลเข้า แล้วทำการส่งข้อมูลผ่านเส้นเชื่อมโยงไปยังชั้นส่งข้อมูลออก ซึ่งปริมาณข้อมูลในชั้นส่งข้อมูลออกจะขึ้นอยู่กับค่าน้ำหนักที่อยู่บนเส้นเชื่อมโยง และในชั้นส่งข้อมูลออกนี้จะนำข้อมูลที่ได้ออกมาคำนวณโดยใช้ฟังก์ชันทางคณิตศาสตร์ เรียกว่า ฟังก์ชันการแปลง (Transfer function) แล้วทำการส่งผลลัพธ์ออกมา เช่น โครงข่ายแบบชั้นเดียวแบบเพอเซปตรอนอย่างง่าย (Simple perceptron) จะแสดงดังรูปที่ 2.14



รูปที่ 2.14 โครงข่ายประสาทเทียมแบบชั้นเดียว (Single layer)

2.6.5.1.2 โครงข่ายแบบหลายชั้น (Multi-layer)

โครงข่ายแบบหลายชั้น เป็นโครงข่ายที่มีชั้นแอบแฝงตั้งแต่ 1 ชั้นขึ้นไป จะใช้ในกรณีที่ปัญหาที่มีความซับซ้อน ซึ่งโครงข่ายแบบชั้นเดียวไม่สามารถแก้ปัญหาได้จึงทำการเพิ่มจำนวนโหนด หรือชั้นแอบแฝงให้กับโครงข่าย ตัวอย่างของโครงข่ายแบบหลายชั้นได้แก่ การแพร่ย้อนกลับ (back propagation) และเคาน์เตอร์พรอพเกชัน (counter propagation) เป็นต้น จะแสดงดังรูปที่ 2.15 [26]



รูปที่ 2.15 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer)

2.6.3.2 ฟังก์ชันกระตุ้นหรือฟังก์ชันการส่งต่อ (Transfer function)

เป็นฟังก์ชันการคำนวณเพื่อทำนายค่าของข้อมูลส่งออก ซึ่งรูปแบบที่นิยมมากที่สุดคือฟังก์ชันไม่เป็นสมการเชิงเส้น (Non-linear function) เนื่องจากลักษณะแบบสมการเชิงเส้นในความเป็นจริงพบเจอได้น้อย ฟังก์ชันกระตุ้นจึงทำหน้าที่ในการตัดสินใจให้ Neurons โดยดูค่าผลรวมของข้อมูลเข้าและค่าน้ำหนัก ฟังก์ชันกระตุ้นจะถูกนำไปใช้ทั้งโหนดซ่อน (Hidden node) และโหนดข้อมูลออก (Output node) ซึ่งทั้งสองโหนดอาจจะใช้ฟังก์ชันกระตุ้นที่เหมือนกันก็ได้ ฟังก์ชันกระตุ้นจะมีหลากหลายรูปแบบ ดังต่อไปนี้

2.6.3.2.1 ฟังก์ชันกระตุ้นค่าแบ่ง (Threshold Activation Function) หรือฟังก์ชันไบนารีสเตป ซึ่งฟังก์ชันนี้จะพิจารณาค่าของข้อมูลเข้าว่ามากกว่าหรือน้อยกว่าค่าแบ่งที่กำหนดไว้ (threshold) เพื่อส่งค่าต่อไปยังขั้นถัดไป

2.6.3.2.2 ฟังก์ชันกระตุ้นซิกมอยด์ (Sigmoid Activation Function) เป็นฟังก์ชันทางคณิตศาสตร์ที่มีลักษณะเป็นตัวเอส เรียกว่า Sigmoid curve จะมีค่าระหว่าง 0 และ 1 ฟังก์ชันนี้จะใช้เมื่อต้องการทำนายความน่าจะเป็น (Probability)

2.6.3.2.3 ฟังก์ชันไฮเพอร์โบลิคแทนกेंट (Hyperbolic Tangent Function: tanh) จะมีค่าระหว่าง [-1, 1] สามารถแปลงค่าข้อมูลเข้าที่มีค่าเป็นลบให้เป็นข้อมูลออกที่ติดลบได้ และข้อมูลที่มีค่าเป็นศูนย์จะถูกแปลงเป็นข้อมูลออกที่มีค่าใกล้ศูนย์ (near-zero output)

2.6.3.2.4 ฟังก์ชันเรกติไฟด์ไลน์ยูนิต (Rectified Linear Units, ReLu) ฟังก์ชันนี้จะมีค่าอยู่ระหว่าง $[0, \infty)$ หมายถึงถ้าข้อมูลเข้ามีค่ามากกว่าศูนย์ข้อมูลออกจะเป็นค่าบวก และถ้าข้อมูลเข้ามีค่าศูนย์หรือติดลบ ข้อมูลออกจะมีค่าเป็นศูนย์ เป็นฟังก์ชันที่นิยมใช้ในโครงข่ายประสาทเทียมอัจฉริยะ (ANN) และโครงข่ายประสาทเทียมแบบบิด (CNN)

2.6.6 การเรียนรู้เชิงลึก (Deep learning)


การเรียนรู้เชิงลึกเป็นส่วนหนึ่งของการเรียนรู้ของเครื่องจักร (Machine Learning) ซึ่งเป็นอัลกอริทึมที่ใช้สำหรับการเรียนรู้ที่สามารถทำให้เครื่องจักรสามารถตัดสินใจได้เช่นเดียวกับมนุษย์ โดยการเรียนรู้ของเครื่องเป็นการประยุกต์ใช้ความรู้ทางด้านสถิติในการวิเคราะห์ข้อมูลและสร้างแบบจำลองสำหรับทำนายผลลัพธ์จากข้อมูล ดังภาพที่ 2.16 การเรียนรู้เชิงลึกเป็นอัลกอริทึมที่พัฒนามาจากโครงข่ายประสาทเทียม โดยทำการต่อยอดในการวางโครงสร้างในรูปแบบต่างๆวางซ้อนกันหลายๆแบบ จึงเกิดการประยุกต์ใช้ความสามารถของแต่ละโครงสร้างที่นำมาใช้ร่วมกันเพื่อเพิ่มประสิทธิภาพในการวิเคราะห์ที่ดียิ่งขึ้น ปัจจุบันการเรียนรู้เชิงลึกสามารถวิเคราะห์และทำนายผลได้ดีกว่าการใช้อัลกอริทึมของการเรียนรู้ของเครื่องเป็นอย่างมาก แสดงดังตารางที่ 2.3 [27]

ตารางที่ 2.3 ความแตกต่างระหว่าง Machine Learning และ Deep learning

Machine learning	Deep learning
เป็น Subset ของ AI	เป็น Subset ของ Machine learning
ใช้ข้อมูลที่น้อย	ต้องการข้อมูลจำนวนมาก
ต้องใช้มนุษย์ในการเรียนรู้และการแก้ไขปัญหา	สามารถเรียนรู้ได้เองจากค่าความผิดพลาด
ใช้เวลาในการ training น้อย	ใช้เวลาในการ training มาก
และความแม่นยำต่ำกว่า	และความแม่นยำมากกว่า
ตัวอย่างโมเดล KNN, SVR และ LR เป็นต้น	ตัวอย่างโมเดล ANN, CNN และ DNN เป็นต้น

2.6.6 Multi-layer perceptron (MLP)

Multi-layer perceptron (MLP) หรือ โครงข่ายประสาทเทียมแบบหลายชั้น จัดเป็น Deep Learning ซึ่งเป็นรูปแบบหนึ่งที่พัฒนาจากโครงข่ายประสาทเทียม (ANN) ซึ่งประกอบเป็นชั้นที่นำข้อมูลเข้า เรียกว่า ชั้นรับข้อมูลป้อนเข้า (Input layer) ส่วนชั้นสุดท้าย เรียกว่า ชั้นส่งข้อมูลออก (Output layer) และชั้นที่อยู่ระหว่างชั้นข้อมูลที่ป้อนเข้าและชั้นส่งข้อมูลออก เรียกว่า ชั้นแอบแฝง (Hidden layer) ซึ่งจะมีจำนวนมากกว่า 1 ชั้นขึ้นไป โดยกระบวนการฝึกฝนจะประกอบด้วย 2 ส่วนคือการส่งผ่านข้อมูลไปข้างหน้า (Feed-forward) การส่งค่าย้อนกลับ (Backpropagation) สำหรับการส่งผ่านข้อมูลไปข้างหน้า ข้อมูลจะผ่านเข้าโครงข่ายประสาทเทียมที่ชั้นข้อมูลเข้าและจะส่งข้อมูลผ่านชั้นหนึ่งไปสู่อีกชั้นหนึ่ง จนถึงชั้นข้อมูลออก สำหรับการส่งค่าย้อนกลับค่าน้ำหนักการเชื่อมต่อจะถูกปรับเปลี่ยนให้สอดคล้องกับกฎการแก้ข้อผิดพลาด (Error-Correction) คือผลต่างของผลตอบที่แท้จริง (Actual Response) กับผลตอบเป้าหมาย (Target Response) ทำให้เกิดเป็นสัญญาณผิดพลาด (Error Signal) ซึ่งสัญญาณผิดพลาดนี้จะถูกส่งย้อนกลับเข้าสู่โครงข่ายประสาทเทียม และค่าน้ำหนักของการเชื่อมต่อจะถูกปรับจนกระทั่งผลตอบที่แท้จริงเข้าใกล้ผลตอบเป้าหมายดังรูปที่ 2.16 [28]



รูปที่ 2.16 แสดงกระบวนการของโครงข่ายประสาทเทียมแบบหลายชั้น

2.9 การทดสอบประสิทธิภาพ

การวิเคราะห์การถดถอย โดยส่วนใหญ่จะเป็นการเรียนรู้แบบมีผู้สอน Supervised machine learning และประกอบด้วยการทำนายเป้าหมายอิสระอย่างต่อเนื่องจากชุดของตัวแปรทำนายอื่นๆ ความแตกต่างระหว่างการจำแนกประเภทแบบไบนารีและการถดถอยจะอยู่ในช่วงเป้าหมาย โดยที่ในการจำแนกประเภทแบบไบนารี เป้าหมายสามารถมีได้เพียงสองค่า (โดยปกติจะเป็น 0 และ 1) ในขณะที่การถดถอย เป้าหมายสามารถมีได้หลายค่า และการทดสอบและวิเคราะห์การถดถอยที่ในปัจจุบันนิยมได้แก่

2.7.1 ค่าสัมประสิทธิ์การตัดสินใจ (R^2) เป็นตัววัดทางสถิติที่แสดงถึงสัดส่วนของความแปรปรวนของตัวแปรตามซึ่งอธิบายโดยตัวแปรอิสระหรือตัวแปรในแบบจำลอง จึงสามารถอธิบายความสัมพันธ์ระหว่างตัวแปรอิสระและตัวแปรตามได้ แสดงดังสมการที่ 2.7

$$R^2 = 1 - \frac{\sum_{i=1}^m (x_i - y_i)^2}{\sum_{i=1}^m (\bar{y} - y_i)^2} \quad (2.7)$$

(worst value = $-\infty$; best value = +1)

2.7.2 ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error: MSE) จะวัดค่าเฉลี่ยของกำลังสองของข้อผิดพลาด นั่นคือ ความแตกต่างของค่าเฉลี่ยกำลังสองระหว่างค่าที่ประเมินกับค่าจริง ค่า MSE เป็นฟังก์ชันความเสี่ยง ซึ่งสอดคล้องกับค่าคาดหวังของการสูญเสียข้อผิดพลาดกำลังสอง MSE จะเป็นค่าบวกและไม่ใช่ศูนย์ เป็นเพราะการสุ่มหรือเนื่องจากตัวประมาณค่าไม่ได้คำนึงถึงข้อมูลที่สามารถสร้างค่าประมาณที่แม่นยำยิ่งขึ้น MSE จะประเมินคุณภาพของตัวทำนาย จะแสดงดังสมการที่ 2.8

$$MSE = \frac{1}{M} \sum_{i=1}^m (X_i - Y_i)^2 \quad (2.8)$$

(best value = 0; worst value = $+\infty$)

2.7.3 ตัวแปรรูต (Root Mean Square Error: RMSE) คือใส่ Square root เพื่อให้ได้ค่า loss ที่มีหน่วยเดียวกับตัวแปร y เพราะจาก MSE ที่นำค่าความผิดพลาดมายกกำลังสอง RMSE จึงทำการใส่ Square root เพื่อให้ง่ายต่อการอ่านค่าความผิดพลาด ดังสมการที่ 2.9

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^m (X_i - Y_i)^2} \quad (2.9)$$

(best value = 0; worst value = $+\infty$)

2.7.4 ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) เป็นการนำข้อมูลข้อผิดพลาด มาใส่ Absolute เพื่อหาค่าเฉลี่ยของความแตกต่างสัมบูรณ์ระหว่างค่าจริงและค่าที่คาดการณ์ในชุด ตัวอย่างเช่น Y กับ X เวลาเริ่มต้นกับเวลาถัดมา เทคนิคการวัดแบบหนึ่งกับเทคนิคการวัดแบบอื่น เป็นต้นมีหน่วยเดียวกับข้อมูลต้นฉบับ และสามารถเปรียบเทียบระหว่างรุ่นที่มีการวัดข้อผิดพลาดในหน่วยเดียวกันเท่านั้น ดังสมการที่ 2.10

$$MAE = \frac{1}{M} \sum_{i=1}^m |X_i - Y_i| \quad (2.10)$$

(best value = 0; worst value = $+\infty$)

2.7.5 ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) มีลักษณะคล้ายกับ MAE แต่เปลี่ยนค่าเป็นเปอร์เซ็นต์ ดังสมการที่ 2.11 [29]

$$MAPE = \frac{1}{M} \sum_{i=1}^m \left| \frac{Y_i - X_i}{Y_i} \right| \quad (2.11)$$

(best value = 0; worst value = $+\infty$)

2.10 งานวิจัยที่เกี่ยวข้อง

दनัย และคณะ (2562) [30] ได้ทำการศึกษาดัชนีที่ใช้ในเก็บเกี่ยวและคุณภาพหลังการเก็บเกี่ยวของผลอะโวคาโดด้วยเทคนิคเนียร์อินฟราเรดสเปกโทรสโกปี (NIRS) ซึ่งได้ทำการเก็บเกี่ยวอะโวคาโดพันธุ์บัคคาเนียร์และพันธุ์แฮสที่ระยะเกี่ยวที่กำหนดหลังติดผล นำมาทดลองวัดคุณสมบัติทางกายภาพและเคมีอย่างมีนัยสำคัญทางสถิติ ($P \leq 0.05$) ซึ่งจะทำการเปรียบเทียบระหว่างผลที่ได้หลังการเก็บเกี่ยวกับผลที่ผ่านการบ่มรักษาเพื่อให้อะโวคาโดสุกที่อุณหภูมิห้อง 30 องศาเซลเซียส เป็นระยะเวลา 12 วัน ผลการทดลองปรากฏว่าการเปลี่ยนแปลงของวัตถุแห้งหรือปริมาณของแข็งที่ละลายน้ำได้กับลิพิดเป็นดัชนีที่ชัดเจนกว่าดัชนีอื่นๆ และได้ทำสร้างสมการเทียบมาตรฐานที่ได้จากการทดลองกับการวัดค่าของเทคนิคเนียร์อินฟราเรดสเปกโทรสโกปี (NIRS) เพื่อใช้ในการทำนายค่าดัชนีดังกล่าว อย่างไรก็ตามในกระบวนการสุกของผลอะโวคาโดพันธุ์แฮสนั้นสามารถพิจารณาได้จากสีเปลือก ซึ่งมีการเปลี่ยนแปลงอย่างชัดเจนจากสีเขียวเป็นสีม่วงดำและการอ่อนนุ่มลงของเนื้อผล โดยที่ผลดิบกับผลที่สุกมีค่าสีของเปลือกและค่าความแน่นเนื้อแตกต่างกันอย่างมีนัยสำคัญทางสถิติ ($P \leq 0.05$)

Cho, Koyama, Olivares Díaz & Koseki (2020) [31] ได้ทำการศึกษาทำนายความสุขของอะโวคาโด ด้วยค่าความแน่นของเนื้อที่วัดได้ในระหว่างกระบวนการเก็บรักษา โดยใช้ machine learning ในการทำนาย ซึ่งในงานวิจัยนี้ได้ทำการวิเคราะห์ค่าสีของอะโวคาโดด้วยเครื่องวัดสี Colorimeter เป็นค่าสีระบบ CIE-L*a*b* และวัดค่าความแน่นของเนื้อ (Firmness) ด้วยเครื่อง Table-Top Universal Testing Instruments ทำการจดบันทึกเป็นรายวัน และใช้สมาร์ทโฟนในการถ่ายภาพ โดยใช้อะโวคาโด 1 ผลต่อ 1 ภาพ และแบ่งเป็นข้อมูลที่ใช้ฝึก 140 ภาพ และ 38 ภาพในการทดสอบข้อมูล เป็นอัตราส่วน 80/20 และการประมวลผลภาพจะเริ่มจากการปรับขนาดของรูปภาพให้เล็กลงเป็น 384 × 512 พิกเซล แล้วทำการแยกผลอะโวคาโดรูปภาพออกจากภาพพื้นหลังโดยการด้วยวิธีการ threshold ซึ่งอะโวคาโดที่ได้จากรูปภาพนั้นเป็นค่าสี RGB จะทำการแปลงเป็นค่าสี L*a*b* เพื่อนำมาใช้ในการวิเคราะห์ค่าของสีที่เปลี่ยนไปของอะโวคาโด และส่งไป Machine Learning เพื่อใช้

ในการทำนายความสุกของอะโวคาโด โดยโมเดลที่ได้ใช้ในงานวิจัยนี้คือ Support Vector Regression (SVR) โดยใช้ Gaussian radial basis function (RBF) เป็น kernel ที่ตั้งค่า C เป็น 100 และตั้งค่า gamma เป็น 0.01, K-Nearest Neighbors (KNN) โดยที่ที่ตั้งค่าให้ k เท่ากับ 5, Ridge Regression ไฮเปอร์พารามิเตอร์ α ในงานวิจัยนี้ใช้ค่ามาตรฐานเป็น 0.01, Lasso Regression ไฮเปอร์พารามิเตอร์ α สำหรับการทำให้เป็นมาตรฐานใช้โมเดลนี้คือ 0.01 และได้ทำการทดสอบประสิทธิภาพโดยการเปรียบเทียบค่าความแน่นของเนื้อที่เครื่องทำนายได้กับค่าความแน่นของเนื้อที่ได้จากวัดจริง ปรากฏว่าค่า R^2 , RMSE และ RPD ของ SVR นั้นดีที่สุดโดยมีค่า 0.92, 7.54, 3.8 ตามลำดับ

Cho, Koyama & Koseki (2021) [32] ทำการศึกษาทำนายความสุกของอะโวคาโด ซึ่งในงานวิจัยนี้จะใช้โมเดล Artificial neural network (ANN) และโมเดล Support Vector Regression (SVR) โดยใช้อะโวคาโด 1 ผลต่อ 1 ภาพ และแบ่งเป็นภาพที่ใช้ฝึก 215 ภาพ และ 24 ภาพในการทดสอบข้อมูล เป็นอัตราส่วน 90/10 และในการประมวลผลภาพจะเริ่มจากการแปลงขนาดของรูปภาพให้เล็กลงเป็น 523 x 392 พิกเซล แล้วทำการแยกผลอะโวคาโดรูปภาพจากภาพพื้นหลังด้วย K-means clustering และแปลงจาก RGB เป็นพื้นที่สี $L^*a^*b^*$ และ YUV เพื่อใช้ในการวิเคราะห์ค่าสีของแต่ละระบบ และถูกถ่ายโอนไปยังโมเดล Artificial Neural Network (ANN) และโมเดล Support Vector Regression (SVR) โดยที่ในงานวิจัยนี้จะใช้โมเดล ANN ที่มี 7 hidden layer และฟังก์ชัน ReLu ในการทำนาย และโดยที่โมเดล SVR จะใช้ Gaussian radial basis function (RBF) เป็น kernel ที่ตั้งค่า C เป็น 100 และตั้งค่า gamma เป็น 0.01 จากผลการทดสอบประสิทธิภาพปรากฏว่าค่า R^2 , RMSE และ RPD ของ ANN นั้นให้ค่าดีที่สุดมีค่าเท่ากับ 0.9371, 0.3825, 4.03 ตามลำดับ ซึ่งดีกว่า SVR ที่ได้ค่าเท่ากับ 0.9092, 0.4725, 3.26 ตามลำดับ และความสัมพันธ์ระหว่างค่าความแน่นของเนื้อกับค่าสี $L^*a^*b^*$, YUV ที่ระดับความเชื่อมั่นที่ 99 % ปรากฏว่าค่า a^* เป็นค่าที่ทำการประมาณค่าความแน่นของเนื้อที่ดีที่สุดจากระดับความน่าเชื่อมั่นที่ 99% และระบบสีที่ดีที่สุดระหว่าง $L^*a^*b^*$ และ YUV กับค่าความแน่นของเนื้อ ที่ระดับความน่าเชื่อมั่น 99% ปรากฏว่าระบบสี $L^*a^*b^*$ ดีที่สุดในการทำนายความแน่นของเนื้อ และพบว่าค่า a^* เป็นค่าสีที่ทำการประมาณค่าความแน่นของเนื้อที่ดีที่สุด

จากงานวิจัยที่ได้กล่าวมาทำให้ผู้วิจัยได้นำมาเป็นแนวทางในดำเนินงานวิจัย โดยใช้ค่าความแน่นเนื้อของผลอะโวคาโดและค่าสีของเปลือกผลอะโวคาโดในระบบสี $L^*a^*b^*$ ในการวัดระดับความสุกของผลอะโวคาโด โดยจะใช้อะโวคาโดพันธุ์แฮสซึ่งเป็นที่นิยมในการบริโภค จำนวน 40 ผล ที่ทำการบ่มรักษาเพื่อให้อะโวคาโดสุก เป็นเวลา 7-9 วัน ที่อุณหภูมิห้อง และในการวัดระดับความสุกของผลอะโวคาโดนี้จะใช้เทคนิคการประมวลผลภาพร่วมกับโมเดลแบบจำลอง KNN, SVR และ MLP ซึ่งเป็นโมเดลที่ได้รับความนิยมและมีประสิทธิภาพในการประมวลผลข้อมูลที่แม่นยำ จึงนำมาประยุกต์ใช้ในงานวิจัยนี้

บทที่ 3

วิธีดำเนินงานวิจัย

ในบทนี้ทางผู้วิจัยจะทำการศึกษาและวางแผนในการทำนายระดับความสุกของผลอะโวคาโดด้วยวิธีการประมวลผลภาพวิธีการประมวลผลภาพร่วมกับโมเดลแบบจำลองทางคณิตศาสตร์ โดยการใช้ค่าสีของเปลือกผลอะโวคาโดที่ได้จากวิธีการประมวลผลภาพและค่าความแน่นเนื้อของผลอะโวคาโด (Firmness) ที่เปลี่ยนไปในระหว่างการบ่มรักษา ซึ่งในงานวิจัยนี้จะใช้โมเดล K-Nearest Neighbors (KNN), Support Vector Regression (SVR) และ Multi-layer Perceptron (MLP) ในการทำนายค่าความแน่นเนื้อของผลอะโวคาโดระหว่างค่าที่ได้จากโมเดลกับค่าที่วัดได้จากการทดลอง ดังรูปที่ 3.1



รูปที่ 3.1 ขั้นตอนการดำเนินงานวิจัย

ตารางที่ 3.1 แผนการดำเนินงานวิจัย

วิธีการดำเนินงาน	ปีการศึกษา 2565		ปีการศึกษา 2566						
	ต.ค.	ธ.ค.	ม.ค.	เม.ย.	พ.ค.	ส.ค.	ก.ย.	พ.ย.	ธ.ค.
1.วางแผนดำเนินงาน	←→	←→							
2.ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง	←→	←→							
3.ศึกษาและรวบรวมข้อมูลของผลอะโวกาโด	←→	←→							
4.กำหนดกลุ่มตัวอย่างและกำหนดปัจจัยที่			←→	←→					
5.สร้างระบบประมวลผลภาพ					←→	←→			
6.สร้างโมเดลแบบจำลองทางคณิตศาสตร์					←→	←→	←→		
7.ทดสอบประสิทธิภาพและเปรียบเทียบแบบจำลอง						←→	←→	←→	
8.สรุปผลการทดลอง						←→	←→	←→	
9.จัดทำเล่มวิทยานิพนธ์							←→	←→	←→

←→ แสดงการดำเนินงานจริง

←- - - - -> แสดงการแผนดำเนินงาน

3.1 ศึกษาและรวบรวมข้อมูลของอะโวคาโด

ในการศึกษาอะโวคาโดทางผู้วิจัยได้ทำการเดินทางไปยังพื้นที่ที่มีการเพาะปลูกอะโวคาโดที่จังหวัดตาก อำเภอพบพระ เมื่อวันที่ 14 ตุลาคม พ.ศ. 2565 เพื่อไปสัมภาษณ์ข้อมูลเกี่ยวกับอะโวคาโดจากผู้เชี่ยวชาญเรื่องของอะโวคาโด ผอ.ธนากร โพธิ์กำชัย ผู้อำนวยการศูนย์ส่งเสริมและพัฒนาอาชีพการเกษตรที่สูงจังหวัดตาก ดังรูปที่ 3.1 และเกษตรกรในพื้นที่ ดังรูปที่ 3.2 จึงทำให้ทราบว่าเกษตรกรยังมีปัญหาในการเก็บเกี่ยวอะโวคาโด เพราะเกษตรกรส่วนใหญ่ยังคงใช้ลักษณะภายนอกในการคัดแยกอะโวคาโดที่สุกกับไม่สุกซึ่งต้องใช้ประสบการณ์ในการสังเกตจากการเปลี่ยนแปลงลักษณะภายนอกของอะโวคาโดหรือใช้วิธีการนับวันในการกำหนดความสุกของอะโวคาโด ซึ่งไม่ได้เกี่ยวข้องกับความสุขของอะโวคาโดโดยตรง และในเกษตรกรบางรายจะใช้วิธีการนำตัวอย่างอะโวคาโดนำออกมาทดลองบ่มรักษา ซึ่งจะใช้เวลา 4-7 วัน ซึ่งถ้าตัวอย่างอะโวคาโดที่เก็บเกี่ยวไม่สุกดีอะโวคาโดผลนั้นจะไม่สุกสมบูรณ์ ผลจะเหี่ยวลง เนื้อภายในจะเหนียว และถ้าผลอะโวคาโดมีความสุขที่พอดี เนื้อภายในจะเนียนละเอียด ซึ่งวิธีที่กล่าวมาข้างต้นนั้นอาจส่งผลให้การเก็บเกี่ยวอะโวคาโดมีคุณภาพที่ไม่สม่ำเสมอ ส่งผลให้การขนส่งอะโวคาโดมายังพ่อค้าคนกลางกับผู้บริโภคนั้นไม่ได้คุณภาพที่สม่ำเสมอเช่นกัน



รูปที่ 3.2 ผอ.ธนากร โพธิ์กำชัย ให้ความรู้เกี่ยวกับอะโวคาโดที่อำเภอพบพระ จังหวัดตาก
ที่มา : ผู้วิจัย



รูปที่ 3.3 สัมภาษณ์เกษตรกรที่อำเภอพบพระ จังหวัดตาก
ที่มา : ผู้วิจัย

3.2 กำหนดกลุ่มตัวอย่างและกำหนดตัวแปรที่ใช้ในงานวิจัย

อะโวคาโดที่ใช้ในงานวิจัยนี้จะใช้อะโวคาโดพันธุ์แฮส โดยทางผู้วิจัยได้ซื้ออะโวคาโดจากตลาดไท ซึ่งทางร้านค้าได้เก็บรักษาผลอะโวคาโดในตู้แช่เย็นที่อุณหภูมิ 0-4 องศาเซลเซียส ดังรูปที่ 3.4 หลังจากทำการซื้อผลอะโวคาโด ผู้วิจัยจะทำการบ่มรักษาผลอะโวคาโดในห้องมืดที่ปิดสนิท เพื่อให้ผลของอะโวคาโดสุกจนกระทั่งผลเกิดการเน่าเสีย ซึ่งจะทำการบ่มรักษาผลอะโวคาโดที่อุณหภูมิห้องเป็นเวลา 7-9 วัน โดยกำหนดอะโวคาโดวันที่ทำการซื้อเป็นวันที่ 0 และกำหนดกลุ่มตัวอย่างที่ 40 ผล แบ่งเป็นทดลอง 32 ผล และทดสอบ 8 ผล ที่ระดับความเชื่อมั่นที่ 95% ซึ่งสอดคล้องกับงานวิจัยของ ดนัย และคณะ (2562) และจากงานวิจัยของ Sanaeifar, Bakhshipour & de la Guardia (2016) กับงานวิจัยของ Mozaffari, Sadeghi & Asefi ที่ได้ทำการศึกษาทดลองการใช้เทคนิคการประมวลผลภาพร่วมกับโมเดล ซึ่งใช้ตัวอย่าง 15-50 ผล ก็เพียงพอสำหรับการศึกษาทดลอง

ในการวัดค่าสีของเปลือกอะโวคาโด จะทำการวัดด้วยเครื่องวัดสี (color meter, WR-10, Minolta, Japan) ดังรูปที่ 3.5 โดยจะทำการวัดค่าสีในระบบ CIELab และการวัดค่าความแน่นเนื้อของผลอะโวคาโด จะทำการวัดด้วยเครื่องวิเคราะห์เนื้อสัมผัส (texture analyzer, TA.Xtplus, Stable Micro System, UK) ด้วยหัววัดชนิด P2 (2 mm diameter cylinder stainless steel) โดยการวัดแรงเป็นนิวตัน (N)



รูปที่ 3.4 ร้านค้าผลไม้นานาชาติในตลาดไทที่ติดตั้งห้องแช่เย็น
ที่มา : ผู้วิจัย

color meter, WR-10

texture analyzer, TA.Xtplus




อะโวคาโดพันธุ์แฮส

รูปที่ 3.5 การทดสอบผลอะโวคาโด

3.3 กระบวนการประมวลผลภาพของอะโวคาโด (Image Processing)

3.2.1 การได้มาของภาพ (Image Acquisition)

ในงานวิจัยนี้ได้ใช้กล้องจากสมาร์ทโฟน (iPhone 13 Pro max) ในการถ่ายภาพของผลอะโวคาโด และจะตั้งค่าทั้งหมดดังตารางที่ 3.1 ซึ่งจะถ่ายใน Studio Tent Box ที่ติดตั้ง LED โดยค่าความสว่างจะอยู่ที่ 26 ลูกเมน และอุณหภูมิของแสงสีขาวจะอยู่ที่ 5600K โดยในงานวิจัยนี้จะทำการถ่ายภาพอะโวคาโดที่ระยะห่าง 25 เซนติเมตรในแนวตั้งซึ่งสอดคล้องกับงานวิจัยของ Cho, Koyama & Koseki (2021) และภาพที่ถ่ายได้จะถูกส่งไปยังคอมพิวเตอร์เพื่อใช้ในการประมวลผลภาพและทำนายความสุกของผลอะโวคาโด ดังรูปที่ 3.6




รูปที่ 3.6 กระบวนการได้มาของภาพ (Image Acquisition) ของผลอะโวคาโด

ตารางที่ 3.2 แสดงข้อมูลของเฉพาะและการตั้งค่าของกล้องสมาร์ทโฟน

ตัวแปร	ข้อมูลเฉพาะและการตั้งค่า
ขนาดรูปภาพ	3264 × 2448 พิกเซล
ซูม (Zoom)	ไม่ใช่ซูม
แฟลช (Flash)	ไม่เปิดแฟลช
ความไวแสง (Sensitivity) หรือ ISO	Auto
ความเร็วชัตเตอร์ (Exposure time)	Auto
ค่าสมดุลแสงสีขาว (White balance)	Auto
รูรับแสง (Aperture)	f/2.2
ประเภทไฟล์	JPEG

3.2.2 การประมวลผลภาพ (Image Processing)

การประมวลผลภาพใช้จากแหล่ง open source โดยใช้โปรแกรม OpenCV [12] และใช้ Scikit-learn [13] ในการเขียนโปรแกรมแบบจำลองโมเดล โดยจะทำการ Run โปรแกรมใน Google Colab ซึ่งจะมีขั้นตอนดังรูปที่ 3.7 โดยในการประมวลผลภาพจะเริ่มเมื่อทำการป้อนข้อมูลรูปภาพอะไครโดเข้าคอมพิวเตอร์ และทำการเรียกข้อมูลรูปภาพมาทำการแปลงขนาดรูปภาพให้เล็กลงขนาด 315 × 420 พิกเซล (โดยจะทำการคงค่าอัตราส่วนของรูปภาพไว้) หลังจากนั้นจะทำการปรับค่าแสงของรูป และทำลบสัญญาณรบกวน (Noise) กับเบลรูปภาพแล้วจึงทำการแยกผลอะไครโดรูปภาพออกจากภาพพื้นหลังโดยการด้วยวิธีการ threshold (แปลงค่าสีจากภาพ RGB เป็น Grayscale โดยที่หลังจากแปลงค่าแล้วจะได้ค่า 1 ที่เป็นผลอะไครโด และค่า 0 ที่เป็นภาพพื้นหลัง) หลังจากแยกผลอะไครโดออกจากภาพพื้นหลังแล้วจะทำการแปลงค่าสีของอะไครโดจาก RGB โดยจะทำการแปลงเป็นค่าสี $L^*a^*b^*$ แล้วส่งรูปไปยังโมเดลแบบจำลองทางคณิตศาสตร์ในการทำนายระดับความแน่นของเนื้ออะไครโด เพื่อทำนายระดับความสุกของผลอะไครโด



รูปที่ 3.7 ขั้นตอนการประมวลผลภาพ

3.4 สร้างโมเดลแบบจำลองทางคณิตศาสตร์ขั้นสูงในการพยากรณ์

ในงานวิจัยนี้จะทำการแบ่งข้อมูลรูปภาพออกเป็นข้อมูลที่ใช้ฝึก (Training data) กับรูปภาพที่ใช้ในการทดสอบ (Testing data) เป็นอัตราส่วน 90/10, 80/20 และ 70/30 โดยที่ในงานวิจัยนี้จะใช้โมเดล K-Nearest Neighbors (KNN), Support Vector Regression (SVR) และ Multi-layer Perceptron (MLP) ในการทำนายค่าความแน่นของเนื้อเพื่อใช้ในการทำนายความสุกของผลอะโวคาโด

3.4.1 K-Nearest Neighbors (KNN)

การสร้างโมเดล K-Nearest Neighbors (KNN) จะมีขั้นตอนดังรูปที่ 3.8 โดยจะเริ่มต้นการสร้าง Data Frame ที่ได้จากกระบวนการประมวลผลภาพและค่าความแน่นเนื้อที่ได้จากการทดสอบผลอะโวคาโด และจะทำการแบ่งข้อมูลที่ใช้ฝึก (Training data) กับรูปภาพที่ใช้ในการทดสอบ (Testing data) เป็นอัตราส่วน 90/10, 80/20 และ 70/30 หรือ KNN (90/10), KNN (80/20) และ KNN (70/30) และได้นำ Grid Search มาใช้ซึ่งเป็นไลบรารีที่ใช้ในการปรับค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับโมเดล ซึ่งอยู่ในช่วง $K = 3, 5, 7, 9$ หลังจากนั้นจะนำค่าพารามิเตอร์ที่ได้จาก Grid Search มาใช้ในการวิเคราะห์และเปรียบเทียบ



รูปที่ 3.8 ขั้นตอนกระบวนการสร้างโมเดล KNN

3.4.2 Support Vector Regression (SVR)


การสร้างโมเดล Support Vector Regression (SVR) จะมีขั้นตอนดังรูปที่ 3.9 ซึ่งจะทำเหมือนกับโมเดล KNN โดยจะเริ่มต้นจากการสร้าง Data Frame และทำการแบ่งข้อมูลที่ใช้ฝึก (Training data) กับรูปภาพที่ใช้ในการทดสอบ (Testing data) เป็นอัตราส่วน 90/10, 80/20 และ 70/30 หรือ SVR (90/10), SVR (80/20) และ SVR (70/30) และใช้ Grid Search ในการปรับค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับโมเดล ซึ่งในการตั้งค่าพารามิเตอร์ของ SVR จะทำการตั้งค่าพารามิเตอร์ C และ gamma ในช่วง 0.1, 1, 10 และตั้งค่า Kernel ให้เลือก linear, poly, rbf, sigmoid หลังจากนั้นจะนำค่าพารามิเตอร์ที่ได้จาก Grid Search มาใช้ในการวิเคราะห์และเปรียบเทียบ



รูปที่ 3.9 ขั้นตอนกระบวนการสร้างโมเดล SVR

3.4.3 Multi-layer Perceptron (MLP)

การสร้างโมเดล Multi-layer Perceptron (MLP) จะมีขั้นตอนดังรูปที่ 3.10 ซึ่งจะเหมือนกันกับโมเดล KNN และโมเดล SVR โดยจะเริ่มต้นการสร้าง Data Frame และจะทำการแบ่งข้อมูลที่ใช้ฝึก (Training data) กับรูปภาพที่ใช้ในการทดสอบ (Testing data) เป็นอัตราส่วน 90/10, 80/20 และ 70/30 หรือ MLP (90/10), MLP (80/20) และ MLP (70/30) และจะใช้ Grid Search ในการปรับค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับโมเดล ซึ่งในการตั้งค่าพารามิเตอร์ของ MLP จะทำการตั้งค่าพารามิเตอร์ hidden layer sizes ในช่วง 1, 50, 100 และตั้งค่า activation ให้เลือก identity, logistic, tanh, relu โดย Solver จะให้เลือก lbfgs, sgd, adam หลังจากนั้นจะนำค่าพารามิเตอร์ที่ได้จาก Grid Search มาใช้ในการวิเคราะห์และเปรียบเทียบ



รูปที่ 3.10 ขั้นตอนกระบวนการสร้างโมเดล MLP

3.5 ทดสอบโมเดลทางคณิตศาสตร์ เพื่อทำการเปรียบเทียบประสิทธิภาพ

การทดสอบประสิทธิภาพจะในงานวิจัยนี้จะใช้ค่า R^2 , RMSE และ MAE ในการเปรียบเทียบค่าความแน่นของเนื้อของผลอะโวคาโดที่แต่ละแบบจำลองทางคณิตศาสตร์หรือโมเดลสามารถทำนายได้ ซึ่งค่า R^2 , RMSE, MAE หาได้จากสมการที่ 3.5, 3.6 และ 3.7 ตามลำดับ และการทดสอบความแม่นยำ (R^2) ในการทำนายค่าความแน่นเนื้อของผลอะโวคาโด จะทำโดยการเปรียบเทียบค่าความแน่นเนื้อที่แบบจำลองทางคณิตศาสตร์หรือโมเดลทำนายได้กับค่าความแน่นเนื้อที่ได้จากการทดลองโดยเครื่องวิเคราะห์เนื้อสัมผัส TA.Xtplus เพื่อหาโมเดลที่เหมาะสมในการทำนายความสุกของผลอะโวคาโด

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (3.5)$$

(worst value = $-\infty$; best value = +1)

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^m (X_i - Y_i)^2} \quad (3.6)$$

(best value = 0; worst value = $+\infty$)

$$MAE = \frac{1}{M} \sum_{i=1}^m |X_i - Y_i| \quad (3.7)$$

(best value = 0; worst value = $+\infty$)

บทที่ 4

ผลการทดลองและวิจารณ์

การศึกษางานวิจัยในครั้งนี้ได้ทำการศึกษาการทำนายระดับความสุกของผลอะโวคาโดด้วยวิธีการประมวลผลภาพร่วมกับแบบจำลองทางคณิตศาสตร์ โดยเริ่มจากการเก็บรวบรวมข้อมูลและทำการทดลองหาค่าสีของเปลือกและค่าความแน่นเนื้อของผลอะโวคาโดพันธุ์แฮส ซึ่งได้ผลการทดลองดังตารางที่ 4.1 และนำข้อมูลที่ได้จากการทดลองนำมาประยุกต์ใช้ในการประมวลผลภาพร่วมกับการสร้างโมเดลเพื่อใช้ในการทำนายค่าความแน่นเนื้อของผลอะโวคาโด (Firmness) ด้วยโมเดล K-Nearest Neighbors (KNN), Support Vector Regression (SVR) และ Multi-layer Perceptron (MLP) ซึ่งได้ผลการทดลองดังขั้นตอนต่อไปนี้


ตารางที่ 4.1 ผลการทดลองของผลอะโวคาโดโดยเฉลี่ย



วันที่	ลูกที่	L*	a*	b*	ค่าความแน่นเนื้อ (N)
0	1	30.39	-10.81	22.35	15.47
0	2	30.04	-10.57	20.72	13.53
0	3	30.01	-10.37	21.54	14.86
0	4	30.21	-10.21	21.18	15.68
0	5	30.02	-9.82	20.07	15.59
1	1	29.29	-11.33	23.21	14.14
1	2	27.66	-8.97	17.55	12.53
1	3	28.96	-8.90	20.13	13.29
1	4	27.97	-9.58	22.13	12.71
1	5	29.31	-10.07	18.00	12.03
2	1	28.21	-10.35	20.61	12.410
2	2	28.06	-9.50	17.44	11.997
2	3	28.83	-8.05	18.91	10.438
2	4	27.97	-10.37	21.21	9.695
2	5	28.21	-6.88	17.19	9.817

ตารางที่ 4.1 ผลการทดลองของผลอะโวคาโดโดยเฉลี่ย (ต่อ)

วันที่	ลูกที่	L*	a*	b*	ค่าความแน่นเนื้อ (N)
3	1	27.80	-7.93	22.35	8.87
3	2	27.10	-7.95	16.44	3.98
3	3	28.73	-7.43	21.54	6.13
3	4	27.71	-7.60	21.18	5.16
3	5	27.97	-7.38	19.51	4.06
4	1	27.64	-4.60	14.19	1.78
4	2	27.65	-3.71	17.49	1.48
4	3	27.29	-2.16	14.83	1.70
4	4	27.31	-2.48	17.35	1.60
4	5	27.01	-2.00	16.39	1.42
5	1	26.33	-1.14	10.91	0.71
5	2	26.72	0.90	13.93	0.79
5	3	26.78	-2.68	13.39	0.64
5	4	26.41	1.19	7.98	0.67
5	5	27.52	-3.66	14.61	0.78
6	1	25.76	-0.85	12.15	0.45
6	2	25.49	-0.97	13.39	0.48
6	3	24.75	-1.10	13.31	0.32
6	4	25.41	-0.85	12.41	0.45
6	5	24.40	-1.07	15.98	0.60
7	1	25.76	-2.99	13.21	0.31
7	2	25.49	-3.21	13.31	0.31
7	3	24.31	-2.57	13.80	0.26
7	4	25.41	-3.57	13.58	0.30
7	5	22.74	-2.06	16.31	0.37

จากตารางที่ 4.1 เป็นผลการทดลองของผลอะโวคาโดโดยเฉลี่ยตั้งแต่วันที่ 0 ถึงวันที่ 7 พบว่าในวันที่ 0 หรือวันที่ทำการซื้อผลอะโวคาโด จะมีค่าสีของเปลือก L^* , a^* , b^* เฉลี่ยอยู่ที่ 30.14, 10.36 และ 22.28 ตามลำดับ และมีค่าความแน่นเนื้อ (Firmness) เฉลี่ยอยู่ที่ 15.025 N หลังจากทำการบ่มรักษาเพื่อให้อะโวคาโดสุกโดยในวันที่ 7 คือวันที่อะโวคาโดสุกและเริ่มเกิดการเน่าเสีย ซึ่งจะมีค่าสีของเปลือก L^* , a^* , b^* เฉลี่ยอยู่ที่ 24.74, -2.88 และ 14.04 ตามลำดับ โดยการเปลี่ยนแปลงของค่าสี $L^*a^*b^*$ ของสีเปลือกอะโวคาโดจะแสดงดังรูปที่ 4.1 และมีค่าความแน่นเนื้อ (Firmness) เฉลี่ยอยู่ที่ 0.307 N ซึ่งสอดคล้องกับงานวิจัยดณัย และคณะ (2562) ที่กล่าวไว้ว่า การสุกของผลอะโวคาโดสามารถพิจารณาได้จากสีเปลือก ซึ่งมีการเปลี่ยนแปลงที่ชัดเจนอย่างมีนัยสำคัญทางสถิติ ($p \leq 0.05$) โดยสีเปลือกจะเปลี่ยนจากสีเขียวเป็นสีม่วงดำและการอ่อนนุ่มลงของเนื้อผล เนื่องด้วยในการบ่มรักษาผลอะโวคาโดจะมีการเสื่อมสลายของผนังเซลล์หรือสารที่เชื่อมผนังเซลล์ จึงทำให้เนื้อผลอ่อนนุ่มลง






(c)


รูปที่ 4.1 การเปลี่ยนแปลงของค่าสีในผลอะโวคาโดที่ในกระบวนการบ่มรักษา (a) คือค่าสีของ L* (b) คือค่าสีของ a* (c) คือค่าสีของ b*

4.1 การทดสอบค่าสีของผลอะโวคาโด


ในการทดสอบค่าสีของผลอะโวคาโด ทางผู้วิจัยได้ทำการเก็บค่าสีในระบบ CIELab และได้ทำการวัดค่าสีของผลอะโวคาโดเป็น 3 ส่วนคือ ด้านบน,ตรงกลาง และด้านล่าง โดยจะแสดงในตารางภาคผนวก ก และได้้นำผลการทดลองใส่ในโปรแกรม Minitab และได้ผลการทดลองดังรูปที่ 4.2 โดยรูปที่ 4.2(a) จะแสดงค่าสี L^* , รูปที่ 4.2(b) คือค่าสีของ a^* และรูปที่ 4.2(c) คือค่าสีของ b^* ที่แบ่งออกเป็น 3 ส่วนคือ ด้านบน,ตรงกลาง และด้านล่าง จากการทดสอบสมมติฐานเพื่อหาความแตกต่างของค่าสีของเปลือกในแต่ละส่วน จะพบว่าค่า $p > 0.05$ แสดงว่าค่าสี $L^*a^*b^*$ ของผลอะโวคาโดในแต่ละวัน และในแต่ละส่วนจะไม่มี ความแตกต่างสามารถนำมาใช้แทนกันได้



(a)



(b)




(c)


รูปที่ 4.2 ค่าสีของผลอะโวคาโดแต่ละส่วน (a) คือค่าสีของ L* (b) คือค่าสีของ a* (c) คือค่าสีของ b*

4.2 การทดสอบค่าความแน่นเนื้อของผลอะโวคาโด

ในการทดสอบค่าความแน่นเนื้อของผลอะโวคาโด ทางผู้วิจัยได้ทำการวัดค่าความแน่นเนื้อของผลอะโวคาโดเป็น 3 ส่วนคือ ด้านบน,ตรงกลาง และด้านล่าง โดยจะแสดงในตารางภาคผนวก ก และได้นำผลการทดลองใส่ในโปรแกรม Minitab และได้ผล ดังรูปที่ 4.3 จากการทดสอบสมมติฐานเพื่อหาความแตกต่างของค่าความแน่นเนื้อของผลอะโวคาโดในแต่ละส่วน จะพบว่าค่า $p > 0.05$ แสดงว่าค่าความแน่นเนื้อของผลอะโวคาโดในแต่ละวันและในแต่ละส่วนจะไม่มี ความแตกต่างกันสามารถนำมาใช้แทนกันได้ และพบว่าที่ระดับความเชื่อมั่นที่ 95% ค่าความแน่นเนื้อของผลอะโวคาโดที่บันทึกได้ในแต่ละวัน จะมีการเปลี่ยนแปลงโดยผลอะโวคาโดที่ยังดิบเมื่อนำไปบ่มรักษาตามระยะเวลา (วัน) เพื่อให้ผลอะโวคาโดสุกค่าความแน่นเนื้อของผลอะโวคาโดจะลดลง และผลที่สุกค่าความแน่นเนื้อก็จะยิ่งเข้าใกล้ 0 N ซึ่งสอดคล้องกับงานวิจัยของ Magwaza & Tesfay (2015) ที่ได้กล่าวไว้ว่า ค่าความแน่นเนื้อของผลอะโวคาโดจะเปลี่ยนอย่างช้าๆ โดยเมื่อผลอะโวคาโดที่ใกล้สุกเต็มที่จะมีค่าความแน่นเนื้อ (Firmness) ใกล้เคียง 0 N ดังรูปที่ 4.4



รูปที่ 4.3 ค่าความแน่นเนื้อของผลอะโวคาโดในแต่ละส่วน



รูปที่ 4.4 การเปลี่ยนแปลงของค่าความแน่นเนื้อในผลอะโวคาโด

Method

Null hypothesis All means are equal
Alternative hypothesis Not all means are equal
Significance level $\alpha = 0.05$
Equal variances were assumed for the analysis.

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Days	7	1319.20	188.457	211.94	0.000
Error	32	28.45	0.889		
Total	39	1347.65			

Model Summary

S	R-sq	R-sq(adj)	R-sq(pred)
0.942966	97.89%	97.43%	96.70%


Grouping Information Using the Tukey Method and 95% Confidence

Days	N	Mean	Grouping
0	5	15.025	A
1	5	12.941	B
2	5	10.871	C
3	5	5.640	D
4	5	1.5973	E
5	5	0.7181	E
6	5	0.4610	E
7	5	0.3075	E


Means that do not share a letter are significantly different.

จากข้อมูลทางสถิติของ Tukey ในโปรแกรม Minitab ทำให้ทราบว่าการเปลี่ยนแปลงของค่าความแน่นเนื้อของผลอะโวคาโด ที่ระดับความเชื่อมั่น 95% สามารถแบ่งระดับความสุกของผลอะโวคาโดได้โดยที่วันที่ 0 ถึงวันที่ 3 หลังจากการบ่มรักษาผลอะโวคาโดยังคงดิบ และหลังจากวันที่ 4 เป็นต้นไป ผลอะโวคาโดจะมีระดับความสุกที่พร้อมสำหรับการรับประทาน


4.3 ความสัมพันธ์ระหว่างค่าสีของเปลือกกับค่าความแน่นเนื้อของผลอะโวคาโด



(a)



(b)



(c)

รูปที่ 4.5 ความสัมพันธ์ระหว่างค่าสีกับค่าความแน่นเนื้อของผลอะโวคาโด (a) L^* กับ Firmness
(b) คือค่าสีของ a^* กับ Firmness (c) คือค่าสีของ b^* กับ Firmness

จากรูปที่ 4.5 ที่ระดับความเชื่อมั่นที่ 95% จะพบว่าความสัมพันธ์ของค่าสี (L^* , a^* , b^*) กับค่าความแน่นเนื้อ (Firmness) ของผลอะโวคาโดมีความสัมพันธ์กัน โดยที่ค่าสัมประสิทธิ์สหสัมพันธ์หรือ Pearson Correlation ระหว่างความแน่นเนื้อกับ L^* , a^* และ b^* มีค่าเท่ากับ 0.837, -0.921 และ 0.805 ตามลำดับ ทำให้ทราบว่าในการเปลี่ยนแปลงของค่าสี a^* จะส่งผลกับการเปลี่ยนแปลงของค่าความแน่นเนื้อมากที่สุด ค่าสี a^* จึงเหมาะสำหรับการนำมาทำนายค่าความแน่นเนื้อของผลอะโวคาโด เพราะอะโวคาโดพันธุ์แฮสเมื่อยังเป็นผลดิบจะมีสีเขียว และเมื่อผลเริ่มที่สุกจะเปลี่ยนเป็นสีม่วง โดยที่ค่าสี a^* คือค่าสีระหว่างสีเขียวกับสีแดง

4.4 การทดสอบประสิทธิภาพของโมเดล

จากการนำผลอะไคโดมาทำการถ่ายภาพ 2 ด้าน ต่อ 1 ลูก และทำการประมวลภาพเพื่อนำข้อมูลที่ได้ไปใช้ร่วมด้วย 3 โมเดล คือ โมเดล K-Nearest Neighbors (KNN)

4.4.1 K-Nearest Neighbors (KNN)

จากการสร้างโมเดล KNN (90/10), KNN (80/20) และ KNN (70/30) และได้ใช้ Grid Search ซึ่งเป็นไลบรารีที่ใช้ในการปรับค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับโมเดล พบว่าค่าพารามิเตอร์ที่เหมาะสมที่ Grid Search ปรับค่าพารามิเตอร์ให้เข้ากับข้อมูลในงานวิจัยคือ $K = 5$ และได้ทำการกำหนดค่าพารามิเตอร์นี้เอาไว้ เพื่อทำการเปรียบเทียบและได้ผลดังตารางที่ 4.2

ตารางที่ 4.2 ผลการทดสอบประสิทธิภาพของโมเดล KNN

Model	Train/Test	R^2		RMSE		MAE	
		Test	Validation	Test	Validation	Test	Validation
KNN	70/30	0.786	0.868	6.962	5.098	1.703	1.586
KNN	80/20	0.787	0.882	6.953	4.566	1.672	1.503
KNN	90/10	0.785	0.871	6.910	4.994	1.723	1.529

จากตารางที่ 4.2 พบว่าโมเดล KNN (70/30) ในการทดสอบมีค่าสัมประสิทธิ์การตัดสินใจ (R^2) หรือค่าความแม่นยำในการทำนายค่าความแน่นอนของผลอะไคโดในการทดสอบมีค่า 0.786 เทียบกับข้อมูลที่ใช้ในการตรวจสอบ มีค่าเท่ากับ 0.868 ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของตัวแปรรากที่สอง (RMSE) และค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) หรือค่าความผิดพลาด (Error) มีค่าเท่ากับ 6.962 และ 1.703 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 5.098 และ 1.586 ตามลำดับ และในโมเดลของ KNN (80/20) มีค่า R^2 , RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.787, 6.953 และ 1.672 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.882, 4.566 และ 1.503 ตามลำดับ ส่วนโมเดลของ KNN (90/10) มีค่า R^2 , RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.785, 6.910 และ 1.723 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.871, 4.994 และ 1.529 ตามลำดับ ทำให้ทราบว่าโมเดล KNN (80/20) ให้ค่าความแม่นยำในการทำนายค่าความแน่นอนของผลอะไคโดที่มากที่สุดสำหรับโมเดล KNN

4.4.2 Support Vector Regression (SVR)

จากการสร้างโมเดล SVR (90/10), SVR (80/20) และ SVR (70/30) และได้ใช้ Grid Search ซึ่งเป็นไลบรารีที่ใช้ในการปรับค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับโมเดล พบว่าค่าพารามิเตอร์ที่เหมาะสมที่ Grid Search ปรับค่าพารามิเตอร์ให้เข้ากับข้อมูลในงานวิจัยนี้คือ Kernel ที่เป็นเกาส์เซียนเคอร์เนล (Gaussian (RBF) kernel) โดยที่ค่า $C = 1$ และ $\gamma = 1$ และได้ทำการกำหนดค่าพารามิเตอร์นี้เอาไว้ เพื่อทำการเปรียบเทียบและได้ผลดังตารางที่ 4.3

ตารางที่ 4.3 ผลการทดสอบประสิทธิภาพของโมเดล SVR

Model	Train/Test	R^2		RMSE		MAE	
		Test	Validation	Test	Validation	Test	Validation
SVR	70/30	0.769	0.671	8.886	12.748	2.001	2.772
SVR	80/20	0.770	0.637	8.597	12.752	1.998	2.804
SVR	90/10	0.776	0.670	8.310	12.760	1.993	2.814

จากตารางที่ 4.3 พบว่าโมเดล SVR (70/30) จะมีค่า R^2 , RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.769, 8.886 และ 2.001 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.671, 12.748 และ 2.772 ตามลำดับ SVR (80/20) จะมีค่า R^2 , RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.770, 8.597 และ 1.998 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.637, 12.752 และ 2.804 ตามลำดับ SVR (90/10) จะมีค่า R^2 , RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.776, 8.310 และ 1.993 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.670, 12.760 และ 2.814 ตามลำดับ ทำให้ทราบว่าโมเดล SVR (90/10) ให้ค่าความแม่นยำในการทำนายค่าความแน่นอนของผลอะโวคาโดที่มากที่สุดสำหรับโมเดล SVR

4.4.3 Multi-layer Perceptron (MLP)

จากการสร้างโมเดล MLP (90/10), MLP (80/20) และ MLP (70/30) และได้ใช้ Grid Search ซึ่งเป็นไลบรารีที่ใช้ในการปรับค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับโมเดล พบว่าค่าพารามิเตอร์ที่เหมาะสมที่ Grid Search ปรับค่าพารามิเตอร์ให้เข้ากับข้อมูลในงานวิจัยนี้คือ activation ที่เป็นฟังก์ชันเรกติไฟด์ไลน์ยูนิต (Rectified Linear Units, ReLu) โดยมีค่า hidden layer sizes = 100 , Solver เป็น adam ในการปรับค่าน้ำหนักของโครงข่ายประสาทเทียมซึ่งมี Learning rate หรืออัตราการเรียนรู้ในการปรับค่าน้ำหนัก เท่ากับ 0.001 และได้ทำการกำหนดค่าพารามิเตอร์นี้เอาไว้ เพื่อทำการเปรียบเทียบและได้ผลดังตารางที่ 4.4

ตารางที่ 4.4 ผลการทดสอบประสิทธิภาพของโมเดล MLP

Model	Train/Test	R ²		RMSE		MAE	
		Test	Validation	Test	Validation	Test	Validation
MLP	70/30	0.882	0.882	4.544	4.582	1.074	1.479
MLP	80/20	0.988	0.859	0.480	5.474	0.440	1.484
MLP	90/10	0.990	0.946	0.341	2.102	0.321	0.992


จากตารางที่ 4.4 โมเดล MLP นั้น MLP (70/30) จะมีค่า R², RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.882, 4.544 และ 1.074 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.882, 4.582 และ 1.479 ตามลำดับ MLP (80/20) จะมีค่า R², RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.988, 0.480 และ 0.440 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.859, 5.474 และ 1.484 ตามลำดับ MLP (90/10) จะมีค่า R², RMSE และ MAE ที่ได้จากการทดสอบเท่ากับ 0.990, 0.341 และ 0.321 ตามลำดับ เทียบกับข้อมูลที่ใช้ในการตรวจสอบ ซึ่งมีค่าเท่ากับ 0.946, 2.102 และ 0.992 ตามลำดับ ทำให้ทราบว่าโมเดล MLP (90/10) ให้ค่าความแม่นยำในการทำนายค่าความแน่นเนื้อของผลอะโวคาโดที่มากที่สุดสำหรับโมเดล MLP และเมื่อนำทั้งสามโมเดลที่ดีที่สุดมาได้แก่ KNN (80/20) , SVR (90/10) และ MLP (90/10) ทำการเปรียบเทียบกันพบว่าโมเดล MLP (90/10) ให้ค่าความแม่นยำในการทำนายค่าความแน่นเนื้อของผลอะโวคาโดที่มากที่สุดและมีค่าความผิดพลาดน้อยที่สุดอีกด้วย

4.5 การทดสอบค่าความแม่นยำในการทำนายของโมเดล


การทดสอบความแม่นยำ (R^2) ของโมเดลนี้คือการทดสอบความแม่นยำของการทำนายค่าความแน่นเนื้อของผลอะโวคาโดระหว่างค่าที่ทำนายได้จากโมเดลและค่าที่ได้จากวัดของการทดลอง ดังตารางที่ 4.5 ที่ระดับความเชื่อมั่นที่ 95% โดยจะใช้ผลอะโวคาโด 8 ผลที่เตรียมไว้สำหรับการตรวจสอบ พบว่าโมเดล KNN สามารถทำนายความแน่นเนื้อเทียบกับค่าที่วัดได้จากการทดลองถึง 95.2% และโมเดล SVR สามารถทำนายความแน่นเนื้อเทียบกับค่าที่วัดได้จากการทดลองถึง 94.9% ส่วนโมเดล MLP สามารถทำนายความแน่นเนื้อเทียบกับค่าที่วัดได้จากการทดลองได้สูงถึง 99.4% ดังรูปที่ 4.6 ดังนั้นโมเดลที่เหมาะสมที่สุดในงานวิจัยนี้ในการนำไปใช้ในการพัฒนาคือโมเดล MLP ซึ่งขั้นตอนและวิธีการทดสอบโมเดลจะแสดงในภาคผนวก ค

ตารางที่ 4.5 ค่าความแน่นเนื้อของผลอะโวคาโดที่ได้จากโมเดลกับค่าความแน่นเนื้อที่ได้จากการทดลอง


ค่าความแน่นเนื้อที่โมเดลทำนาย (N)			ค่าความแน่นเนื้อจากการทดลอง (N)
SVR	MLP	KNN	
12.839	14.344	11.372	15.590
12.951	12.116	11.096	12.714
8.898	12.530	11.267	11.997
7.493	6.138	7.586	6.132
2.415	1.138	1.864	1.705
0.567	0.415	0.621	0.665
0.412	0.415	0.474	0.449
0.238	0.215	0.207	0.257



(a)



(b)



(c)

รูปที่ 4.6 แสดงค่าความแม่นยำในการทำนายค่าความแน่นเนื้อระหว่างค่าที่โมเดลได้ทำการทำนายกับค่าที่วัดได้จากการทดลอง (a) โมเดล KNN (b) โมเดล SVR (c) โมเดล MLP

บทที่ 5

สรุปผลการทดลองและข้อเสนอแนะ

5.1 สรุปผลการทดลองและข้อเสนอแนะ

5.1.1 สรุปผลการสร้างแบบจำลองเพื่อทดสอบในการทำนายค่าความแน่นเนื้อของผลอะโวคาโด จากการใช้วิธีการประมวลผลภาพรวมรวมกับการใช้โมเดลแบบจำลองทางคณิตศาสตร์สามารถทำนายค่าความแน่นเนื้อของผลอะโวคาโดได้ และโมเดลที่ใช้ในงานวิจัยนี้คือโมเดล K-Nearest Neighbors (KNN), Support Vector Regression (SVR) และ Multi-layer perceptron (MLP)

5.1.2 สรุปผลการทดลองและเปรียบเทียบพบว่าโมเดล K-Nearest Neighbors (KNN) ที่แบ่งข้อมูลฝึกฝนเป็น 80% กับข้อมูลที่ใช้ในการทดสอบเป็น 20% ซึ่งมีค่า R^2 , RMSE และ MAE เท่ากับ 0.787, 6.953 และ 1.762 ตามลำดับ Support Vector Regression (SVR) ที่แบ่งข้อมูลฝึกฝนเป็น 90% กับข้อมูลที่ใช้ในการทดสอบเป็น 10% ซึ่งมีค่า R^2 , RMSE และ MAE เท่ากับ 0.776, 8.310 และ 1.993 ตามลำดับ Multi-layer perceptron (MLP) ที่แบ่งข้อมูลฝึกฝนเป็น 90% กับข้อมูลที่ใช้ในการทดสอบเป็น 10% ซึ่งมีค่า R^2 , RMSE และ MAE เท่ากับ 0.990, 0.341 และ 0.321 ตามลำดับ และจากการทดสอบความแม่นยำ (R^2) ที่ระดับความเชื่อมั่นที่ 95% พบว่าในการทำนายค่าความแน่นเนื้อของโมเดลกับค่าที่วัดได้จากการทดลอง โมเดล KNN สามารถทำนายความแน่นเนื้อเทียบกับค่าที่วัดได้จากการทดลองได้ความแม่นยำถึง 95.2% และโมเดล SVR สามารถทำนายความแน่นเนื้อเทียบกับค่าที่วัดได้จากการทดลองได้ความแม่นยำถึง 94.9% ส่วนโมเดล MLP สามารถทำนายความแน่นเนื้อเทียบกับค่าที่วัดได้จากการทดลองได้ความแม่นยำถึง 99.4% ดังนั้นโมเดลที่เหมาะสมที่สุดในงานวิจัยนี้ในการนำไปใช้ในการพัฒนาในการทำนายความสุกของผลอะโวคาโด คือโมเดล MLP โดยมีสมการถดถอยดังนี้ $Firmness = -24.54 + 0.904 L^* - 1.056 a^* - 0.009 b^*$ ที่สามารถทำนายหาค่าความแน่นเนื้อของผลอะโวคาโดได้อย่างแม่นยำและมีความผิดพลาดในการทำนายที่น้อย

5.1.3 งานวิจัยนี้สามารถใช้เป็นแนวทางในการนำโมเดลนี้ไปพัฒนาต่อไปได้ โดยจากงานวิจัยนี้ทำการเก็บตัวอย่างอะโวคาโดเพียงสองด้านต่อหนึ่งลูก จึงสามารถพัฒนาให้เป็นการถ่ายรูปแบบ 3D เพื่อนำมาวิเคราะห์ข้อมูล และยังสามารถต่อยอดเป็นแอปพลิเคชันบนสมาร์ตโฟน ใช้ในการสแกนค่าความแน่นเนื้อของผลอะโวคาโดสายพันธุ์แฮสเพื่อให้ผู้บริโภคสามารถเลือกอะโวคาโดระดับความสุกของผลอะโวคาโดที่ต้องการได้ ทั้งยังสามารถนำไปเป็นแนวทางในการประยุกต์ใช้แบบจำลองโมเดลนี้ในการวัดคุณสมบัติของผลอะโวคาโดในระดับอุตสาหกรรม หรือนำงานวิจัยนี้เป็นแนวทางและประยุกต์ใช้กับผลอะโวคาโดสายพันธุ์อื่นๆก็ได้

5.2 ข้อเสนอแนะ

5.2.1 งานวิจัยนี้สามารถนำไปใช้เป็นแนวทางในการประยุกต์ใช้ร่วมกับกล้อง Webcam หรือกล้อง CCTV เพื่อใช้ในการวิเคราะห์คุณสมบัติของผลอะโวคาโดแบบ Real-Time ได้

5.2.2 งานวิจัยนี้สามารถนำไปใช้เป็นแนวทางประกอบในการคัดแยกผลอะโวคาโดผลที่สูงกับผลที่ติดร่วมกับโมเดลที่ใช้ในด้านของ Classification เพื่อพัฒนาโมเดลในการวัดระดับความสุกของผลอะโวคาโดต่อไปได้

5.2.3 งานวิจัยนี้สามารถใช้เป็นแนวทางในการวิเคราะห์คุณสมบัติของผลไม้อื่นๆได้



บรรณานุกรม

- [1] ฉลองชัย แบบประเสริฐ และคนอื่นๆ. (2545). การพัฒนาพันธุ์อะโวคาโดเพื่อการค้าและอุตสาหกรรม: รายงานการวิจัยฉบับสมบูรณ์ ประจำปี 2545. [ม.ป.ท.]: มูลนิธิโครงการหลวง
- [2] มูลนิธิโครงการหลวง สถาบันวิจัยและพัฒนาพื้นที่สูง (องค์กรมมหาชน). (2563). คู่มือการเก็บเกี่ยวอะโวคาโดบนพื้นที่สูง. พิมพ์ครั้งที่ 2. เชียงใหม่: วนิตการพิมพ์
- [3] Magwaza, L. S., & Tesfay, S. Z. (2015). A review of destructive and non-destructive methods for determining avocado fruit maturity. Food and bioprocess technology, 8(10), 1995-2011.
- [4] Suksukont, A., Santingamwong, C., Khamkhaek, W., & Pansuwan, S. (2022). ระบบวิเคราะห์การสุกของผลไม้ด้วยเทคโนโลยีการประมวลผลภาพ. JOURNAL OF INFORMATION SCIENCE AND TECHNOLOGY, 12(1), 61-66.
- [5] อภิศักดิ์ พรหมฉาย และพิทักษ์ คล้ายชม. (2560). การจำแนกระดับความสุกทุเรียนพันธุ์หลงลับแลโดยการตรวจสอบระดับสีผิวเปลือกทุเรียนด้วยกระบวนการประมวลผลภาพ. วารสารวิจัยและพัฒนา มจร. ปีที่ 40 ฉบับที่ 2 เมษายน – มิถุนายน 2560
- [6] Mozaffari, M., Sadeghi, S., & Asefi, N. (2022). Prediction of the quality properties and maturity of apricot by laser light backscattering imaging. Postharvest Biology and Technology, 186, 111842.
- [7] Sanaeifar, A., Bakhshipour, A., & De La Guardia, M. (2016). Prediction of banana quality indices from color features using support vector regression. Talanta, 148, 54-61.
- [8] Sherafati, A., Mollazade, K., Saba, M. K., & Vesali, F. (2022). TomatoScan: An Android-based application for quality evaluation and ripening determination of tomato fruit. Computers and Electronics in Agriculture, 200, 107214.
- [9] Keramat-Jahromi, M., Mohtasebi, S. S., Mousazadeh, H., Ghasemi-Varnamkhasti, M., & Rahimi-Movassagh, M. (2021). Real-time moisture ratio study of drying date fruit chips based on on-line image attributes using kNN and random forest regression methods. Measurement, 172, 108899.

บรรณานุกรม (ต่อ)

- [10] ชูพงษ์ สุขุมลันนันทน์. (2558). การนำเข้าพันธุ์ไม้ผลจากต่างถิ่นและการทดสอบในพื้นที่มูลนิธิโครงการหลวง. เชียงใหม่ มูลนิธิโครงการหลวง
- [11] อภิชาติ ศรีสอาด และศุภวรรณ ใจแสน. 2552. คู่มือเพาะปลูกพืชผักและผลไม้ที่สูงในไทย. บริษัท นาคา อินเตอร์มีเดีย จำกัด. พิมพ์ครั้งที่ 1. 168 หน้า.
- [12] ดนัย บุญเกียรติ และคณะ. (2562). การเปลี่ยนแปลงทางกายภาพและเคมีของผลอะโวคาโดพันธุ์แฮสในระหว่างการแก่และการสุก. วารสารวิทยาศาสตร์เกษตร 50 (3 พิเศษ): 83-86. 2562.
- [13] Hunt, R. W. G., & Pointer, M. R. (2011). **Measuring colour**. John Wiley & Sons.
- [14] Agudo, J. E., Pardo, P. J., Sánchez, H., Pérez, Á. L., & Suero, M. I. (2014). **A low-cost real color picker based on arduino**. *Sensors*, 14(7), 11943-11956.
- [15] Mohammadi, V., Kheiralipour, K., & Ghasemi-Varnamkhasti, M. (2015). **Detecting maturity of persimmon fruit based on image processing technique**. *Scientia Horticulturae*, 184, 123-128.
- [16] ปิยาภรณ์ มาตย์วิเศษ. (2566). การวิเคราะห์คุณลักษณะของนักเก็ตไก่แช่แข็งโดยใช้การถ่ายภาพร่วมกับวิธีการทางสถิติ. วิทยานิพนธ์. วิศวกรรมอุตสาหการ. สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
- [17] Mohamad, M., Saman, M. Y. M., Hitam, M. S., & Telipot, M. (2015). **A Review on OpenCV**. Terengganu. Universitas Malaysia Terengganu.
- [18] Géron, A. (2022). **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. O'Reilly Media, Inc.
- [19] McCarthy, J. (2004). **What is artificial intelligence?**. Computer Science Department. Stanford. Stanford University.
- [20] วีระพันธ์ พานิชย์วิเศษ. (2563). การประยุกต์ใช้ Machine Learning ทำนายผลการเรียนวิชา Web Database ของนิสิตสาขาเทคโนโลยีการศึกษา คณะศึกษาศาสตร์ มหาวิทยาลัยบูรพา. วิทยานิพนธ์. วิศวกรรมคอมพิวเตอร์และโทรคมนาคม. มหาวิทยาลัยธุรกิจบัณฑิตย์
- [21] Ayodele, T. O. (2010). **Machine learning overview**. *New Advances in Machine Learning*, 2, 9-18.

บรรณานุกรม (ต่อ)

- [22] ภัทรกร วัฒนาชีพ และ ศิริรัตน์ บุญกว้าง. (2555). การเรียนรู้ของเครื่อง. ปริญญาานิพนธ์. วิศวกรรมคอมพิวเตอร์. สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
- [23] Trieu, N. M., & Thinh, N. T. (2022). A study of combining knn and ann for classifying dragon fruits automatically. Journal of Image and Graphics, 10(1), 28-35
- [24] รณชัย ชื่น ธวัช, กิตติ ศักดิ์ เกิด ประสพ และนิต ยา เกิด ประสพ. (2017). การพยากรณ์ความต้องการใช้งานหน่วยจำหน่ายไฟฟ้าด้วยซัพพอร์ทเวกเตอร์รีเกรสชันแบบตรวจสอบสลับ 3 ส่วน. วารสาร วิทยาศาสตร์ และ เทคโนโลยี มหาวิทยาลัย อุบลราชธานี, 19(1), 215-232.
- [25] กอบเกียรติ สระอุบล. 2565. เรียนรู้ AI: Deep learning ด้วย Python. กรุงเทพฯ : อินเทอร์เน็ต. พิมพ์ครั้งที่ 1. 592 หน้า.
- [26] ธนาวุฒิ ประกอบผล. (2552). โครงข่ายประสาทเทียม Artificial Neural Networks. วารสาร มวก.วิชาการ. ปีที่ 12 ฉบับที่ 14 มกราคม - มิถุนายน 2552. 83-7.
- [27] ภูมิรพี ภูมิคำ. (2565). เทคนิคการเรียนรู้เชิงลึกเพื่อวิเคราะห์ความรู้สึกจากผู้ใช้งานผลิตภัณฑ์. วิทยานิพนธ์. วิศวกรรมคอมพิวเตอร์และโทรคมนาคม. มหาวิทยาลัยเทคโนโลยีสุรนารี
- [28] Popescu, M. C., Balas, V. E., Perescu-Popescu, L., & Mastorakis, N. (2009). Multilayer perceptron and neural networks. WSEAS Transactions on Circuits and Systems, 8(7), 579-588.
- [29] Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. Peer J Computer Science, 7, e623.
- [30] ดนัย บุญเกียรติ. (2562). การประเมินดัชนีเก็บเกี่ยวและคุณภาพหลังการเก็บเกี่ยวของผลอะโวคาโดด้วยเทคนิคเนียร์อินฟราเรดสเปกโทรสโกปี: รายงานวิจัยฉบับสมบูรณ์. เชียงใหม่. มวลนิธิโครงการหลวง.
- [31] Cho, B. H., Koyama, K., Olivares Díaz, E., & Koseki, S. (2020). Determination of “Hass” avocado ripeness during storage based on smartphone image and machine learning model. Food and Bioprocess Technology, 13, 1579-1587.

บรรณานุกรม (ต่อ)

- [32] Cho, B. H., Koyama, K., & Koseki, S. (2021). Determination of 'Hass' avocado ripeness during storage by a smartphone camera using artificial neural network and support vector regression. *Journal of Food Measurement and Characterization*, 15, 2021-2030.



ภาคผนวก



ภาคผนวก ก
ภาพและผลการทดลองผลของผลอะโวคาโด



การทดสอบผลอะโวคาโด

การทดสอบวัดค่าสีของผลอะโวคาโดจะทำการวัดด้วยเครื่องวัดสี (color meter, WR-10, Minolta, Japan) โดยจะทำการวัดค่าสีในระบบ CIELab ดังรูปที่ 1



รูปที่ 1 เครื่องวัดสี (color meter, WR-10, Minolta, Japan)

ในการวัดค่าสีจะทำการวัดค่าสีทั้งหมด 9 ตำแหน่ง ต่อ 1 ด้าน โดยจะแบ่งเป็น 3 โซน คือ บน กลาง ล่าง และในแต่ละโซนจะทำการวัดอีก 3 ตำแหน่ง ซ้าย กลาง ขวา และบันทึกค่าสี ดังรูปที่ 2



รูปที่ 2 ตำแหน่งในการวัดค่าสีของผลอะโวคาโด

การวัดค่าความแน่นเนื้อของผลอะโวคาโด จะทำการวัดด้วยเครื่องวิเคราะห์เนื้อสัมผัส (texture analyzer, TA.Xtplus, Stable Micro System, UK) ด้วยหัววัดชนิด P2 (2 mm diameter cylinder stainless steel) โดยการวัดแรงเป็นนิวตัน (N) ดังภาพที่ 3 ซึ่งจะทำการทดสอบทั้งหมด 3 โซน คือ บน กลาง ล่าง ดังรูปที่ 4




รูปที่ 3 เครื่องวิเคราะห์เนื้อสัมผัส (texture analyzer, TA.Xtplus, Stable Micro System, UK)




รูปที่ 4 ตำแหน่งในการวัดค่าความแน่นเนื้อของผลอะโวคาโด


ขั้นตอนการวัดค่าความแน่นเนื้อของผลไม้

1. เปิดโปรแกรม Exponent ในคอมพิวเตอร์ที่ทำการเชื่อมต่อกับเครื่องวิเคราะห์เนื้อสัมผัส






2. ทำการ Calibration ความสูงในการเจาะของเครื่องวิเคราะห์เนื้อสัมผัส โดยทำการคลิกไปที่ T.A. > Calibrate > Calibrate Height และทำการตั้งค่าการเจาะ







3. หลังจากทำการ Calibrate ความสูงในการเจาะแล้ว จะทำการตั้งค่าการเจาะผลอะโวคาโด โดยคลิกไปที่ T.A. > T.A. Setting > Library > Return to start > OK และทำการตั้งค่าการในการเจาะเพื่อวิเคราะห์ความแน่นเนื้อของผลอะโวคาโด










4. ตั้งค่าชนิดของหัวเจาะ โดยคลิกไปที่ T.A. > Run a Test > Probe Selection > P/2 > Apply หลังจากทำการตั้งค่าทุกอย่างแล้ว กดคลิกที่ Start Test





5. จดบันทึกค่าที่ได้จากการทดสอบความหนาแน่นของผลไม้จากผลไม้





ตารางภาคผนวกที่ ก.1 ค่าสี่ของเปลือก $L^*a^*b^*$ ของผลไม้โวคาโด วันที่ 0

ลูกที่	L^*		a^*		b^*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	30.40	29.84	-11.57	-11.38	25.91	23.65
	30.52	30.52	-11.03	-10.82	22.87	22.21
	30.92	29.73	-12.52	-10.51	26.87	20.94
	30.54	30.95	-10.57	-10.89	23.23	21.21
	30.47	30.65	-10.60	-9.94	22.03	20.54
	32.72	28.97	-11.52	-9.85	21.51	19.86
	30.28	29.88	-10.51	-10.13	20.38	19.56
	30.13	30.89	-10.58	-11.23	21.55	25.19
	30.00	29.64	-10.91	-10.10	22.94	21.77
เฉลี่ย	30.39		-10.81		22.35	

ตารางภาคผนวกที่ ก.1 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 0 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	29.36	30.50	-10.81	-10.33	21.52	20.85
	30.46	31.19	-9.97	-9.86	20.61	21.55
	28.67	29.36	-9.65	-10.54	20.41	20.58
	30.86	28.22	-10.84	-10.72	21.68	20.02
	30.43	30.53	-9.78	-10.26	21.30	19.45
	29.38	30.86	-10.71	-9.44	20.50	21.05
	28.42	31.72	-10.46	-11.17	20.95	20.37
	30.42	29.44	-13.83	-10.42	20.24	19.60
	30.47	30.46	-10.00	-11.53	21.10	21.12
เฉลี่ย	30.04		-10.57		20.72	
3	30.80	29.50	-9.21	-10.56	24.67	24.11
	29.82	30.66	-9.34	-10.41	25.11	26.00
	29.22	29.12	-9.27	-11.22	28.63	18.69
	29.99	29.96	-10.74	-10.04	18.97	23.31
	30.90	30.33	-10.71	-9.54	22.88	23.28
	29.39	30.95	-10.93	-9.58	18.27	16.16
	30.36	29.52	-11.23	-10.64	21.57	14.05
	30.92	29.53	-10.47	-9.30	24.17	19.68
	29.90	29.30	-10.97	-12.52	19.97	18.27
เฉลี่ย	30.01		-10.37		21.54	

ตารางภาคผนวกที่ ก.1 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 0 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	30.39	30.28	-10.62	-10.38	26.07	29.43
	30.61	31.73	-10.52	-9.12	24.54	27.03
	30.76	29.16	-10.24	-9.22	28.44	25.09
	30.55	31.08	-10.08	-10.98	19.38	22.03
	28.13	30.35	-9.15	-11.57	18.82	20.64
	31.05	31.08	-9.25	-10.61	19.21	17.83
	28.57	31.41	-11.37	-9.99	13.66	18.37
	29.37	30.34	-11.23	-9.63	17.29	16.53
	30.75	28.23	-10.50	-9.37	18.94	17.94
เฉลี่ย	30.21		-10.21		21.18	
5	30.16	30.18	-9.65	-9.92	19.47	15.28
	30.48	30.54	-9.68	-9.68	18.94	18.64
	30.78	30.57	-9.97	-9.23	17.29	17.24
	29.86	29.34	-9.21	-9.72	25.75	19.97
	29.86	30.29	-10.92	-9.53	21.71	22.43
	30.00	29.27	-9.35	-10.23	28.08	20.62
	29.15	30.7	-10.53	-9.43	16.60	21.67
	30.60	29.97	-11.34	-9.29	17.00	21.04
	28.24	30.42	-9.28	-9.81	19.99	19.45
เฉลี่ย	30.02		-9.82		20.07	

ตารางภาคผนวกที่ ก.2 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 0

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	17.736	14.833	13.852	15.474
2	15.344	12.603	12.64	13.529
3	15.538	14.688	14.342	14.856
4	16.522	14.956	15.558	15.679
5	16.258	14.656	15.856	15.590
เฉลี่ยทั้งหมด	15.025			

ตารางภาคผนวกที่ ก.3 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 1

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	28.92	33.23	-10.12	-12.42	22.87	25.92
	29.15	30.52	-12.37	-11.57	24.63	24.70
	29.39	27.42	-12.50	-11.48	25.73	23.05
	28.89	30.43	-11.11	-11.09	27.30	21.38
	27.23	28.89	-10.67	-11.37	23.50	22.98
	29.01	30.34	-11.28	-11.55	24.46	24.21
	27.17	30.02	-10.66	-11.28	22.38	20.15
	28.89	28.66	-10.66	-11.80	19.90	23.76
	30.41	28.71	-10.25	-11.71	18.42	22.36
เฉลี่ย	29.29		-11.33		23.21	

ตารางภาคผนวกที่ ก.3 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 1 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	26.81	27.07	-9.71	-8.63	19.06	19.12
	28.22	28.65	-8.03	-9.62	15.80	19.48
	27.21	27.56	-8.72	-8.83	18.19	14.25
	27.47	27.10	-8.60	-8.15	17.50	15.44
	28.71	26.77	-9.74	-9.77	15.01	18.93
	27.54	27.55	-9.12	-9.25	14.31	22.54
	30.14	27.14	-8.77	-8.78	17.50	17.46
	27.86	26.85	-8.93	-9.31	15.21	21.07
	27.54	27.62	-9.05	-8.46	15.35	19.70
เฉลี่ย	27.66		-8.97		17.55	
3	28.35	27.51	-8.15	-9.54	24.10	19.60
	27.81	28.91	-7.50	-10.39	22.98	18.42
	28.35	29.98	-9.17	-9.98	19.68	21.36
	28.98	31.87	-9.98	-9.31	24.23	14.03
	28.60	30.12	-8.70	-9.60	19.45	20.25
	28.92	30.00	-9.96	-9.47	16.68	16.85
	28.21	29.65	-7.85	-8.52	19.55	20.23
	27.58	28.25	-7.95	-8.36	20.12	20.00
	28.98	29.25	-7.66	-8.11	23.69	21.20
เฉลี่ย	28.96		-8.90		20.13	

ตารางภาคผนวกที่ ก.3 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 1 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	26.82	27.02	-9.76	-9.10	23.21	23.04
	27.66	28.74	-10.86	-11.02	24.96	25.11
	27.71	27.50	-9.01	-9.52	25.13	24.85
	30.94	27.23	-9.55	-9.41	22.03	23.05
	29.21	28.02	-9.22	-9.36	18.21	19.85
	27.69	27.24	-8.52	-9.14	22.28	21.58
	28.11	27.69	-9.52	-9.95	24.75	23.96
	27.70	28.25	-10.14	-9.57	19.99	20.18
	27.79	28.12	-9.46	-9.28	17.42	18.65
เฉลี่ย	27.97		-9.58		22.13	
5	31.57	28.94	-11.23	-9.70	18.78	18.59
	31.11	28.97	-11.30	-10.68	19.54	19.74
	29.85	32.38	-11.12	-11.40	20.96	19.90
	30.64	28.76	-10.58	-9.46	18.79	16.67
	29.35	28.31	-10.16	-10.14	17.75	18.47
	26.68	29.92	-10.59	-8.90	18.05	17.20
	27.37	28.73	-10.30	-8.55	19.21	14.78
	29.56	30.49	-9.66	-8.66	16.01	16.01
	26.90	27.99	-9.00	-9.91	15.66	17.90
เฉลี่ย	29.31		-10.07		18.00	

ตารางภาคผนวกที่ ก.4 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 1

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	14.833	12.852	14.736	14.140
2	13.344	11.645	12.603	12.531
3	13.521	12.552	13.785	13.286
4	13.652	11.528	12.962	12.714
5	12.253	10.996	12.854	12.034
เฉลี่ยทั้งหมด	12.941			

ตารางภาคผนวกที่ ก.5 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 2

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	27.95	29.82	-11.47	-12.32	22.09	23.78
	29.26	28.63	-10.62	-10.60	19.87	21.46
	27.50	28.08	-10.57	-11.42	21.68	21.12
	29.50	27.78	-11.57	-11.39	18.57	21.84
	29.18	26.68	-10.49	-11.91	19.60	23.78
	27.38	27.56	-9.17	-11.52	19.69	22.61
	28.29	27.15	-10.36	-9.67	19.03	20.65
	29.60	26.04	-9.35	-8.70	19.51	19.91
	29.19	28.21	-6.27	-8.92	15.93	19.87
เฉลี่ย	28.21		-10.35		20.61	

ตารางภาคผนวกที่ ก.5 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 2 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	26.53	29.50	-9.55	-10.34	16.40	18.76
	29.89	28.00	-10.80	-10.38	17.93	17.30
	28.83	29.61	-10.28	-9.03	25.26	16.07
	29.62	27.55	-9.02	-9.30	16.05	16.93
	28.54	27.37	-8.53	-9.89	15.94	17.53
	27.53	28.27	-9.32	-10.00	18.64	16.22
	28.30	26.75	-9.45	-9.52	14.80	17.99
	27.08	27.57	-9.42	-9.00	18.54	17.49
	26.95	27.14	-8.79	-8.41	16.27	15.74
เฉลี่ย	28.06		-9.50		17.44	
3	29.57	29.62	-9.44	-5.55	17.65	22.52
	27.11	30.06	-9.75	-5.86	19.65	17.67
	28.68	27.43	-3.12	-9.67	15.81	20.90
	28.43	28.66	-10.55	-9.99	19.97	23.07
	28.78	29.01	-9.79	-4.67	20.48	15.04
	27.83	27.59	-6.86	-10.11	16.28	23.33
	28.06	35.61	-6.70	-10.17	16.50	19.49
	28.01	28.50	-7.60	-10.46	17.59	21.50
	28.25	27.75	-7.48	-7.21	16.37	16.51
เฉลี่ย	28.83		-8.05		18.91	

ตารางภาคผนวกที่ ก.5 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 2 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	27.18	27.69	-10.18	-12.06	20.58	25.09
	29.28	27.14	-10.83	-11.18	19.48	22.97
	27.78	29.20	-9.84	-10.11	20.20	18.96
	27.69	27.60	-10.37	-11.84	20.02	26.08
	26.67	29.61	-10.17	-9.61	22.91	19.30
	27.68	27.26	-10.06	-9.87	18.10	21.02
	26.83	27.60	-10.69	-12.44	23.16	25.77
	28.11	28.36	-9.92	-7.66	20.79	18.50
	29.23	28.59	-9.94	-9.97	17.24	21.57
เฉลี่ย	27.97		-10.37		21.21	
5	29.97	29.22	-5.42	-9.32	15.43	19.97
	28.55	28.07	-8.51	-8.08	20.54	16.12
	29.47	28.61	-8.55	-5.06	20.39	15.91
	27.05	26.38	-5.38	-7.96	15.89	21.60
	27.54	27.63	-6.77	-9.86	16.80	19.18
	27.55	27.87	-6.94	-7.84	18.88	17.91
	27.89	28.60	-6.03	-5.50	15.56	17.64
	28.79	29.46	-5.40	-5.11	12.37	12.63
	27.35	27.80	-6.76	-5.30	17.14	15.43
เฉลี่ย	28.21		-6.88		17.19	

ตารางภาคผนวกที่ ก.6 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 2

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	12.459	12.068	12.702	12.410
2	12.625	11.157	12.209	11.997
3	10.122	10.923	10.269	10.438
4	9.526	9.256	10.302	9.695
5	9.859	9.223	10.369	9.817
เฉลี่ยทั้งหมด	10.871			

ตารางภาคผนวกที่ ก.7 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 3

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	26.37	26.84	-8.47	-9.38	25.91	23.65
	26.76	26.62	-8.13	-5.82	22.87	22.21
	27.92	27.73	-8.04	-9.15	26.87	20.94
	26.54	30.95	-7.57	-7.85	23.23	21.21
	27.47	26.65	-8.60	-7.94	22.03	20.54
	32.72	26.97	-8.52	-7.16	21.51	19.86
	28.28	29.88	-7.51	-8.13	20.38	19.56
	27.13	27.89	-7.22	-8.23	21.55	25.19
	27.00	26.64	-7.91	-7.10	22.94	21.77
เฉลี่ย	27.80		-7.93		22.35	

ตารางภาคผนวกที่ ก.7 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 3 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	26.36	26.50	-7.81	-8.33	21.52	20.85
	26.46	27.19	-7.97	-7.86	18.61	18.55
	27.67	27.36	-7.65	-8.54	14.41	20.58
	26.86	28.22	-8.84	-8.72	16.68	15.02
	27.43	27.53	-8.78	-7.26	15.30	17.45
	28.38	26.86	-7.71	-7.44	15.50	17.05
	27.42	27.72	-8.46	-7.00	14.95	13.37
	28.42	28.44	-6.83	-8.42	12.24	15.60
	28.47	20.46	-8.00	-7.53	16.10	12.12
เฉลี่ย	27.10		-7.95		16.44	
3	28.80	29.50	-9.21	-6.56	24.67	24.11
	27.82	30.66	-8.34	-8.41	25.11	26.00
	27.22	29.12	-9.27	-8.22	28.63	18.69
	28.99	29.96	-6.74	-6.04	18.97	23.31
	27.90	30.33	-8.71	-6.54	22.88	23.28
	28.39	28.95	-6.93	-5.58	18.27	16.16
	28.36	27.52	-8.23	-5.64	21.57	14.05
	28.92	28.53	-8.47	-5.30	24.17	19.68
	26.90	29.30	-8.97	-6.52	19.97	18.27
เฉลี่ย	28.73		-7.43		21.54	

ตารางภาคผนวกที่ ก.7 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 3 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	27.39	28.28	-8.62	-8.38	26.07	29.43
	26.61	28.73	-7.52	-8.12	24.54	27.03
	28.76	27.16	-8.24	-9.22	28.44	25.09
	27.55	28.08	-8.08	-7.98	19.38	22.03
	27.13	27.35	-5.15	-6.57	18.82	20.64
	27.05	27.08	-5.25	-8.61	19.21	17.83
	28.57	27.41	-5.37	-7.99	13.66	18.37
	28.37	27.34	-7.23	-8.63	17.29	16.53
	28.75	27.23	-7.50	-8.37	18.94	17.94
เฉลี่ย	27.71		-7.60		21.18	
5	28.16	28.18	-6.65	-6.92	19.47	15.28
	28.48	27.54	-5.68	-7.68	18.94	18.64
	27.78	28.57	-5.97	-9.23	17.29	17.24
	27.86	27.34	-5.21	-7.72	22.75	19.97
	27.86	27.29	-7.92	-8.53	21.71	22.43
	27.00	27.27	-5.35	-8.23	21.08	20.62
	28.15	28.7	-7.53	-7.43	16.60	21.67
	30.60	26.97	-7.34	-8.29	17.00	21.04
	28.24	27.42	-9.28	-7.81	19.99	19.45
เฉลี่ย	27.97		-7.38		19.51	

ตารางภาคผนวกที่ ก.8 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 3

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	8.583	9.731	8.296	8.870
2	5.084	3.069	3.788	3.980
3	6.567	5.015	6.815	6.132
4	5.615	6.267	3.599	5.160
5	4.258	3.056	4.856	4.057
เฉลี่ยทั้งหมด	5.640			

ตารางภาคผนวกที่ ก.9 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 4

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	27.61	28.00	-7.47	-2.34	14.90	9.90
	28.04	28.11	-5.37	-1.74	13.73	8.45
	27.93	28.14	-4.40	-4.04	20.52	11.55
	28.22	27.95	-7.09	-2.04	14.80	9.29
	27.38	28.11	-6.63	-6.76	15.91	14.40
	27.70	27.52	-6.40	-5.05	16.79	15.01
	27.69	27.04	-6.40	-3.40	17.10	12.14
	27.37	27.75	-5.33	-1.79	18.90	12.80
	26.70	26.75	-3.52	-3.07	14.27	15.00
เฉลี่ย	27.64		-4.60		14.19	

ตารางภาคผนวกที่ ก.9 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 4 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	27.59	26.61	-4.96	-0.63	20.57	15.53
	27.87	27.10	-5.02	2.30	23.56	15.96
	26.90	26.83	-6.25	-1.71	16.38	17.97
	28.31	29.04	-5.18	0.63	18.72	12.39
	28.14	29.27	-5.99	-0.49	19.30	13.55
	27.11	29.07	-8.62	-2.83	21.44	14.81
	27.45	28.31	-8.45	-0.54	20.39	10.89
	26.93	26.60	-5.88	-2.50	18.00	12.74
	27.92	26.62	-9.36	-1.30	21.43	21.25
เฉลี่ย	27.65		-3.71		17.49	
3	26.58	27.48	-3.10	0.92	14.97	11.91
	27.61	27.02	1.13	-3.54	12.77	17.01
	25.87	26.51	1.90	-2.44	12.21	13.19
	28.80	26.90	-2.95	-1.03	16.92	16.78
	28.91	27.11	-1.91	-2.94	14.69	15.50
	28.30	27.44	-1.05	-3.59	9.70	18.00
	26.94	27.51	-3.64	-3.27	17.15	17.31
	27.63	27.77	-5.39	-3.95	16.10	17.16
	27.08	25.81	-0.40	-3.59	6.67	18.84
เฉลี่ย	27.29		-2.16		14.83	

ตารางภาคผนวกที่ ก.9 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 4 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	28.12	27.27	2.66	-1.83	17.24	16.67
	26.88	28.33	0.73	-4.30	19.13	15.17
	27.22	26.96	-0.67	-2.59	21.09	17.18
	27.07	27.26	-2.61	-4.27	16.74	16.66
	27.47	27.01	-1.44	-4.05	22.25	16.71
	27.53	27.50	-1.37	3.12	18.93	17.04
	27.71	27.27	-7.02	-0.50	19.40	11.29
	26.32	27.55	-5.37	-6.08	20.42	15.67
	27.14	27.02	-3.94	-5.10	15.12	15.51
เฉลี่ย	27.31		-2.48		17.35	
5	23.41	28.80	-3.53	-0.22	19.97	10.90
	27.81	28.36	0.14	-1.19	17.24	18.16
	27.14	25.49	-0.09	-2.82	11.47	15.83
	27.70	27.87	-2.79	0.06	17.72	15.15
	27.17	29.76	-1.29	-1.50	13.99	23.44
	26.62	27.40	-0.39	-1.71	15.12	17.87
	26.18	27.74	-5.61	-0.28	17.56	11.89
	27.89	20.18	-1.97	-4.55	14.56	22.44
	27.65	28.93	-2.97	-5.28	14.11	17.54
เฉลี่ย	27.01		-2.00		16.39	

ตารางภาคผนวกที่ ก.10 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 4

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	1.998	1.804	1.551	1.784
2	1.759	1.536	1.138	1.478
3	1.614	1.835	1.665	1.705
4	1.593	1.632	1.586	1.604
5	1.434	1.376	1.439	1.416
เฉลี่ยทั้งหมด	1.597			

ตารางภาคผนวกที่ ก.11 ค่าสีของเปลือก $L^*a^*b^*$ ของผลอะโวคาโด วันที่ 5

ลูกที่	L^*		a^*		b^*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	27.10	22.96	0.05	-5.42	7.99	13.42
	27.02	22.38	-1.26	-1.03	8.22	8.53
	26.53	25.01	-5.07	-0.48	12.38	7.10
	25.07	27.03	1.03	-3.80	9.87	16.21
	25.13	28.50	-0.65	0.52	10.66	8.33
	26.27	28.27	-3.16	-0.29	13.01	8.61
	25.36	29.88	-0.27	-0.36	10.65	16.67
	24.83	28.84	0.23	0.92	9.64	12.27
	25.37	28.31	-1.25	-0.16	13.39	9.49
เฉลี่ย	26.33		-1.14		10.91	

ตารางภาคผนวกที่ ก.11 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 5 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	30.44	29.43	1.87	-1.60	17.90	17.62
	25.38	29.84	-1.13	0.15	15.59	12.46
	24.68	23.25	-1.06	0.91	16.14	15.64
	26.48	26.95	3.62	0.00	9.42	12.67
	25.99	26.03	1.11	3.57	21.13	9.80
	24.26	27.93	-0.43	1.19	11.17	10.51
	25.29	24.90	-0.22	0.58	8.98	20.78
	28.14	27.51	1.31	2.69	8.70	13.41
	28.94	25.49	1.86	1.77	15.03	13.77
เฉลี่ย	26.72		0.90		13.93	
3	25.31	25.94	-0.77	-2.25	14.84	10.67
	26.74	25.76	-1.67	-0.69	8.33	11.67
	27.33	27.02	-2.14	0.02	10.15	13.04
	28.45	28.75	-3.39	-2.45	13.72	13.81
	27.03	28.72	-3.74	-2.98	15.42	15.98
	28.70	28.94	-4.13	-3.55	14.50	15.78
	28.15	28.86	-3.63	-2.80	12.49	13.97
	24.93	25.36	-4.33	-2.28	17.10	11.63
	22.50	23.49	-3.50	-3.88	12.87	15.04
เฉลี่ย	26.78		-2.68		13.39	

ตารางภาคผนวกที่ ก.11 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 5 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	26.93	28.04	2.09	1.81	4.94	9.61
	26.95	26.18	0.71	2.42	10.76	8.30
	22.78	24.66	1.67	0.08	13.08	6.82
	24.80	28.75	1.47	3.49	5.84	6.77
	28.56	28.82	0.56	2.36	8.69	5.14
	27.55	27.59	1.43	0.12	10.20	6.73
	28.17	28.70	0.02	1.32	8.74	5.44
	27.35	25.92	-0.19	3.06	9.17	9.02
	20.90	22.75	0.30	-1.24	7.03	7.34
เฉลี่ย	26.41		1.19		7.98	
5	28.19	28.11	-0.56	-2.13	13.81	10.42
	28.22	27.98	-4.00	-2.08	16.35	10.45
	28.76	26.60	-3.88	-1.87	14.77	8.55
	24.98	25.90	-0.79	-3.98	22.80	15.63
	28.45	27.49	-5.00	-3.80	17.95	10.67
	27.68	28.22	-2.61	-3.26	14.30	15.28
	27.30	27.44	-3.90	-5.90	14.67	17.80
	28.53	27.08	-5.93	-5.80	15.38	13.82
	26.53	27.82	-4.88	-5.52	15.93	14.42
เฉลี่ย	27.52		-3.66		14.61	

ตารางภาคผนวกที่ ก.12 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 5

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	0.71	0.659	0.752	0.707
2	0.825	0.752	0.805	0.794
3	0.692	0.525	0.713	0.643
4	0.708	0.592	0.695	0.665
5	0.863	0.685	0.796	0.781
เฉลี่ยทั้งหมด	0.718			

ตารางภาคผนวกที่ ก.13 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 6

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	26.75	27.25	-2.24	-1.89	9.41	7.36
	24.23	26.96	-1.79	-2.62	14.76	10.12
	26.50	26.95	-0.62	-1.05	8.01	9.21
	26.00	27.06	0.79	0.73	15.03	9.51
	24.96	27.60	-1.31	-1.18	14.58	8.53
	22.40	25.61	0.05	0.22	16.35	11.46
	23.23	27.06	-0.63	-0.74	17.83	9.45
	23.46	27.33	-0.56	-0.20	19.14	8.12
	26.86	23.52	-1.36	-0.82	13.36	17.63
เฉลี่ย	25.76		-0.85		12.15	

ตารางภาคผนวกที่ ก.13 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 6 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	23.47	26.36	-0.87	-1.67	14.32	11.79
	24.59	24.89	-0.56	-0.84	14.04	12.54
	25.42	23.39	-1.13	-0.82	12.69	14.63
	26.93	26.84	-1.69	-1.41	14.54	10.14
	25.69	24.95	-1.00	-1.54	14.19	15.00
	26.23	22.98	-1.56	-1.64	11.87	16.95
	26.24	27.34	-0.17	0.15	14.30	9.40
	27.21	23.93	-0.89	-0.45	10.25	16.79
	27.13	25.17	-0.73	-0.72	10.20	17.30
เฉลี่ย	25.49		-0.97		13.39	
3	22.13	26.75	-1.59	-1.03	17.20	8.90
	27.20	25.63	-0.56	-2.13	9.04	5.24
	24.66	24.68	-1.50	-1.11	11.92	8.26
	25.76	26.91	-0.82	0.66	17.57	7.17
	25.96	25.18	-1.90	-1.09	10.15	12.64
	25.43	25.32	-1.92	-0.71	12.69	16.09
	25.90	25.25	-1.83	-0.44	18.95	11.12
	20.51	23.70	-1.22	-0.57	20.48	15.20
	23.57	20.92	-1.61	-0.48	16.94	20.09
เฉลี่ย	24.75		-1.10		13.31	

ตารางภาคผนวกที่ ก.13 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 6 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	26.48	22.53	-2.22	-2.24	5.92	14.16
	26.82	26.39	-1.74	-0.47	6.76	8.50
	25.10	26.29	-0.41	-1.17	12.09	11.93
	21.10	23.94	-1.95	-1.22	17.10	14.54
	27.15	25.66	-1.50	-1.28	9.08	10.24
	25.90	25.65	-2.57	-1.19	11.58	13.08
	25.03	26.43	0.89	-0.54	15.81	11.72
	27.62	23.61	1.29	0.23	12.54	18.52
	26.68	24.96	1.22	-0.39	12.90	16.97
เฉลี่ย	25.41		-0.85		12.41	
5	21.25	18.06	-1.62	-1.44	17.90	21.43
	26.67	26.33	-1.50	-1.67	8.63	23.90
	26.46	26.10	-1.58	-1.07	8.81	8.83
	25.81	26.07	-1.15	-0.83	23.00	19.18
	25.25	20.14	-1.55	-1.53	12.21	19.37
	26.69	20.44	-0.74	-2.01	9.05	21.46
	25.04	26.95	0.20	0.33	22.44	12.23
	25.29	24.33	-0.43	-0.02	14.31	16.60
	27.06	21.23	-1.22	-1.49	8.96	19.38
เฉลี่ย	24.40		-1.07		15.98	

ตารางภาคผนวกที่ ก.14 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 6

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	0.485	0.405	0.465	0.452
2	0.523	0.436	0.493	0.484
3	0.385	0.254	0.332	0.324
4	0.463	0.422	0.463	0.449
5	0.685	0.535	0.569	0.596
เฉลี่ยทั้งหมด	0.461			

ตารางภาคผนวกที่ ก.15 ค่าสีของเปลือก $L^*a^*b^*$ ของผลอะโวคาโด วันที่ 7

ลูกที่	L^*		a^*		b^*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
1	26.75	27.25	-2.24	-1.89	14.14	13.35
	24.23	26.96	-1.79	-2.62	14.56	11.26
	26.50	26.95	-2.62	-2.05	10.01	11.21
	26.00	27.06	-2.79	-2.73	15.03	10.51
	24.96	27.60	-3.31	-1.18	13.52	9.12
	22.40	25.61	-4.05	-3.22	16.52	12.16
	23.23	27.06	-4.63	-3.74	17.75	10.95
	23.46	27.33	-4.56	-2.20	19.14	9.65
	26.86	23.52	-4.36	-3.82	13.36	15.63
เฉลี่ย	25.76		-2.99		13.21	

ตารางภาคผนวกที่ ก.15 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 7 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
2	23.47	26.36	-3.87	-1.67	14.32	11.79
	24.59	24.89	-3.56	-3.84	14.04	12.54
	25.42	23.39	-3.13	-3.82	12.69	14.63
	26.93	26.84	-2.69	-3.41	13.52	10.20
	25.69	24.95	-3.00	-3.54	13.25	14.95
	26.23	22.98	-2.56	-4.64	11.75	15.95
	26.24	27.34	-3.17	-2.17	15.05	9.40
	27.21	23.93	-2.89	-4.45	11.25	16.79
	27.13	25.17	-1.73	-3.72	10.20	17.30
เฉลี่ย	25.49		-3.21		13.31	
3	22.13	27.13	-2.59	-1.03	16.96	10.90
	27.20	26.63	-0.56	-2.13	10.00	9.54
	24.66	26.68	-2.50	-1.11	11.92	10.26
	20.76	26.91	-2.82	-2.66	17.57	7.17
	25.96	25.18	-1.90	-3.09	10.15	12.60
	25.43	22.30	-1.92	-2.71	12.69	15.96
	22.92	26.25	-3.83	-3.44	18.95	11.12
	20.20	23.70	-3.22	-3.57	20.35	15.20
	23.57	19.92	-3.61	-3.48	16.94	20.09
เฉลี่ย	24.31		-2.57		13.80	

ตารางภาคผนวกที่ ก.15 ค่าสีของเปลือก L*a*b* ของผลอะโวคาโด วันที่ 7 (ต่อ)

ลูกที่	L*		a*		b*	
	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2	ด้านที่ 1	ด้านที่ 2
4	26.50	22.53	-3.22	-4.24	13.92	14.16
	26.82	26.39	-1.74	-2.47	14.76	12.50
	25.08	26.29	-3.41	-1.17	12.09	11.93
	21.08	23.94	-4.95	-4.22	17.10	14.54
	27.10	25.59	-2.50	-4.28	10.05	10.24
	25.92	25.74	-2.57	-4.19	11.58	13.08
	25.03	26.43	-3.89	-4.54	15.81	11.72
	27.62	23.61	-2.29	-5.00	12.54	18.52
	26.71	24.96	-5.22	-4.39	12.90	16.97
เฉลี่ย	25.41		-3.57		13.58	
5	21.25	18.06	-2.62	-2.44	17.90	21.43
	26.63	16.33	-1.50	-1.67	9.63	23.90
	26.46	26.06	-1.58	-2.07	9.68	9.88
	17.81	20.07	-3.15	-2.83	23.00	19.18
	25.25	20.14	-2.55	-3.53	12.21	19.37
	26.96	20.44	-0.74	-2.01	10.05	21.46
	20.40	26.83	-2.57	0.33	22.44	12.23
	24.29	24.33	-2.43	-0.02	14.31	16.60
	27.06	21.03	-1.22	-4.49	10.96	19.38
เฉลี่ย	22.74		-2.06		16.31	

ตารางภาคผนวกที่ ก.16 ค่าความแน่นเนื้อของผลอะโวคาโด วันที่ 7

ลูกที่	ค่าความแน่นเนื้อ (N)			ค่าเฉลี่ย แต่ละลูก
	บน	กลาง	ล่าง	
1	0.406	0.261	0.261	0.309
2	0.359	0.228	0.338	0.308
3	0.317	0.192	0.262	0.257
4	0.156	0.368	0.368	0.297
5	0.357	0.397	0.342	0.365
เฉลี่ยทั้งหมด	0.307			




ภาคผนวก ข
ตัวอย่างและ Code ของโปรแกรม




ขั้นตอนและโปรแกรมของการประมวลผลภาพของผลอะโวคาโด

1. ถ่ายภาพของผลอะโวคาโดด้วยกล้องจากสมาร์ทโฟน (iPhone 13 Pro max) ใน Studio Tent Box โดยจะถ่ายในมุมมองด้านบน (Top view) ดังรูปที่ 1





รูปที่ 1 ภาพถ่ายที่ได้จากสมาร์ทโฟน

2. ทำการเชื่อมต่อสมาร์ทโฟนกับแล็ปท็อป และทำการโหลดรูปจากสมาร์ทโฟนลงในโฟลเดอร์ที่เตรียมไว้ในแล็ปท็อป เพื่อใช้ในการประมวลผลภาพ ดังรูปที่ 2



รูปที่ 2 ภาพถ่ายที่ได้จากสมาร์ทโฟน

3. หลังที่ทำการจัดภาพลงในโฟลเดอร์ที่กำหนดแล้ว จะทำการอัปโหลดโฟลเดอร์ลงใน Google Drive เพื่อที่จะทำการ Run โปรแกรมการประมวลผลภาพใน Google Colab
- 4.เปิด Google Colab > File > Upload Notebook เพื่อทำการอัปโหลดโปรแกรม



5. หลังจากการอัปโหลดโปรแกรมที่ได้เขียนด้วยภาษา Python แล้วจะทำการดึงข้อมูลภาพที่อยู่ในโฟลเดอร์ที่ได้ทำการอัปโหลด

```
from google.colab import drive
import os
drive.mount('/content/gdrive', force_remount = True)

os.chdir("/content/gdrive/My Drive/Avocado Model")
```

Mounted at /content/gdrive

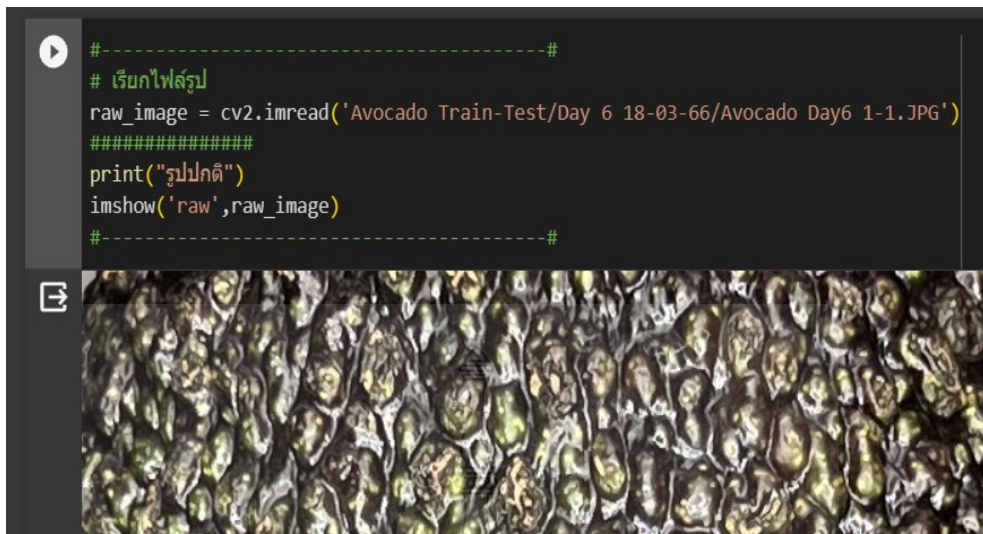
6. Import คำสั่งที่จะใช้ในการประมวลผลภาพ

```
import os
import cv2
import math
import time
import imutils
import argparse
import numpy as np
import pandas as pd
```

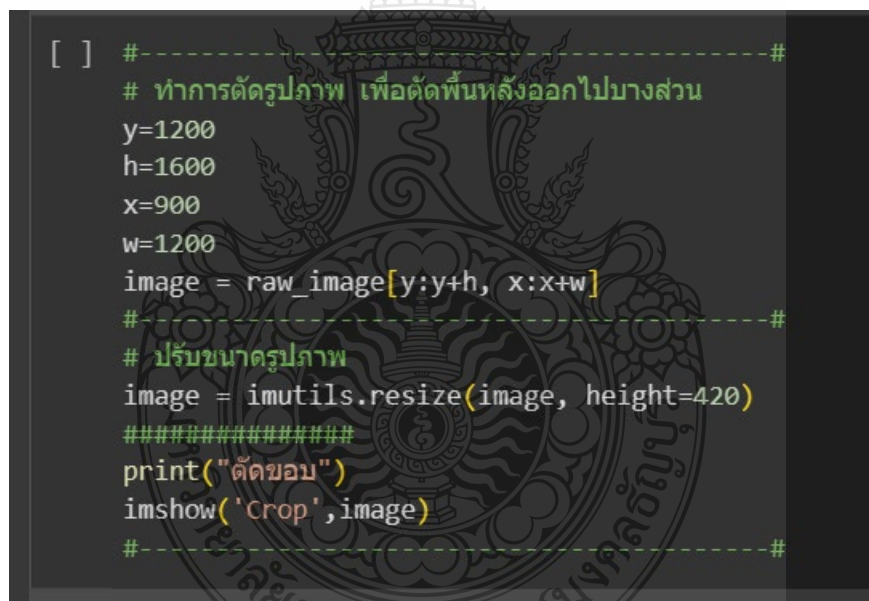
7. Import ภาพจากโฟลเดอร์และให้ทำการโชว์ภาพที่ได้


```
[ ] import base64 ##
from IPython.display import display, HTML ##
#Show image in jupyter
def imshow(name, imageArray):
    _, png = cv2.imencode('.png', imageArray)
    encoded = base64.b64encode(png)
    return HTML(data=''.format(name, encoded.decode('ascii')))
```

#####



8. ทำการตัดภาพ (Crop) เพื่อลดขนาดและตัดพื้นที่บางส่วนของภาพโดยคงอัตราส่วนของภาพเอาไว้






8. หลังจากนั้นปรับปรุงภาพโดย เริ่มจากทำการปรับขนาดของภาพแล้วจะทำการปรับค่าแสงของรูป

```
#-----#
# ปรับค่าแสงในรูป
alpha = 1.6 # Contrast control
beta = 0 # Brightness control
a_img = cv2.convertScaleAbs(image, alpha=alpha, beta=beta)
#####
print("ปรับแสงในรูป")
imshow('Adjust',a_img)
#-----#
```




9. และทำการลบสัญญาณรบกวน (Noise)

```
#-----#  
# เบลอรูปภาพ เพื่อนำไปตัดขอบ  
b_img1 = cv2.fastNlMeansDenoisingColored(a_img, None, 40, 40, 40, 79)  
#####  
print("ลบ noise และ เบลอรูป")  
imshow('Denoise', b_img1)  
#-----#
```




10. ทำการเบลอภาพ

```
#-----#
# เบลอรูปภาพ เพื่อนำไปตัดขอบ
b_img2 = cv2.bilateralFilter(b_img1,35,100,100)
#####
print("ลบ noise และ เบลอรูป")
imshow('Denoise',b_img2)
#-----#
```




11. หลังจากทำการปรับปรุงภาพแล้วจะเริ่มทำการ Threshold โดยเริ่มจากการแปลงภาพสี RGB เป็นภาพสีเทาหรือ Grayscale

```
#-----#
# เปลี่ยนสีภาพเป็นสีเทา
gray = cv2.cvtColor(b_img2, cv2.COLOR_BGR2GRAY)
#-----#
#####
print("เปลี่ยนสีภาพเป็นสีเทา")
imshow('gray',gray)
#-----#
```



12. หลังจากแปลงภาพเป็น Gray Scale แล้วจะทำการสร้าง Mask เพื่อกำหนดพื้นที่หลังที่จะทำการแยกออกจากผลอะไวคาโด

```
# สร้าง mask สำหรับ ลบ พื้นหลังของรูป
mask = cv2.threshold(gray, 0, 255, cv2.THRESH_BINARY_INV + cv2.THRESH_OTSU)[1]
#-----#
#####
print("สร้าง mask สำหรับ ลบ พื้นหลังของรูป")
imshow('mask',mask)
#-----#
```



12. ทำการรวมภาพสี RGB กับภาพที่ทำการ Mask ที่ทำการลบพื้นหลังเอาไว้

```
# ลบพื้นหลัง
rm_bg = cv2.bitwise_and(image, image, mask=mask)
#-----#
# เปลี่ยนสีพื้นหลังเป็นสีดำ
rm_bg[mask==0] = [0,0,0]
#####
print("ลบพื้นหลังของรูป")
imshow('Remove bg',rm_bg)
#-----#
```



13. หลังจากได้ภาพผลอะโวคาโดที่แยกออกจากพื้นหลังแล้วจะทำการหาตำแหน่งขอบของอะโวคาโด
เนื่องด้วยรูปร่างของผลอะโวคาโดมีขนาดไม่เท่ากัน

```
#-----#  
# หาตำแหน่งของขอบผล avocado  
rows, cols = mask.shape  
top = 0  
bottom = 0  
left = 0  
right = 0
```

```

for i in range(rows):
    pix_t = np.sum(mask[i])
    pix_b = np.sum(mask[rows-1-i])

    if top == 0 and pix_t != 0 :
        top = i
    elif bottom == 0 and pix_b != 0 :
        bottom = rows-1-i
    elif top != 0 and bottom != 0 :
        break
for i in range(cols):
    pix_l = np.sum(mask[:, i])
    pix_r = np.sum(mask[:, cols-1-i])


    if left == 0 and pix_l != 0 :
        left = i
    elif right == 0 and pix_r != 0 :
        right = cols-1-i
    elif right != 0 and left != 0 :
        break

```

```


#-----#
# ตัดภาพ ให้เหลือแต่ส่วน avocado และปรับขนาดรูป
y=top+10
h=bottom-10
x=left+10
w=right-10
c_image = rm_bg[y:h, x:w]
#####
print("ตัดเฉพาะผล avocado")
imshow('Crop avo',c_image)
#-----#

```



14. หลังจากทำการ Threshold และตัดขอบแล้วจะทำการแปลงภาพจากภาพสี RGB เป็นภาพ L*a*b*

```
#-----#
# แปลงสีโทนภาพให้เป็น LAB
lab_re = cv2.cvtColor(c_image, cv2.COLOR_BGR2LAB)
#####
print("แปลงเป็นสี LAB")
imshow('LAB avo',lab_re)
#-----#
```



15. หลังจากทำการแปลงเป็นภาพสี $L^*a^*b^*$ แล้วจะทำการแยกองค์ประกอบของแต่ละค่าสี

```
#-----#
# แยก channel ของสีออกเป็น L , A , B
L_img,A_img,B_img = cv2.split(lab_re)
#-----#
# ทำการหาค่าเฉลี่ยของสีในแต่ละ channel โดยจะแบ่งเป็น 3 โชน ต่อ 1 รูป
# เรียกขนาดของรูป ออกมาใส่ในตัวแปร
rows, cols , __ = lab_re.shape
###
l_arr = []
a_arr = []
b_arr = []
l = []
a = []
b = []
ix = 0
# ใช้คำสั่ง for loop เพื่อทำการหาค่าเฉลี่ยของสีในแต่ละโชน และสั่งเก็บไว้ใน array ของแต่ละ channel
```

```

for i in range(rows):
    #####
    ix = ix+1
    # ลบค่าสีพื้นหลังออกไป
    l_buff = np.delete(L_img[i], np.where(L_img[i] == 0))
    a_buff = np.delete(A_img[i], np.where(A_img[i] == 128))
    b_buff = np.delete(B_img[i], np.where(B_img[i] == 128))
    #####
    # ลบค่าสีพื้นหลังออกไป หาเฉลี่ยของสี
    l.append(np.average(np.nan_to_num(l_buff, nan=np.nanmean(l_buff))))
    a.append(np.average(np.nan_to_num(a_buff, nan=np.nanmean(a_buff))))
    b.append(np.average(np.nan_to_num(b_buff, nan=np.nanmean(b_buff))))
    #####
    if ix == int(rows/3):
        # บันทึกค่าลงใน array
        l_arr.append(np.average(l))
        a_arr.append(np.average(a))
        b_arr.append(np.average(b))
        l = []
        a = []
        b = []
        ix = 0
    # รวมค่าที่บันทึกเอาไว้ด้วยกัน
    lab_data1 = l_arr + a_arr + b_arr
    #####
    print("ค่าสี LAB สามโซน")
    print(lab_data1)
    #-----#

```

16. หลังจากทำการแยกค่าสีแล้วจะทำการสร้างตาราง Data Frame ขึ้นมาเพื่อที่จะนำค่าสีที่ได้นี้มาใช้ในการทำนายค่าความแน่นอนของโมเดล

```

#-----#
# สร้าง dataframe ขึ้นมา
col_list = ['l_1','l_2',
            'a_1','a_2',
            'b_1','b_2']
df = pd.DataFrame(columns = col_list)
#-----#
# หาค่า LAB ของรูปทั้ง 2 ด้าน
lab_data1 = all_process('Avocado Train-Test/Day 6 18-03-66/Avocado Day6 1-1.JPG')
lab_data2 = all_process('Avocado Train-Test/Day 6 18-03-66/Avocado Day6 1-2.JPG')
#-----#
# ในค่าที่ได้จากฟังก์ชัน มาใส่ dataframe
df.loc[len(df)] = [lab_data1[0],lab_data2[0],lab_data1[3],lab_data2[3],lab_data1[6],lab_data2[6]]
df.loc[len(df)] = [lab_data1[1],lab_data2[1],lab_data1[4],lab_data2[4],lab_data1[7],lab_data2[7]]
df.loc[len(df)] = [lab_data1[2],lab_data2[2],lab_data1[5],lab_data2[5],lab_data1[8],lab_data2[8]]
#-----#
#####
print("ชุดที่ 1 ค่าสี 2 ด้าน แบ่ง 3 โซน")
print(df)
#-----#

```

➡ ชุดที่ 1 ค่าสี 2 ด้าน แบ่ง 3 โชน

	l_1	l_2	a_1	a_2	b_1	b_2
0	82.045851	82.010413	113.493627	101.917279	130.173488	131.360482
1	92.704416	88.818980	115.037985	131.511682	128.211190	130.896175
2	103.439006	95.383088	131.983547	131.719041	127.279209	134.887362

```
#-----#
# สร้าง dataframe ขึ้นมา
col_list = ['l_1','l_2',
            'a_1','a_2',
            'b_1','b_2']
df = pd.DataFrame(columns = col_list)
#-----#
l_1x = (lab_data1[0] + lab_data1[1] + lab_data1[2])/3
l_2x = (lab_data2[0] + lab_data2[1] + lab_data2[2])/3
#-----#
a_1x = (lab_data1[3] + lab_data1[4] + lab_data1[5])/3
a_2x = (lab_data1[3] + lab_data1[4] + lab_data1[5])/3
#-----#
b_1x = (lab_data1[6] + lab_data1[7] + lab_data1[8])/3
b_2x = (lab_data1[6] + lab_data1[7] + lab_data1[8])/3
#-----#
df.loc[len(df)] = [l_1x , l_2x , a_1x , a_2x , b_1x , b_2x]
#-----#
# สร้าง ตารางที่นำค่าสี ทั้ง 2 ด้าน มาค่าเฉลี่ย
df['l'] = (df['l_1'] + df['l_2'])/2
df['a'] = (df['a_1'] + df['a_2'])/2
df['b'] = (df['b_1'] + df['b_2'])/2
df_modify = df[['l', 'a', 'b']]
#####
print("ชุดที่ 2 ค่าเฉลี่ยสี 2 ด้าน ไม่มีแบ่งโชน")
print(df_modify)
#-----#
```

➡ ชุดที่ 2 ค่าเฉลี่ยสี 2 ด้าน ไม่มีแบ่งโชน

	l	a	b
0	90.733625	120.17172	128.554629

ขั้นตอนการทำงานของแบบจำลองโมเดลและการทดสอบประสิทธิภาพ

1. Import Library ที่จำเป็นในการใช้งานสำหรับการทดสอบโมเดลแบบจำลอง คือโมเดล SVR, MLP และ KNN จาก Library ของ scikit-learn (sklearn.model) และจะใช้ GridSearchCV ในการตั้งค่า Parameter ที่ดีที่สุดของแต่ละโมเดล โดยกำหนดตามบทที่ 3 ซึ่งในการทดสอบโมเดลจะใช้ค่า R^2 , RMSE, MAE ในการให้คะแนนของแต่ละโมเดล

```
from google.colab import drive
import os
drive.mount('/content/gdrive', force_remount = True)

os.chdir("/content/gdrive/My Drive/Avocado Model")

Mounted at /content/gdrive

import pandas as pd
import numpy as np
import pickle
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
#####
from sklearn.model_selection import RandomizedSearchCV
from sklearn.model_selection import GridSearchCV
from sklearn.svm import SVR
from sklearn.neural_network import MLPRegressor
from sklearn.neighbors import KNeighborsRegressor
#####
from sklearn.metrics import r2_score
from sklearn.metrics import mean_squared_error
from sklearn.metrics import mean_absolute_error
```

2. ทำการเรียกไฟล์ข้อมูลสี่ที่เก็บมาจากกระบวนการประมวลผลภาพ (Image Processing)

```
# ข้อมูลสำหรับ Train
# เรียกข้อมูลจากไฟล์
df_train = pd.read_csv("avo_train.csv")
# สังเกตข้อมูล column แปล่าที่อาจจะติดมาจากการบันทึก
df_train = df_train.loc[:, ~df_train.columns.str.contains('^Unnamed')]
# แบ่งข้อมูลออกเป็น X และ y
df_train = df_train.drop(columns=['d'])
df_train = df_train.groupby(df_train.index // 3).mean()
df_train['l'] = (df_train['l_1'] + df_train['l_2'])/2
df_train['a'] = (df_train['a_1'] + df_train['a_2'])/2
df_train['b'] = (df_train['b_1'] + df_train['b_2'])/2
df_train_X = df_train[['l', 'a', 'b']]
df_train_y = np.squeeze(df_train[['f']])

# ข้อมูลสำหรับ Validate
df_valid = pd.read_csv("avo_test.csv")
df_valid = df_valid.loc[:, ~df_valid.columns.str.contains('^Unnamed')]
df_valid = df_valid.drop(columns=['d'])
df_valid = df_valid.groupby(df_valid.index // 3).mean()
df_valid['l'] = (df_valid['l_1'] + df_valid['l_2'])/2
df_valid['a'] = (df_valid['a_1'] + df_valid['a_2'])/2
df_valid['b'] = (df_valid['b_1'] + df_valid['b_2'])/2
val_x = df_valid[['l', 'a', 'b']]
val_y = np.squeeze(df_valid[['f']])
```

3. จัดแบ่งข้อมูล train ออกเป็น 3 กลุ่มตามอัตราส่วน train/test : 70/30 , 80/20 , 90/10

```
# 70 : 30
X70, X30, y70, y30 = train_test_split(df_train_X, df_train_y, train_size=0.70)
# 80 : 20
X80, X20, y80, y20 = train_test_split(df_train_X, df_train_y, train_size=0.80)
# 90 : 10
X90, X10, y90, y10 = train_test_split(df_train_X, df_train_y, train_size=0.90)
```

4. ทำการระบุการตั้งค่า Parameter ของแต่ละโมเดล

ระบุค่า parameter ที่จะนำมาจูนตัวโมเดล

```
svm_parameters = {  
    'gamma': ['scale', 'auto'],  
    'kernel': ['linear', 'poly', 'rbf', 'sigmoid']  
}  
mlp_parameters = {  
    'activation': ['identity', 'logistic', 'tanh', 'relu'],  
    'solver': ['lbfgs', 'sgd', 'adam'],  
    'learning_rate': ['constant', 'invscaling', 'adaptive'],  
    'max_iter': [200, 500, 1000, 1500, 2000, 2500, 3000, 4000],  
}  
knn_parameters = {  
    'n_neighbors': [3, 5, 7, 9],  
    'weights': ['uniform', 'distance'],  
}
```

ทำการระบุโมเดล และเครื่องมือที่ใช้จูนตัวโมเดล โดยมีโมเดล SVR, MLP และ KNN ทำการจูนด้วย GridsearchCV

```
[ ] # SVM  
svm_70 = GridSearchCV(SVR(), svm_parameters, n_jobs=-1)  
svm_70_scale = GridSearchCV(SVR(), svm_parameters, n_jobs=-1)  
svm_80 = GridSearchCV(SVR(), svm_parameters, n_jobs=-1)  
svm_80_scale = GridSearchCV(SVR(), svm_parameters, n_jobs=-1)  
svm_90 = GridSearchCV(SVR(), svm_parameters, n_jobs=-1)  
svm_90_scale = GridSearchCV(SVR(), svm_parameters, n_jobs=-1)  
# MLP  
mlp_70 = GridSearchCV(MLPRegressor(), mlp_parameters, n_jobs=-1)  
mlp_70_scale = GridSearchCV(MLPRegressor(), mlp_parameters, n_jobs=-1)  
mlp_80 = GridSearchCV(MLPRegressor(), mlp_parameters, n_jobs=-1)  
mlp_80_scale = GridSearchCV(MLPRegressor(), mlp_parameters, n_jobs=-1)  
mlp_90 = GridSearchCV(MLPRegressor(), mlp_parameters, n_jobs=-1)  
mlp_90_scale = GridSearchCV(MLPRegressor(), mlp_parameters, n_jobs=-1)  
# KNN  
knn_70 = GridSearchCV(KNeighborsRegressor(), knn_parameters, n_jobs=-1)  
knn_80 = GridSearchCV(KNeighborsRegressor(), knn_parameters, n_jobs=-1)  
knn_90 = GridSearchCV(KNeighborsRegressor(), knn_parameters, n_jobs=-1)  
knn_70_scale = GridSearchCV(KNeighborsRegressor(), knn_parameters, n_jobs=-1)  
knn_80_scale = GridSearchCV(KNeighborsRegressor(), knn_parameters, n_jobs=-1)  
knn_90_scale = GridSearchCV(KNeighborsRegressor(), knn_parameters, n_jobs=-1)
```

5. ทำการแสดงผลการทดสอบของแต่ละโมเดล

```
print("mlp Data:70 \n")

print("Test data")
y_pred = mlp_70.predict(X30)
y_true = y30.to_numpy()
print("score : " + str(mlp_70.score(X30,y30)))
print("r2 : " + str(r2_score(y_true, y_pred)))
print("rmse : " + str(mean_squared_error(y_true, y_pred)))
print("mae : " + str(mean_absolute_error(y_true, y_pred)))
print("Valid data")
y_pred = mlp_70.predict(val_X)
y_true = val_y.to_numpy()
print("score : " + str(mlp_70.score(val_X,val_y)))
print("r2 : " + str(r2_score(y_true, y_pred)))
print("rmse : " + str(mean_squared_error(y_true, y_pred)))
print("mae : " + str(mean_absolute_error(y_true, y_pred)))

print("=====")
```

```
print("mlp Data:80 \n")

print("Test data")
y_pred = mlp_80.predict(X20)
y_true = y20.to_numpy()
print("score : " + str(mlp_80.score(X20,y20)))
print("r2 : " + str(r2_score(y_true, y_pred)))
print("rmse : " + str(mean_squared_error(y_true, y_pred)))
print("mae : " + str(mean_absolute_error(y_true, y_pred)))
print("Valid data")
y_pred = mlp_80.predict(val_X)
y_true = val_y.to_numpy()
print("score : " + str(mlp_80.score(val_X,val_y)))
print("r2 : " + str(r2_score(y_true, y_pred)))
print("rmse : " + str(mean_squared_error(y_true, y_pred)))
print("mae : " + str(mean_absolute_error(y_true, y_pred)))

print("=====")
```

```

print("mlp Data:90 \n")

print("Test data")
y_pred = mlp_90.predict(X10)
y_true = y10.to_numpy()
print("score : " + str(mlp_90.score(X10,y10)))
print("r2 : " + str(r2_score(y_true, y_pred)))
print("rmse : " + str(mean_squared_error(y_true, y_pred)))
print("mae : " + str(mean_absolute_error(y_true, y_pred)))
print("Valid data")
y_pred = mlp_90.predict(val_X)
y_true = val_y.to_numpy()
print("score : " + str(mlp_90.score(val_X,val_y)))
print("r2 : " + str(r2_score(y_true, y_pred)))
print("rmse : " + str(mean_squared_error(y_true, y_pred)))
print("mae : " + str(mean_absolute_error(y_true, y_pred)))

print("=====")

```

6. ทำการบันทึกการทดสอบประสิทธิภาพที่ค่าที่ได้ของแต่ละโมเดล

mlp Data:70	mlp Data:80	mlp Data:90
Test data	Test data	Test data
score : 0.8819249198569692	score : 0.9875723189158451	score : 0.9900225022623058
r2 : 0.8819249198569692	r2 : 0.9875723189158451	r2 : 0.9900225022623058
rmse : 4.543760038760583	rmse : 0.4797116855378003	rmse : 0.34097948856103777
mae : 1.0741242002908349	mae : 0.4399186530287455	mae : 0.3212023874269585
Valid data	Valid data	Valid data
score : 0.8815670681903669	score : 0.8585272502827603	score : 0.9456597558255909
r2 : 0.8815670681903669	r2 : 0.8585272502827603	r2 : 0.9456597558255909
rmse : 4.582231568798084	rmse : 5.4736540755489225	rmse : 2.1024522361095532
mae : 1.4786060232086864	mae : 1.4838150930104952	mae : 0.9918421044065783
=====	=====	=====

7. ทำการบันทึกโมเดลการแบบจำลองที่ได้ทำการฝึกแล้ว เพื่อนำไปใช้งานจริง

```
import pickle

pickle.dump(svm_70, open('model/modifile2/svm_70.sav', 'wb'))
pickle.dump(svm_80, open('model/modifile2/svm_80.sav', 'wb'))
pickle.dump(svm_90, open('model/modifile2/svm_90.sav', 'wb'))
pickle.dump(svm_100, open('model/modifile2/svm_100.sav', 'wb'))

pickle.dump(mlp_70, open('model/modifile2/mlp_70.sav', 'wb'))
pickle.dump(mlp_80, open('model/modifile2/mlp_80.sav', 'wb'))
pickle.dump(mlp_90, open('model/modifile2/mlp_90.sav', 'wb'))
pickle.dump(mlp_100, open('model/modifile2/mlp_100.sav', 'wb'))

model_fol = "mod1"
|
pickle.dump(knn_70, open('model/'+str(model_fol)+'/knn_70.sav', 'wb'))
pickle.dump(knn_80, open('model/'+str(model_fol)+'/knn_80.sav', 'wb'))
pickle.dump(knn_90, open('model/'+str(model_fol)+'/knn_90.sav', 'wb'))
pickle.dump(knn_100, open('model/'+str(model_fol)+'/knn_100.sav', 'wb'))
```



ภาคผนวก ค
ผลการทดลองการทดสอบโปรแกรม



ขั้นตอนและผลการทดสอบความแม่นยำในการใช้งานจริง

1. ติดตั้งโปรแกรมในการประมวลผลภาพบน Google Colab และทำการดึงข้อมูลจากโฟลเดอร์ที่กำหนดไว้ใน Google Drive

```
Setup

from google.colab import drive
import os
drive.mount('/content/gdrive', force_remount = True)

os.chdir("/content/gdrive/My Drive/Avocado Model")

Mounted at /content/gdrive
```

2. Import Library ที่จำเป็นในการใช้งาน

```
import os
import cv2
import math
import time
import base64
import pickle
import imutils
import argparse
import numpy as np
import pandas as pd
from IPython.display import display, HTML
```

3. ติดตั้งฟังก์ชันรวม ในกระบวนการประมวลผลภาพ

```
# ฟังก์ชันรวม code ในการ process รูป
def all_process(img_name):
    raw_image = cv2.imread(img_name)
    y=1250
    h=1550
    x=950
    w=1150
    image = raw_image[y:y+h, x:x+w]
    #-----#
    # ปรับขนาดรูปภาพ
    image = imutils.resize(image, height=420)
    # ปรับค่าแสงในรูป
    alpha = 1.6 # Contrast control
    beta = 0 # Brightness control
    a_img = cv2.convertScaleAbs(image, alpha=alpha, beta=beta)
    b_img1 = cv2.fastNlMeansDenoisingColored(a_img, None, 40, 40, 40, 79)
    b_img2 = cv2.bilateralFilter(b_img1, 35, 100, 100)
    gray = cv2.cvtColor(b_img2, cv2.COLOR_BGR2GRAY)
    mask = cv2.threshold(gray, 0, 255, cv2.THRESH_BINARY_INV + cv2.THRESH_OTSU)[1]
    rm_bg = cv2.bitwise_and(image, image, mask=mask)
    #-----#
    # เปลี่ยนสีพื้นหลังเป็นสีดำ
    rm_bg[mask==0] = [0,0,0]
    #-----#
```

```
# หาด้านหนึ่งของขอบผล avocado
rows, cols = mask.shape
top = 0
bottom = 0
left = 0
right = 0
for i in range(rows):
    pix_t = np.sum(mask[i])
    pix_b = np.sum(mask[rows-1-i])

    if top == 0 and pix_t != 0 :
        top = i
    elif bottom == 0 and pix_b != 0 :
        bottom = rows-1-i
    elif top != 0 and bottom != 0 :
        break
for i in range(cols):
    pix_l = np.sum(mask[:, i])
    pix_r = np.sum(mask[:, cols-1-i])

    if left == 0 and pix_l != 0 :
        left = i
    elif right == 0 and pix_r != 0 :
        right = cols-1-i
    elif right != 0 and left != 0 :
        break
#-----#
```

```

# ตัดภาพ ให้เหลือแต่ส่วน avocado และปรับขนาดรูป
y=top+10
h=bottom-10
x=left+10
w=right-10
c_image = rm_bg[y:h, x:w]
#####
#-----#
# แปลงสีโทนภาพให้เป็น LAB
lab_re = cv2.cvtColor(c_image, cv2.COLOR_BGR2LAB)
#-----#
# แยก channel ของสีออกเป็น L , A , B
L_img,A_img,B_img = cv2.split(lab_re)
#-----#
# ทำการหาค่าเฉลี่ยของสีในแต่ละ channel โดยจะแบ่งเป็น 3 โซน ต่อ 1 รูป
# เรียกขนาดของรูป ออกมาใส่ในตัวแปร
rows, cols , __ = lab_re.shape
###

```

```

l_arr = []
a_arr = []
b_arr = []
l = []
a = []
b = []
ix = 0
# ใช้คำสั่ง for loop เพื่อทำการหาค่าเฉลี่ยของสีในแต่ละโซน และสั่งเก็บไว้ใน array ของแต่ละ channel
for i in range(rows):
    #####
    ix = ix+1
    # ลบค่าสีพื้นหลังออกไป
    l_buff = np.delete(L_img[i], np.where(L_img[i] == 0))
    a_buff = np.delete(A_img[i], np.where(A_img[i] == 128))
    b_buff = np.delete(B_img[i], np.where(B_img[i] == 128))
    #####
    # ลบค่าสีพื้นหลังออกไป หาค่าเฉลี่ยของสี
    l.append(np.average(np.nan_to_num(l_buff, nan=np.nanmean(l_buff))))
    a.append(np.average(np.nan_to_num(a_buff, nan=np.nanmean(a_buff))))
    b.append(np.average(np.nan_to_num(b_buff, nan=np.nanmean(b_buff))))
    #####

```

```

if ix == int(rows/3):
    # บันทึกค่าลงใน array
    l_arr.append(np.average(l))
    a_arr.append(np.average(a))
    b_arr.append(np.average(b))
    l = []
    a = []
    b = []
    ix = 0

# รวมค่าที่บันทึกเอาไว้ด้วยกัน
lab_data1 = l_arr + a_arr + b_arr
#####
print("ค่าสี LAB สามโซน")
print(lab_data1)
#-----#

return lab_data1

```

4. ทำการจัดเก็บและแบ่งข้อมูลของค่าสีที่ได้จากการประมวลผลภาพ

```

def data1 (df) :
    df = df.loc[:, ~df.columns.str.contains('^Unnamed')]
    df_X = df[['l_1', 'l_2', 'a_1', 'a_2', 'b_1', 'b_2']]

    return df_X

def data2 (df) :
    df = df.loc[:, ~df.columns.str.contains('^Unnamed')]

    df['l'] = (df['l_1'] + df['l_2'])/2
    df['a'] = (df['a_1'] + df['a_2'])/2
    df['b'] = (df['b_1'] + df['b_2'])/2
    df_X = df[['l', 'a', 'b']]

    return df_X

```

```
def data3 (df) :
    df = df.loc[:, ~df.columns.str.contains('^Unnamed')]

    df = df.groupby(df.index // 3).mean()
    df_X = df[['l_1', 'l_2', 'a_1', 'a_2', 'b_1', 'b_2']]

    return df_X

def data4 (df) :
    df = df.loc[:, ~df.columns.str.contains('^Unnamed')]

    df = df.groupby(df.index // 3).mean()
    df['l'] = (df['l_1'] + df['l_2'])/2
    df['a'] = (df['a_1'] + df['a_2'])/2
    df['b'] = (df['b_1'] + df['b_2'])/2
    df_X = df[['l', 'a', 'b']]

    return df_X
```

5. จากนั้นจะทำการดึงภาพผลอะโวคาโดที่อยู่ในโฟลเดอร์ที่กำหนดไว้มาการประมวลผลภาพและใช้โมเดลที่ได้ฝึกแล้วจากบันทึกมาทำนายค่าความแน่นเนื้อ

Run model

```
[ ] img_name1 = 'Avocado Validation/Day 5 17-03-66/Avocado Day5 4-1.JPG'
    img_name2 = 'Avocado Validation/Day 5 17-03-66/Avocado Day5 4-2.JPG'
```

SVR Model

```
#-----#
# สร้าง dataframe ขึ้นมา
col_list = ['l_1','l_2',
            'a_1','a_2',
            'b_1','b_2']
df = pd.DataFrame(columns = col_list)
#-----#
# หาค่า LAB ของรูปทั้ง 2 ด้าน
lab_data1 = all_process(img_name1)
lab_data2 = all_process(img_name2)
#-----#
# ในค่าที่ได้จากฟังก์ชัน มาใส่ dataframe
df.loc[len(df)] = [lab_data1[0],lab_data2[0],lab_data1[3],lab_data2[3],lab_data1[6],lab_data2[6]]
df.loc[len(df)] = [lab_data1[1],lab_data2[1],lab_data1[4],lab_data2[4],lab_data1[7],lab_data2[7]]
df.loc[len(df)] = [lab_data1[2],lab_data2[2],lab_data1[5],lab_data2[5],lab_data1[8],lab_data2[8]]

svr_90 = pickle.load(open('Showcase Model/svr_90.sav', 'rb'))
df_x = data4(df)
y_pred = svr_90.predict(df_x)
y_pred = mean_arr(y_pred)
#-----#
print("firmness: " + str(y_pred))
```

```
ค่าสี LAB สามโซน
[82.05009944102243, 88.81413445043592, 90.70513283014344, 130.23619930081503, 127.22566671727041,
ค่าสี LAB สามโซน
[98.65496960537392, 97.1170098255235, 107.73385629627697, 124.22238107718822, 123.22046388076929,
firmness: 0.6704574375128076
```


ประวัติผู้เขียน



ชื่อ – สกุล

นายสิริวิชญ์ เดชอธิรัชช์

วัน เดือน ปีเกิด

4 กันยายน พ.ศ. 2540

ที่อยู่

31/150 หมู่บ้านฟ้าทอฝัน ม.3 ตำบล บึงคำพร้อย อำเภอลำลูกกา
จังหวัดปทุมธานี 12150

การศึกษา

ปริญญาตรี คณะวิศวกรรมศาสตร์ สาขาวิศวกรรมอาหาร
มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

เบอร์โทรศัพท์

092-273-2959

อีเมลล์

sirawit_d@mail.rmutt.ac.th