

การจำแนกสายพันธุ์และคุณภาพของแก้วมังกรไทย

SPECIE AND QUALITY CLASSIFICATION OF THAI DRAGON FRUIT



นรุวรรณ อยู่สำราญ
NARUWAN YUSAMRAN

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์
ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2566

KMITL-2023-SC-D-002-043

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

SPECIE AND QUALITY CLASSIFICATION OF THAI DRAGON FRUIT



NARUWAN YUSAMRAN

A THESIS SUBMITTED IN PARTIAL FULFILLMENT OF THE REQUIREMENT FOR THE
DEGREE OF DOCTOR OF PHILOSOPHY IN COMPUTER SCIENCE
DEPARTMENT OF COMPUTER SCIENCE SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2023

KMITL-2023-SC-D-002-043

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2023

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การจำแนกสายพันธุ์และคุณภาพของแก้วมังกรไทย
ชื่อนักศึกษา	นางสาวนรธรรม อยู่สำราญ
รหัสประจำตัว	62605118
ปริญญา	ปรัชญาดุษฎีบัณฑิต (วิทยาการคอมพิวเตอร์)
ภาควิชา	วิทยาการคอมพิวเตอร์
พ.ศ.	2566
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ผู้ช่วยศาสตราจารย์ ดร.นวลสวาท หิรัญสกุลวงศ์

บทคัดย่อ

ด้วยคุณค่าของแก้วมังกรที่เป็นผลไม้ที่มีประโยชน์ มีคุณค่าทางโภชนาการสูง และเป็นพืชเศรษฐกิจชนิดหนึ่งที่มีการเพาะปลูกเชิงพาณิชย์ตามมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ สามารถสร้างรายได้ให้กับเกษตรกรไทยได้ จากการสำรวจพบว่าการเพาะปลูกแก้วมังกรทั้งหมด 7 สายพันธุ์ ซึ่งมีลักษณะสัณฐานวิทยาที่แตกต่างกัน ยากต่อการจำแนกสายพันธุ์ต้องใช้ความเชี่ยวชาญในการจำแนก อาจส่งผลกระทบต่อการเพิ่มมูลค่าและการตรวจสอบคุณภาพผลผลิตแก้วมังกรได้ ดังนั้นงานวิจัยนี้จึงนำเสนอการจำแนกแก้วมังกรไทยจากภาพ โดยมีวัตถุประสงค์เพื่อพัฒนาอัลกอริทึมสำหรับการจำแนกสายพันธุ์และอัลกอริทึมสำหรับจำแนกคุณภาพของแก้วมังกรไทยจากภาพ โดยใช้เทคนิคการประมวลผลภาพดิจิทัลและการเรียนรู้ของเครื่อง ในการดำเนินงานวิจัยมีการสร้างชุดข้อมูลภาพแก้วมังกรไทยขึ้นมาใหม่เพื่อใช้ในการทดลอง จากผลการทดลองระบุว่า โมเดลของการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพสามารถรองรับการประมวลผลภาพที่ถูกบันทึกในห้องปฏิบัติการและสภาวะแวดล้อมกลางแจ้งได้ สำหรับเฉพาะชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการมีความถูกต้อง 98.80% ชุดข้อมูลภาพเฉพาะที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งมีความถูกต้อง 94.00% และชุดข้อมูลภาพที่รวมทั้งภาพที่ถูกบันทึกในห้องปฏิบัติการและสภาวะแวดล้อมกลางแจ้งมีความถูกต้อง 95.53% สำหรับโมเดลของการจำแนกคุณภาพของแก้วมังกรไทยจากภาพซึ่งถูกแบ่งเป็น 2 ส่วน ได้แก่ การจำแนกคุณภาพโดยการตรวจหาตำหนิตัวด้วยการสร้างกฎ มีค่าความถูกต้องเท่ากับ 100.00% และการจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้การแยกคุณลักษณะสี รูปร่าง และการเรียนรู้ด้วยต้นไม้ตัดสินใจ ซึ่งให้ค่าความถูกต้องเท่ากับ 94.18% จากการงานวิจัยนี้ผู้วิจัยคาดหวังว่าจะนำไปสู่การพัฒนานวัตกรรมสำหรับการจำแนกสายพันธุ์และจำแนกคุณภาพของแก้วมังกรไทยที่ช่วยลดแรงงานในการคัดแยกสายพันธุ์และตรวจสอบคุณภาพแก้วมังกรได้ อาจช่วยให้เกษตรกรขายผลผลิตได้ในราคาที่ดีขึ้น ผู้บริโภคที่แพ้แก้วมังกรบางสายพันธุ์สามารถหลีกเลี่ยงได้อย่างถูกต้องหรือเลือกบริโภคได้ตามความชื่นชอบได้

คำสำคัญ : การจำแนกภาพ การเรียนรู้ของเครื่อง แก้วมังกร ชุดข้อมูลภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Thesis Title	Specie and Quality Classification of Thai Dragon Fruit
Student Name	Naruwan Yusamran
Student ID	62605118
Degree	Doctor of Philosophy (Computer Science)
Department	Computer Science
Year	2023
Thesis Advisor	Asst. Prof. Dr. Nualsawat Hirsakolwong

Abstract

With the value of the dragon fruit, it has a high nutritional value, and it is one of the economic crops that is cultivated commercially according to the National Agricultural Commodity and Food Standards. It can make income for Thai farmers. From the survey, there are seven species of Thai dragon fruits that were cultivated with different morphology which are difficult to classify and require expertise to classification. It may affect the value-added and quality measuring of dragon fruit products. Therefore, this research presents the specie and quality classification of Thai dragon fruit. The objective was to develop algorithms for classifying species and for classifying the quality of Thai dragon fruit from images by using digital image processing techniques and machine learning. In this research, a new image dataset of Thai dragon fruit was created for experimentations. The experimental results indicate that the model for classifying Thai dragon fruit species only with the laboratory dataset with accuracy 98.80%, only with the outdoor dataset with accuracy 94.00%, and the whole datasets with accuracy 95.53%. For quality classification of Thai dragon fruit, which is divided into two parts, namely quality classification for detecting defects by creating rules which gave an accuracy equal to 100.00% and size classification of dragon fruit from the image using color and shape feature extraction with decision tree learning which gave an accuracy value of 94.18%. Finally, this research expected when farmers, factories, and consumers can classify species of Thai dragon fruit correctly, it will help farmers sell their products for a better price. Consumers who are allergic to certain species will be able to avoid them correctly or choose their favorite.

Keywords : Dragon Fruit, Image Classification, Machine Learning, Image Dataset

กิตติกรรมประกาศ

วิทยานิพนธ์นี้มีอาจสำเร็จลุล่วงไปได้ด้วยดีหากไม่ได้รับคำแนะนำ คำชี้แจง ความรู้ และความเอาใจใส่จาก ผู้ช่วยศาสตราจารย์ ดร.นวลสวาท ทิรัญสกลวงศ์ ผู้เป็นอาจารย์ที่ปรึกษา ซึ่งท่านได้สละเวลาให้กับข้าพเจ้าอย่างเต็มที่ จึงใคร่ขอขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.กฤษณะ ชินสาร รองศาสตราจารย์ ดร.จิรพร วีระพันธุ์ ผู้ช่วยศาสตราจารย์ ดร.วรางคณา กัมปาน และผู้ช่วยศาสตราจารย์ ดร.อนันตพร ทรราชคุณาฒย์ ที่กรุณาเป็นคณะกรรมการสอบหัวข้อวิทยานิพนธ์ในครั้งนี้

ขอขอบคุณบุคลากร คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ทุกๆท่านที่ให้ความช่วยเหลือและคำปรึกษาตลอดระยะเวลาการดำเนินงานวิจัยจนสำเร็จลุล่วงไปได้ด้วยดี

ขอขอบพระคุณ มหาวิทยาลัยราชภัฏเลย และกระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม ที่ให้ทุนสนับสนุนในการศึกษาครั้งนี้แก่ข้าพเจ้า

ขอขอบพระคุณสวนแก้วมังกรไร่พ้อจอม สวนแก้วมังกรน้องเทอร์โบ สวนกระต่ายสบายเลย สวนแก้วมังกรคุณสุภาพ เชื้อบุญมี สวนแก้วมังกรคุณเยี่ยม กุณโใบ และสวนแก้วมังกรคุณแสงเดือน พรหมมาวัน ผู้ให้แหล่งข้อมูลแก้วมังกรซึ่งเป็นข้อมูลสำคัญที่ใช้ในการดำเนินงานวิจัยครั้งนี้และช่วยอำนวยความสะดวกในด้านต่างๆในระหว่างการลงพื้นที่เก็บข้อมูล

ขอกราบขอบพระคุณบิดา มารดา สมาชิกในครอบครัว ตลอดจนญาติ พี่น้อง และเพื่อนๆทุกคน ที่สนับสนุนและเป็นกำลังใจในระหว่างการศึกษานี้เป็นอย่างดียิ่ง

ขอขอบคุณทุกๆ ท่านที่ไม่ได้กล่าวมา ณ ที่นี้ที่มีส่วนร่วมในการทำวิทยานิพนธ์ในครั้งนี้

นรวัชรณ อยู่สำราญ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ก
บทคัดย่อภาษาอังกฤษ	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ช
สารบัญรูป	ฉ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	3
1.3 ขอบเขตของงานวิจัย	3
1.3.1 ขอบเขตการวิจัย	3
1.3.2 ตัวแปร	3
1.3.3 นิยามศัพท์เฉพาะ	3
1.3.4 ขั้นตอนการศึกษาและวิธีดำเนินงานวิจัย	4
1.4 ประโยชน์ที่คาดว่าจะได้รับ	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	5
2.1 แก้วมังกร	5
2.1.1 ข้อมูลทั่วไป	5
2.1.2 คุณค่าทางโภชนาการและสรรพคุณทางยา	6
2.1.3 สถานการณ์การเพาะปลูกแก้วมังกรของไทย	8
2.1.4 มาตรฐานสินค้าเกษตรเพื่อการส่งออกแก้วมังกรของไทย	9
2.2 ความรู้เบื้องต้นเกี่ยวกับการประมวลผลภาพดิจิทัล	11
2.2.1 ภาพดิจิทัล	11
2.2.2 โมเดลสี	12
2.2.3 ประเภทของภาพดิจิทัล	16
2.3 การประมวลผลภาพ	18
2.3.1 การเก็บข้อมูลภาพ	19
2.3.2 การเตรียมข้อมูลภาพ	20
2.3.3 การแยกคุณลักษณะ	20
2.3.4 การจำแนกภาพ	21
2.4 การแบ่งส่วนภาพ	21
2.4.1 การแบ่งส่วนภาพโดยใช้ค่าขีดแบ่ง	22
2.4.2 การแบ่งส่วนภาพโดยใช้เส้นขอบ	22
2.4.3 การแบ่งส่วนภาพโดยใช้พื้นที่	23
2.4.4 การแบ่งส่วนภาพโดยใช้พลังงาน	24

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์โดยมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการศึกษา

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
2.5 โมเดลการจำแนกภาพ	25
2.5.1 การจำแนกด้วยกฎ	25
2.5.2 การแยกคุณลักษณะตามเนื้อหา	26
2.5.3 การเรียนรู้เชิงลึก	26
2.6 การวัดประสิทธิภาพโมเดล	28
2.6.1 ตารางคอนฟิวชันเมทริกต์	28
2.6.2 การแบ่งข้อมูล k-fold Cross Validation	29
2.7 งานวิจัยที่เกี่ยวข้อง	30
บทที่ 3 วิธีการดำเนินงานวิจัย	40
3.1 การเก็บข้อมูลภาพ	40
3.1.1 ตัวอย่างแก้วมังกร	40
3.1.2 ชุดข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกสายพันธุ์แก้วมังกรไทย	42
3.1.3 ชุดข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย	47
3.2 การพัฒนาอัลกอริทึมสำหรับจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ	49
3.2.1 การระบุประเภทของภาพ	51
3.2.2 การเตรียมข้อมูลภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้ง	57
3.2.3 การจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก	60
3.2.4 การลบพื้นหลัง	63
3.2.5 การแบ่งข้อมูลเพื่อใช้ในการทดลองด้วยเทคนิค 10-folds Validation	69
3.2.6 การจำแนกสายพันธุ์ของแก้วมังกร	70
3.3 การพัฒนาอัลกอริทึมสำหรับจำแนกคุณภาพแก้วมังกรไทยจากภาพ	81
3.3.1 การเตรียมข้อมูลภาพสำหรับจำแนกคุณภาพ	82
3.3.2 การแยกคุณลักษณะสำหรับจำแนกคุณภาพ	88
3.3.3 การจำแนกคุณภาพแก้วมังกรไทยจากภาพ	90
3.4 การวัดประสิทธิภาพอัลกอริทึม	93
บทที่ 4 ผลการวิจัยและการอภิปรายผล	94
4.1 ผลการทดลองการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ	94
4.1.1 ผลการทดลองการระบุประเภทของภาพ	94
4.1.2 ผลการทดลองการจำแนกภาพแก้วมังกรด้วยสีเปลือก	94
4.1.3 ผลการทดลองการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา	96
4.1.4 ผลการทดลองการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการเรียนรู้เชิงลึก	100
4.2 ผลการทดลองจำแนกคุณภาพของแก้วมังกรไทยจากภาพ	103
4.2.1 ผลการทดลองจำแนกคุณภาพโดยการตรวจหาตำหนิ	103

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี หากมีข้อผิดพลาดประการใดขออภัยเป็นอย่างสูง

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
4.2.2 ผลการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้ เทคนิคการแยกคุณลักษณะตามเนื้อหา	104
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	109
5.1 สรุปผลการวิจัย	109
5.2 ข้อจำกัดและข้อเสนอแนะ	111
บรรณานุกรม	112
ภาคผนวก	119
ภาคผนวก ก ผลงานที่ได้รับการตีพิมพ์	120
ภาคผนวก ข ข้อมูลวารสารที่ได้รับการตีพิมพ์	155
ประวัติผู้เขียน	168



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
2.1 ส่วนประกอบของผลแก้วมังกรต่อส่วนที่รับประทานได้ 100 กรัม	7
2.2 ข้อมูลรายงานสถิติทางการเกษตรเรียงลำดับตามเนื้อที่ปลูก	8
2.3 ข้อมูลรายงานสถิติทางการเกษตรเรียงลำดับตามผลผลิตที่เก็บเกี่ยวได้	8
2.4 ขนาดของแก้วมังกร	10
2.5 วิธีวิเคราะห์คุณภาพแก้วมังกร	10
2.6 การเปรียบเทียบเซ็นเซอร์สำหรับการจำแนกประเภทผลไม้และผัก	19
2.7 คุณสมบัติของตัวบอกคุณลักษณะ	20
3.1 จำนวนภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละสายพันธุ์	44
3.2 จำนวนภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งของแต่ละสายพันธุ์	45
3.3 จำนวนภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละรหัสขนาด	48
3.4 จำนวนภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละชั้นคุณภาพ	48
3.5 ชุดข้อมูลที่ใช้ในการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ	70
3.6 แผนการทดลองการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา	80
3.7 โครงสร้างโมเดลการเรียนรู้เชิงลึกที่ใช้ในการทดลอง (DIPDEEP)	80
3.8 แผนการทดลองการจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา	92
3.9 แผนการการวัดประสิทธิภาพอัลกอริทึม	93
4.1 ผลการทดลองการระบุประเภทของภาพ	94
4.2 ผลการทดลองการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกของภาพที่ถูกบันทึกในห้องปฏิบัติการ	95
4.3 ผลการทดลองการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกของภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง	95
4.4 คุณลักษณะที่ใช้ในการทดลองของ CBML Method	97
4.5 ผลการทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Laboratory และคุณลักษณะของ CBML Method	97
4.6 คุณลักษณะที่ใช้ในการทดลองของ DIP-CBML Method	99
4.7 ผลการทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Outdoor Mixdata1 และ Mixdata2	99
4.8 การทดลองย่อยที่ 1	100
4.9 การทดลองย่อยที่ 2	101
4.10 ผลการทดลองจำแนกคุณภาพโดยการตรวจหาตำหนิ	104
4.11 เปรียบเทียบผลการทดลองจำแนกคุณภาพโดยการตรวจหาตำหนิด้วยวิธีของ Trieu and Think (2021) และวิธีที่นำเสนอ	104
4.12 คุณลักษณะที่ใช้ในการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพ	105

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.13 ผลการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา	105
5.1 โมเดลของการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ	110



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
2.1 ต้นแก้วมังกร	6
2.2 ลักษณะภายในและภายนอกของผลแก้วมังกร	6
2.3 ระบบพิกัดของภาพดิจิทัล	11
2.4 แบบจำลองโมเดลสี (a) RGB (b) HSV และ (c) Lab	12
2.5 แบบจำลองสามมิติโมเดลสี RGB	12
2.6 แบบจำลองสามมิติโมเดลสี HSV	13
2.7 ตัวอย่างการแปลงภาพโมเดลสี RGB เป็นภาพโมเดลสี HSV	14
2.8 แบบจำลองโมเดลสี Lab	15
2.9 ตัวอย่างการแปลงภาพโมเดลสี RGB เป็นภาพโมเดลสี Lab	16
2.10 ระบบพิกัดของภาพสี	16
2.11 ระบบพิกัดของภาพระดับเทา	17
2.12 ระบบพิกัดของภาพสองระดับ	17
2.13 ตัวอย่างการแบ่งส่วนโดยใช้ค่าขีดแบ่ง	22
2.14 ตัวอย่างการแบ่งส่วนภาพโดยใช้เส้นขอบ	23
2.15 ตัวอย่างการแบ่งส่วนภาพโดยใช้พื้นที่	23
2.16 โครงสร้างโมเดลการจำแนกข้อมูลด้วยกฎ	25
2.17 โครงสร้างของโมเดลการแยกคุณลักษณะตามเนื้อหา	26
2.18 โครงสร้างอย่างง่ายของโมเดลการเรียนรู้เชิงลึก	27
2.19 ตัวอย่างตารางคอนฟิวชันเมทริกต์	28
2.20 ตัวอย่างการแบ่งข้อมูล 5-fold Cross Validation	30
3.1 ขั้นตอนวิธีดำเนินงานวิจัย	40
3.2 แสดงตัวอย่างแก้วมังกรโดยแบ่งตามสายพันธุ์	41
3.3 แสดงตัวอย่างแก้วมังกรโดยแบ่งตามรหัสขนาด	41
3.4 แสดงตัวอย่างแก้วมังกรโดยแบ่งตามชั้นคุณภาพ	42
3.5 อุปกรณ์ที่ใช้ในการเก็บข้อมูลภาพในห้องปฏิบัติการ	42
3.6 แสดงตัวอย่างวิธีการเก็บข้อมูลภาพในห้องปฏิบัติการ	43
3.7 ตัวอย่างข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการ	43
3.8 ตัวอย่างข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง	44
3.9 ตัวอย่างวิธีเก็บข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย	47
3.10 แสดงตัวอย่างการวางเลย์เอาต์ของภาพและตำแหน่งของผลแก้วมังกรของการเก็บข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย	47
3.11 ตัวอย่างข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย	48
3.12 แผนการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ	50
3.13 ผังงานแสดงขั้นตอนการระบุประเภทของภาพ	51
3.14 ตัวอย่างการแปลงภาพสีเป็นภาพระดับเทา 10 รูปแบบ	53

เอกสารนี้เป็นเอกสารลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการศึกษา

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.15 การแปลงภาพระดับเทาเป็นภาพสองระดับด้วยค่าขีดแบ่ง mean threshold	53
3.16 ขั้นตอนการแบ่งส่วนพื้นหลังกับผลแก้วมังกร	53
3.17 การปรับปรุงขั้นตอนการแบ่งส่วนพื้นหลังกับผลแก้วมังกรด้วยการ Fill Hole	54
3.18 ผังงานแสดงขั้นตอนการเตรียมข้อมูลภาพ	54
3.19 ผังงานแสดงขั้นตอนการคำนวณค่า mean threshold	55
3.20 ตัวอย่างผลลัพธ์ที่ได้จากการเตรียมข้อมูลภาพ	55
3.21 แสดงคุณสมบัติทางสถิติของภาพแต่ละประเภท	56
3.22 ผังงานของการเตรียมข้อมูลภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้ง	57
3.23 ผังงานการตรวจจับตำแหน่งผลแก้วมังกร	57
3.24 ตัวอย่างข้อมูลภาพที่ใช้ในการหาช่วงค่า Hue สำหรับแก้วมังกรเปลือกสีเหลืองและสีแดง (HSV Range)	58
3.25 อัลกอริทึมหาช่วงค่า Hue สำหรับแก้วมังกรเปลือกสีเหลือง	58
3.26 อัลกอริทึมหาช่วงค่า Hue สำหรับแก้วมังกรเปลือกสีแดง	58
3.27 ตัวอย่างผลลัพธ์ของการเตรียมข้อมูลภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้ง (a) ภาพต้นฉบับ (b) ภาพ Image HSV1	59
3.28 กฎการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก	60
3.29 ผังงานการคำนวณค่าร้อยละของสีเหลืองและสีแดงจากสีเปลือกผลแก้วมังกร	62
3.30 ตัวอย่างการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกจากภาพที่ถูกลบพื้นหลังแล้ว	62
3.31 ตัวอย่างการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกด้วย (a) ภาพที่ถูกบันทึกในห้องปฏิบัติการ และ (b) ภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้ง	63
3.32 ผังงานแสดงขั้นตอนการลบพื้นหลังของข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการ	64
3.33 ตัวอย่างการปรับขนาดภาพเฉพาะส่วนผลแก้วมังกร	64
3.34 ผังงานแสดงขั้นตอนการลบพื้นหลังของข้อมูลภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้ง	65
3.35 ผังงานโปรแกรมย่อยการลบพื้นหลังที่คงเหลือด้วยโมเดลสี HSV	67
3.36 ผังงานโปรแกรมย่อย Check Mask and Image	67
3.37 ผังงานโปรแกรมย่อยการลบพื้นหลังด้วยโมเดลสี Lab	68
3.38 ตัวอย่างภาพผลลัพธ์ของกระบวนการลบพื้นหลัง (a) ภาพนำเข้า HSV1 (b) ภาพ HSV2 Mask เป็นภาพผลลัพธ์ที่ได้จากโปรแกรมย่อยการลบพื้นหลังที่คงเหลือด้วยโมเดลสี HSV (c) ภาพ A Mask เป็นภาพผลลัพธ์ที่ได้จากโปรแกรมย่อยการลบพื้นหลังด้วยโมเดลสี Lab (d) ภาพ HSVA Mask เป็นภาพผลลัพธ์ที่ได้จากการ intersection A Mask กับ HSV2-Mask (e) ภาพผลลัพธ์ที่ได้จากลบพื้นหลังออกจากภาพด้วย HSVA Mask และ (f) ภาพผลลัพธ์ที่ได้จากการปรับขนาดเฉพาะส่วนผลแก้วมังกรให้มีขนาดไม่เกิน 100x100 พิกเซล	69
3.39 ผังงานการแยกคุณลักษณะสำหรับการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ	71
3.40 ขั้นตอนการแยกคุณลักษณะสี	72

เอกสารนี้เป็นของส่วนราชการสงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.41 ขั้นตอนการแยกคุณลักษณะพื้นผิวโดยใช้ GLCM	73
3.42 ขั้นตอนการแยกคุณลักษณะรูปร่างและขนาด	74
3.43 ขั้นตอนการแยกคุณลักษณะขอบ	77
3.44 ความสัมพันธ์ระหว่างค่า rho และ theta กับ สมการเส้นตรง	77
3.45 ขั้นตอนการแยกคุณลักษณะเส้น	78
3.46 ตัวอย่างการปรับค่าข้อมูลคุณสมบัติทางสถิติของคุณลักษณะสีด้วย MinMaxScaler	79
3.47 แผนการทดลองจำแนกคุณภาพของแก้วมังกรไทยจากภาพ	82
3.48 การเตรียมข้อมูลสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิ	83
3.49 การลบส่วนเกินของกลีบออกจากภาพด้วยหน้ากาก Filled Ellipse Mask	84
3.50 การแจกแจงความถี่และการสร้างหน้ากากด้วยฮิสโตแกรม	85
3.51 การแบ่งส่วนภาพด้วยเส้นแบ่งก้ำช่องของผลแก้วมังกรแต่ละขนาด	86
3.52 การเตรียมข้อมูลสำหรับการจำแนกผลแก้วมังกรตามขนาด	87
3.53 อัลกอริทึมหาเส้นรอบรูปของผลแก้วมังกรรวมกลีบ	87
3.54 ตัวอย่างการแยกคุณลักษณะสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิ	89
3.55 กฎการจำแนกคุณภาพโดยการตรวจหาตำหนิ	91
4.1 โมเดลการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ	102
4.2 ตารางคอนฟิวชันเมตริกต์ของการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Mixdata1 และคุณลักษณะของ DIP-CBML Method	103
4.3 ตัวอย่างการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพไม่ถูกต้อง	103
4.4 ตารางคอนฟิวชันเมตริกต์ของการจำแนกขนาดของผลแก้วมังกรจากภาพ	106
4.5 ตัวอย่างต้นไม้ตัดสินใจที่ได้จากการทดลอง	107
4.6 ตัวอย่างการจำแนกขนาดของผลแก้วมังกรจากภาพไม่ถูกต้อง	108

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

แก้วมังกร (Dragon Fruit) เป็นผลไม้ที่มีความน่าสนใจ ทั้งลักษณะภายนอกที่มีความแปลกตา สีสัมผัสสวยงาม มีคุณค่าทางโภชนาการสูง สามารถนำไปใช้ประโยชน์ในอุตสาหกรรมอาหาร เครื่องสำอาง และยาได้ (Goenaga. et al., 2020; Perween. et al., 2018; Trivellini. et al., 2020; Wichienchot. et al., 2010) ในประเทศไทยมีการเพาะปลูกแก้วมังกรหลากหลายสายพันธุ์ (Cultivar) มีการซื้อขายในตลาดทั้งในประเทศและต่างประเทศ โดยเฉพาะในประเทศไทยมีการซื้อขายผลแก้วมังกรที่ถูกเก็บเกี่ยวทั้งในฤดูกลางและนอกฤดูกลาง รวมถึงกิ่งพันธุ์ (Cladode) ที่เหลือจากการตัดแต่งต้นพันธุ์ที่มีการซื้อขายกันอย่างแพร่หลายในกลุ่มเกษตรกรทั้งรายใหม่และรายเก่า ในขณะที่สถานการณ์การแพร่ระบาดของโรคโควิด-19 การซื้อขายผลแก้วมังกรและกิ่งพันธุ์ยังคงดำเนินการต่อได้โดยไม่ได้รับผลกระทบเนื่องจากสามารถซื้อขายผ่านโซเชียลมีเดียและใช้บริการขนส่งทั้งของรัฐและเอกชนได้ แต่ก็มีความเสี่ยงจากกลุ่มมิจฉาชีพเช่นเดียวกับสินค้าประเภทอื่น

สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ กระทรวงเกษตรและสหกรณ์ของไทยได้กำหนดมาตรฐานแก้วมังกรโดยแบ่งแก้วมังกรออกเป็น 3 กลุ่ม ซึ่งมีความแตกต่างที่สีเปลือก (Peel/Skin) และสีเนื้อข้างใน (Pulp) ได้แก่ กลุ่มที่ 1 เปลือกสีแดงเนื้อสีขาว (*Hylocereus undatus*), กลุ่มที่ 2 เปลือกสีแดงเนื้อสีแดง (*Hylocereus polyrhizus*) หรือ เปลือกสีแดงเนื้อชมพู (*Hylocereus spp.*) และกลุ่มที่ 3 เปลือกสีเหลืองหรือทอง เนื้อสีขาว (*Hylocereus sp.* และ *Selenicereus sp.*) ทั้งสามกลุ่มนี้จะถูกแบ่งชั้นคุณภาพออกเป็น 3 ชั้นคุณภาพ ได้แก่ ชั้นพิเศษ (Extra class), ชั้นหนึ่ง (Class I) และชั้นสอง (Class II) โดยใช้ลักษณะภายนอกและน้ำหนักต่อผลในการจัดลำดับคุณภาพเป็นหลัก สำหรับการบรรจุหีบห่อเพื่อส่งออกจะต้องบรรจุแก้วมังกรพันธุ์เดียวกัน ต่อหนึ่งบรรจุภัณฑ์ พร้อมทั้งระบุสายพันธุ์ของแก้วมังกรบริเวณฉลากที่ติดหน้าบรรจุภัณฑ์ด้วย สำหรับคุณภาพของผลแก้วมังกรในหนึ่งบรรจุภัณฑ์ ควรมีคุณภาพในชั้นคุณภาพเดียวกันทั้งบรรจุภัณฑ์หรือมีผลแก้วมังกรที่มีชั้นคุณภาพต่ำกว่าหนึ่งชั้นปะปนมาได้ แต่ไม่เกินร้อยละ 5-10 ของจำนวนหรือน้ำหนักของแก้วมังกรทั้งหมดในบรรจุภัณฑ์ ไม่ว่าจะอย่างไรก็ตามสิ่งที่ควรคำนึงคือกรณีที่มีมองเห็นแก้วมังกรจากภายนอกบรรจุภัณฑ์ แก้วมังกรส่วนที่มองเห็นต้องเป็นตัวแทนของผลิตผลทั้งหมดในบรรจุภัณฑ์ (National Bureau of Agricultural Commodity and Food Standards, 2015)

จากการสำรวจพื้นที่เพื่อศึกษาสายพันธุ์แก้วมังกรที่มีการเพาะปลูกในประเทศไทย พบว่าพื้นที่จังหวัดเลย ที่ตั้งอยู่ตอนบนสุดของภาคตะวันออกเฉียงเหนือของประเทศไทย เป็นพื้นที่ที่สามารถเก็บเกี่ยวผลผลิตได้มากที่สุดโดยมีปริมาณเกินครึ่งของผลผลิตทั้งประเทศ (Department of agricultural extension, ministry of agriculture and cooperatives, 2020) โดยมีการเพาะปลูกแก้วมังกรทั้งหมด 7 สายพันธุ์ แบ่งเป็นกลุ่มที่ 1 เปลือกสีแดงเนื้อสีขาว 2 สายพันธุ์ ได้แก่ พันธุ์ขาวจัมโบ้ (Jumbo White) , พันธุ์ขาวเวียดนาม (Vietnamese White) กลุ่มที่ 2 เปลือกสีแดงเนื้อสีแดง หรือ เปลือกสีแดงเนื้อชมพู 4 สายพันธุ์ ได้แก่ พันธุ์ชมพูจินดา (Pink), พันธุ์แดงสยาม (Siam Red), พันธุ์แดงไต้หวัน (Taiwan Red), พันธุ์แดงทับทิม (Ruby Red) และกลุ่มที่ 3 เปลือกสีเหลืองหรือทอง เนื้อสีขาว 1 สายพันธุ์ ได้แก่ พันธุ์เหลืองอิสราเอล (Israel Yellow) ซึ่งมีเพียงเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เกษตรกรบางรายที่สามารถระบุสายพันธุ์ที่ตนเองปลูกได้ เกษตรกรส่วนมากจะรู้เพียงแค่เปลือก (Peel) กับเนื้อข้างใน (Pulp) เท่านั้น เช่นเดียวกันกับพ่อค้าคนกลางที่รับซื้อผลผลิตจากเกษตรกรไม่สามารถระบุชื่อสายพันธุ์ได้เช่นกัน ดังนั้นพ่อค้าคนกลางจะคัดแยกผลผลิตออกเป็นสามกลุ่มตามที่สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ กระทรวงเกษตรและสหกรณ์กำหนดไว้ ด้วยเหตุนี้ทำให้ราคาของแก้วมังกรแต่ละสายพันธุ์ถูกกำหนดตามกลุ่มมาตรฐานใน 3 กลุ่มเท่านั้น โดยผลผลิตที่ได้จากการเพาะปลูกของแต่ละพื้นที่ในประเทศมีจำนวนไม่น้อยไม่เท่ากัน ส่งผลต่อราคาขาย พื้นที่ที่มีผลผลิตน้อยจะมีราคาสูงกว่าพื้นที่ที่มีผลผลิตมาก (National Bureau of Agricultural Commodity and Food Standards, 2015) นอกจากนี้การตรวจสอบคุณภาพของผลผลิตยังคงใช้การตรวจสอบด้วยสายตาและทดสอบด้วยประสาทสัมผัสของมนุษย์ในการจำแนกคุณภาพ ซึ่งมีความเสี่ยงเกิดความคลาดเคลื่อนสูง หากเกษตรกรหรือพ่อค้าคนกลางสามารถจำแนกสายพันธุ์แก้วมังกรและจำแนกชั้นคุณภาพของผลผลิตได้อย่างถูกต้อง อาจช่วยส่งเสริมการบริหารจัดการผลผลิตแก้วมังกรได้ ไม่ว่าจะเป็นการดูแลรักษาผลผลิตหลังเก็บเกี่ยว การจัดการลักษณะการขนส่ง ตามลักษณะสัณฐานวิทยาเฉพาะของแต่ละสายพันธุ์ การรักษาคุณภาพผลผลิตให้เป็นไปตามข้อกำหนดของการนำเข้าและส่งออก ซึ่งส่งผลต่อต้นทุนและราคาขายได้ อีกทั้งเป็นการส่งเสริมการอนุรักษ์พันธุ์ผลไม้ไปด้วย

จากข้อมูลข้างต้น หากเป็นนักวิชาการหรือเกษตรกรที่มีความเชี่ยวชาญจะสามารถจำแนกสายพันธุ์ได้จากลักษณะสัณฐานวิทยาที่ค่อนข้างต้องใช้ความรู้และความเชี่ยวชาญอย่างมาก แต่หากเป็นบุคคลทั่วไปหรือเกษตรกรรายใหม่ หรือแม้กระทั่งพ่อค้าคนกลาง ก็อาจจะไม่สามารถจำแนกสายพันธุ์แก้วมังกรได้ถูกต้อง โดยเฉพาะกลุ่มเปลือกสีแดงเนื้อสีขาวกับเปลือกสีแดงเนื้อสีแดงหรือเปลือกสีแดงเนื้อชมพู ซึ่งสองกลุ่มนี้มีเปลือกสีเดียวกันแต่ต่างที่เนื้อข้างใน อาจทำให้แยกกลุ่มผิดพลาดเพราะเวลารับซื้อไม่สามารถผ่าดูเนื้อข้างในได้ทุกผล อาจมีการปะปนผิดสีกันได้ ส่งผลต่อความน่าเชื่อถือและราคาขายจากผู้บริโภคหรือโรงงาน หากมีเครื่องมือช่วยในการจำแนกสายพันธุ์จากภายนอกอย่างง่าย คาดว่าจะช่วยแก้ปัญหาการแยกกลุ่มผลผลิตแก้วมังกรได้ อีกทั้งการจำแนกสายพันธุ์ได้อย่างถูกต้องยังช่วยให้การใช้เกณฑ์สำหรับการตรวจสอบคุณภาพของผลผลิตถูกต้องตรงตามข้อกำหนดของแต่ละสายพันธุ์ แต่หากวิธีการตรวจสอบคุณภาพผลแก้วมังกรยังคงใช้การตรวจพินิจและประสาทสัมผัสของมนุษย์เช่นเดิม คาดว่าอาจมีความเสี่ยงสูงต่อความผิดพลาดในการจำแนกชั้นคุณภาพของผลผลิตได้เช่นกัน

ดังนั้น ผู้วิจัยมีแนวคิดสร้างชุดข้อมูลภาพแก้วมังกรไทยเพื่อพัฒนาอัลกอริทึมสำหรับการจำแนกสายพันธุ์และการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ โดยคาดหวังว่าจะนำไปสู่การพัฒนานวัตกรรมสำหรับการจำแนกสายพันธุ์และจำแนกคุณภาพของแก้วมังกรไทย ที่สามารถใช้งานง่าย สะดวก เหมาะกับบุคคลทั่วไป หรือนำไปประยุกต์ใช้กับงานอุตสาหกรรมได้ในอนาคต ช่วยลดแรงงานในการคัดแยกและตรวจสอบคุณภาพแก้วมังกรได้ อาจช่วยเพิ่มมูลค่าให้กับผลผลิตจากการปลูกแก้วมังกรไทย และอาจเป็นเครื่องมือให้บุคคลที่เลือกบริโภคแก้วมังกรแค่บางสายพันธุ์ เลือกซื้อแก้วมังกรตามความชื่นชอบส่วนตัวของแต่ละบุคคลได้ นอกจากนี้อาจช่วยลดความเสี่ยงจากกลุ่มมิจฉาชีพได้

1.2 วัตถุประสงค์ของงานวิจัย

- 1) เพื่อสร้างชุดข้อมูลภาพแก้วมังกรไทย
- 2) เพื่อพัฒนาอัลกอริทึมสำหรับการจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ
- 3) เพื่อพัฒนาอัลกอริทึมสำหรับการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ

1.3 ขอบเขตของงานวิจัย

1.3.1 ขอบเขตการวิจัย

การวิจัยครั้งนี้เป็นการศึกษาเทคนิคการประมวลผลภาพ (Image Processing) และวิธีการเรียนรู้ของเครื่อง (Machine Learning) เพื่อพัฒนาอัลกอริทึมสำหรับการจำแนกสายพันธุ์ 7 สายพันธุ์ ได้แก่ พันธุ์ขาวจัมโบ้ (Jumbo White) , พันธุ์ขาวเวียดนาม (Vietnamese White) พันธุ์ชมพูจินดา (Pink), พันธุ์แดงสยาม (Siam Red), พันธุ์แดงไต้หวัน (Taiwan Red), พันธุ์แดงทับทิม (Ruby Red) และ พันธุ์เหลืองอิสราเอล (Israel Yellow)

อัลกอริทึมสำหรับจำแนกคุณภาพของแก้วมังกรไทยจากภาพเฉพาะสายพันธุ์ขาวจัมโบ้ เนื่องจากเป็นสายพันธุ์ที่นิยมเพาะปลูก โดยวิธีการประมวลผลภาพ การสร้างกฎ การแยกคุณลักษณะตามเนื้อหา และการเรียนรู้ของเครื่อง

พื้นที่ที่ใช้เป็นแหล่งเก็บรวบรวมข้อมูลภาพแก้วมังกรไทยคือพื้นที่เพาะปลูกแก้วมังกรในเขตพื้นที่จังหวัดเลย ซึ่งเป็นพื้นที่ที่มีการเพาะปลูกแก้วมังกรมากที่สุดในประเทศ

1.3.2 ตัวแปร

- 1) ตัวแปรต้น ได้แก่ สายพันธุ์แก้วมังกรไทย 7 สายพันธุ์ ชั้นคุณภาพและขนาดของผลแก้วมังกรสายพันธุ์ขาวจัมโบ้
- 2) ตัวแปรตาม ได้แก่ ชุดข้อมูลภาพแก้วมังกรไทย อัลกอริทึมสำหรับจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ อัลกอริทึมสำหรับจำแนกคุณภาพและขนาดของแก้วมังกรไทยจากภาพ

1.3.3 นิยามศัพท์เฉพาะ

1) แก้วมังกร (Dragon Fruit) หมายถึงผลไม้ในวงศ์กระบองเพชร (Cactaceae) สกุล *Hylocercus spp.* และ *Selenicereus sp.* มีลักษณะทรงกลม เปลือกมีสีเหลืองหรือสีแดง มีกลีบรอบผล ปลายกลีบมีสีเขียว

2) ชุดข้อมูลภาพ (Image Dataset) หมายถึงชุดข้อมูลภาพถ่ายผลแก้วมังกรที่ปลูกในเขตพื้นที่จังหวัดเลย ประกอบไปด้วยชุดข้อมูลภาพถ่ายที่บันทึกในห้องปฏิบัติการและบันทึกในสภาวะแวดล้อมกลางแจ้ง

3) การจำแนกสายพันธุ์ (Species Classification) หมายถึงการตรวจหาหรือวิเคราะห์คุณลักษณะของแก้วมังกรไทย ที่สามารถระบุสายพันธุ์จากภาพได้

4) การจำแนกคุณภาพ (Quality Classification) หมายถึงการตรวจหาหรือวิเคราะห์คุณลักษณะของแก้วมังกรไทยหลังเก็บเกี่ยว ที่สามารถระบุชั้นคุณภาพและขนาดจากภาพได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5) การเรียนรู้ของเครื่อง หมายถึงกระบวนการสำหรับการเรียนรู้ของเครื่องในการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพถ่าย เช่น Deep Learning, k-Nearest Neighbor (k-NN), Naïve Bayes (NB), Support Vector Machine (SVM) เป็นต้น

1.3.4 ขั้นตอนการศึกษาและวิธีดำเนินงานวิจัย

- 1) สำรวจลงพื้นที่และศึกษาข้อมูลการเพาะปลูกแก้วมังกรในประเทศไทย
- 2) ศึกษางานวิจัยที่เกี่ยวข้องกับการสร้างชุดข้อมูลภาพ
- 3) ศึกษางานวิจัยที่เกี่ยวข้องกับการจำแนกสายพันธุ์แก้วมังกรไทย
- 4) ศึกษางานวิจัยที่เกี่ยวข้องกับการจำแนกชั้นคุณภาพและขนาดแก้วมังกรไทย
- 5) เก็บข้อมูลภาพแก้วมังกรที่เพาะปลูกในพื้นที่จังหวัดเลย
- 6) วิเคราะห์ออกแบบอัลกอริทึมสำหรับการจำแนกสายพันธุ์แก้วมังกรไทย
- 7) วิเคราะห์ออกแบบอัลกอริทึมสำหรับการจำแนกคุณภาพแก้วมังกรไทย
- 8) ทดสอบและประเมินประสิทธิภาพอัลกอริทึมสำหรับการจำแนกสายพันธุ์แก้วมังกรไทยและอัลกอริทึมสำหรับการจำแนกคุณภาพแก้วมังกรไทย ด้วยชุดข้อมูลภาพแก้วมังกรไทยที่สร้างขึ้น

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ได้ชุดข้อมูลภาพแก้วมังกรของไทย
- 2) ได้อัลกอริทึมสำหรับการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ
- 3) ได้อัลกอริทึมสำหรับการจำแนกคุณภาพแก้วมังกรไทยจากภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

สำหรับเนื้อหาในบทนี้จะกล่าวถึงคุณลักษณะทั่วไปของแก้วมังกร แนวคิดทฤษฎีเกี่ยวกับกระบวนการประมวลผลภาพดิจิทัล การแบ่งส่วนภาพ โมเดลการจำแนกภาพ การวัดประสิทธิภาพ โมเดล และงานวิจัยที่เกี่ยวข้องกับการจำแนกภาพ

2.1 แก้วมังกร


แก้วมังกร (Dragon Fruit) เป็นผลไม้ในวงศ์กระบองเพชร (Cactaceae) สกุล *Hylocercus Sp.* และ *Selenicereus Sp.* มีถิ่นกำเนิดทางตอนใต้ของประเทศเม็กซิโกและประเทศใกล้เคียง มีชื่อเรียกอื่นอีกว่า Pitaya, Pitahaya, Pithaya, Strawberry Pear, Night blooming Cereus, Belle of the night, Conderella plant หรือ Jesus in the Cradle (สุรพงษ์, 2556; Perween. et al., 2018) แก้วมังกรถูกนำเข้ามาปลูกในประเทศไทยตั้งแต่ปี พ.ศ. 2540 ซึ่ง ณ ขณะนั้นแก้วมังกรถือว่าเป็นผลไม้ที่ได้รับความสนใจเป็นอย่างมาก เนื่องจากลักษณะภายนอกที่แปลกตา สีสีนสวยงาม ถึงแม้ว่าในระยะแรกรสชาติของแก้วมังกรมีรสอมเปรี้ยวไม่ค่อยได้รับความนิยม จึงมีนักวิชาการและเกษตรกรได้ศึกษาพัฒนาปรับปรุงพันธุ์แก้วมังกรให้มีคุณภาพเพิ่มขึ้นเรื่อยมาจนถึงปัจจุบัน ให้มีรสชาติที่อร่อยขึ้น เนื้อของผลแก้วมังกรมีหลากสี ทั้งขาว แดง และชมพู นอกจากนี้ยังมีการนำสายพันธุ์แก้วมังกรเปลือกสีเหลืองทองมาทดลองปลูกและคัดต้นพันธุ์ ถือได้ว่าเป็นการเพิ่มทางเลือกให้กับผู้บริโภคได้เป็นอย่างดี แก้วมังกรเป็นผลไม้ฉ่ำน้ำ จึงซั้และเน่าเสียง่าย ต้องทะนุถนอม นำมารับประทานหรือแปรรูปโดยเร็ว การเก็บรักษาในตู้เย็นจะช่วยชะลอการเน่าเสียได้ (สุรพงษ์, 2556) นอกจากนี้แก้วมังกรเป็นผลไม้ที่มีคุณค่าทางโภชนาการสูง สามารถนำไปใช้ประโยชน์ในอุตสาหกรรมอาหาร ยา และเครื่องสำอางได้ (Goenaga. et al., 2020; Perween. et al., 2018; Trivellini. et al., 2020; Wichienchot. et al., 2010)

2.1.1 ข้อมูลทั่วไป

ลักษณะลำต้นแก้วมังกรเป็นกระบองเพชรเลื้อย ลำต้นสีเขียว 3 แฉก ดังรูปที่ 2.1 จึงต้องมีหลักและรั้วเล็กๆด้านบน โดยปลูกหลักละ 3-4 ต้น ชอบอากาศร้อน แต่ไม่ร้อนจัดหรือหนาวเย็นจนเกินไป ชอบดินร่วน ระบายน้ำดี (สุรพงษ์, 2556) ลักษณะผลแก้วมังกรมีลักษณะเป็นวงรี เปลือกจะมีสีชมพูอมแดง บางสายพันธุ์มีเปลือกสีเหลืองทอง ภายนอกเปลือกจะมีก้านเล็กๆอยู่ประมาณ 5-10 ก้าน โดยประมาณ ซึ่งถ้ามองดูอย่างผิวเผินจะเหมือนลูกแก้วมังกรบนหลังคาโบสถ์จีน เมื่อผ่าครึ่งลูกแก้วมังกรออกเป็น 2 ซีก พบว่าเนื้อของแก้วมังกรมีลักษณะโดยรอบของเนื้อเป็นวงกลมคล้ายลูกส้ม เนื้อจะกรอบนุ่ม มีสีขา แดง และชมพู ขึ้นอยู่กับสายพันธุ์ นอกจากนี้ภายในเนื้อแก้วมังกรจะมีเมล็ดคล้ายเมล็ดงาหรือเมล็ดแมงลักติดอยู่ สามารถเก็บเนื้อของแก้วมังกรไว้ได้นาน 2-3 อาทิตย์ขึ้นอยู่กับวิธีการรักษา (สุทธิสินี, 2543)



รูปที่ 2.1 ต้นแก้วมังกร



รูปที่ 2.2 ลักษณะภายในและภายนอกของผลแก้วมังกร

จากรูปที่ 2.2 (a) คือแก้วมังกรพันธุ์เหลืองอิสราเอล มีเปลือกสีเหลือง เนื้อข้างในมีสีขาว รูปที่ 2.2 (b) คือแก้วมังกรพันธุ์ขาวจัมโบ้ มีเปลือกสีแดงอมม่วง เนื้อข้างในมีสีขาว รูปที่ 2.2 (c) คือแก้วมังกรพันธุ์ชมพูจินดา มีเปลือกสีแดงอมม่วง เนื้อข้างในมีสีชมพู และ รูปที่ 2.2 (d) คือแก้วมังกรพันธุ์แดงทับทิม มีเปลือกสีแดงอมม่วง เนื้อข้างในมีสีแดงเข้ม

รสชาติของแก้วมังกรมีรสหวาน แต่ไม่หวานแหลมจนเกินไป หากจะเป็นรสหวานที่ให้ความรู้สึกรื่นเย็น มีความเปรี้ยวเล็กน้อย อันเป็นรสชาติที่กำลังดีของผู้ไม่ชอบบริโภคผลไม้รสจัดจนเกินไป (สุทธสิณี, 2543) โดยมีความหวานอย่างน้อย 13% Brix มีปริมาณกรดหรือความเปรี้ยว ร้อยละ 0.25-0.3 ในกรณีผลที่แก่ไม่พอจะมีรสเปรี้ยวและหวานน้อย ส่วนผลที่แก่เต็มที่รสเปรี้ยวก็จะลดลง (สุรพงษ์, 2556)

2.1.2 คุณค่าทางโภชนาการและสรรพคุณทางยา

แก้วมังกรเป็นผลไม้ที่ให้พลังงานต่ำ น้ำตาลที่พบส่วนใหญ่เป็นน้ำตาลกลูโคส ฟรุกโตส และซูโครส ในเนื้อของแก้วมังกรมีวิตามินซี โยอาหาร และโพแทสเซียมสูง โดยวิตามินซีมีส่วนช่วยในการกระตุ้นระบบภูมิคุ้มกัน โยอาหารช่วยให้รู้สึกอิ่มนานและทำให้การขับถ่ายดีขึ้น จึงน่าจะเหมาะกับผู้ที่ต้องการควบคุมระดับน้ำตาลในเลือดหรือควบคุมน้ำหนัก (กฤติยา, 2559)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นอกจากนี้แก้วมังกรยังอุดมด้วยแร่ธาตุต่างๆ และมีสารอาหารที่น่าสนใจ ตามการวิเคราะห์โดยนักวิจัยจากสิงคโปร์แห่งกรมการเกษตรของสิงคโปร์ (สุรพงษ์, 2556) ดังแสดงในตารางที่ 2.1

ตารางที่ 2.1 ส่วนประกอบของผลแก้วมังกรต่อส่วนที่รับประทานได้ 100 กรัม (สุรพงษ์, 2556)

คุณค่าทางโภชนาการ	ปริมาณ	
ความชื้น	85.30	กรัม
โปรตีนรวม	1.10	กรัม
ไขมัน	0.57	กรัม
กลูโคส	5.70	กรัม
ฟรุกโตส	3.20	กรัม
ซูโครส	0.00*	กรัม
ซอร์บิทอล	0.33	กรัม
คาร์โบไฮเดรต	11.20	กรัม
เส้นใยรวม	1.34	กรัม
เถ้า	0.56	กรัม
พลังงาน(กิโลแคลอรี)	67.70	กรัม
วิตามินซี	3.0	มิลลิกรัม
ไนอะซิน	2.8	มิลลิกรัม
วิตามินเอ	0.01	มิลลิกรัม
แคลเซียม	10.2	มิลลิกรัม
เหล็ก	3.37	มิลลิกรัม
แมกนีเซียม	38.9	มิลลิกรัม
ฟอสฟอรัส	27.5	มิลลิกรัม
โพแทสเซียม	272.0	มิลลิกรัม
โซเดียม	8.9	มิลลิกรัม
สังกะสี	0.35	มิลลิกรัม

จากการศึกษาพบว่าในพืชตระกูลกระบองเพชรมีสารมิวซิเลจ (Mucilage) อยู่เป็นจำนวนมาก สารจำพวกนี้คือ สารโพลีแซคคาไรด์เชิงซ้อน (Complex polysaccharides) ลักษณะคล้ายวุ้นเหลว มีคุณสมบัติในการดูดน้ำ ต้นกระบองเพชรบางชนิดมีปริมาณสารนี้ประมาณ 3% โดยปริมาตร ผลแก้วมังกรซึ่งเป็นผลจากพืชตระกูลกระบองเพชร จึงจัดได้ว่ามีสารชนิดนี้เหมือนกัน และมีคุณสมบัติทางสมุนไพร เช่น การบริโภคน้ำตาลได้หรือใบของกระบองเพชรจำพวกต้นเสมา จะช่วยลดและควบคุมน้ำตาลกลูโคสของคนที่เป็นโรคเบาหวาน เป็นต้น สำหรับผลแก้วมังกรเมื่อรับประทานเข้าไป จะเพิ่มธาตุเหล็ก ซึ่งจะช่วยบรรเทาโรคโลหิตจาง โดยเฉพาะสารวุ้นในเนื้อผลจะช่วยบรรเทาโรคเบาหวาน ลดคอเลสเตอรอล และไตรกลีเซอไรด์ เป็นต้น ส่วนผลแก้วมังกรเปลือกสีเหลืองทองจะมีสาร captine ช่วยบำรุงหัวใจได้ (นฤมล, 2537)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.3 สถานการณ์การการเพาะปลูกแก้วมังกรของไทย

จากการสืบค้นข้อมูลรายงานสถิติทางการเกษตร จากระบบสารสนเทศการผลิตทางการเกษตร กรมส่งเสริมการเกษตร กระทรวงเกษตรและสหกรณ์ ช่วงปี 2560-2565 ได้ข้อมูลดังตารางที่ 2.2 และ 2.3 พบว่าทั้งประเทศมีการเพาะปลูกแก้วมังกรทั้งหมด 62 จังหวัดจาก 77 จังหวัด รวมเนื้อที่ปลูกทั้งสิ้น 28,318.72 ไร่โดยเฉลี่ย จังหวัดที่มีการเพาะปลูกแก้วมังกรมากที่สุดคือจังหวัดเลย โดยมีเนื้อที่ปลูกเฉลี่ย 16,902.42 ไร่ คิดเป็นร้อยละ 59.69 ของเนื้อที่เพาะปลูกทั้งประเทศ จังหวัดที่มีเนื้อที่เพาะปลูกรองลงมาคือจังหวัดนครราชสีมา มีเนื้อที่ปลูกเฉลี่ย 2,128.96 ไร่ คิดเป็นร้อยละ 7.52 ของเนื้อที่เพาะปลูกทั้งประเทศ และจังหวัดสมุทรสาคร มีเนื้อที่ปลูกเฉลี่ย 1,181.17 ไร่ คิดเป็นร้อยละ 4.17 ของเนื้อที่เพาะปลูกทั้งประเทศ

หากพิจารณาจำนวนผลผลิตที่เก็บเกี่ยวได้ ดังตารางที่ 2.3 จังหวัดที่มีจำนวนผลผลิตมากที่สุดยังคงเป็นจังหวัดเลย สามารถเก็บเกี่ยวผลผลิตเฉลี่ยโดยประมาณได้มากถึง 22,910 ตัน ซึ่งมีจำนวนเกินครึ่งของผลผลิตทั้งประเทศ รองลงมาคือจังหวัดสมุทรสาคร สามารถเก็บเกี่ยวผลผลิตเฉลี่ยโดยประมาณ 3,310 ตัน และสกลนคร สามารถเก็บเกี่ยวผลผลิตเฉลี่ยโดยประมาณ 996 ตันตามลำดับ

ตารางที่ 2.2 ข้อมูลรายงานสถิติทางการเกษตรเรียงลำดับตามเนื้อที่ปลูก (Department of agricultural extension, Ministry of Agriculture and Cooperatives, 2022)

พื้นที่	เนื้อที่ปลูก (ไร่)	เนื้อที่เก็บเกี่ยวผลผลิต (ไร่)	ผลผลิตที่เก็บเกี่ยวได้ (กิโลกรัม)	ราคาที่เกษตรกรขายได้เฉลี่ย (บาท/กิโลกรัม)
ทั้งประเทศ (62 จังหวัด)	28,318.72	14,837.28 (52.39%)	32,627,969.14	14.10
1. เลย	16,902.42	10,767.67	22,910,597.67	11.99
2. นครราชสีมา	2,128.96	635.50	996,661.00	22.23
3. สมุทรสาคร	1,181.17	730.17	3,310,960.00	16.38

ตารางที่ 2.3 ข้อมูลรายงานสถิติทางการเกษตรเรียงลำดับตามผลผลิตที่เก็บเกี่ยวได้ (Department of agricultural extension, Ministry of Agriculture and Cooperatives, 2022)

พื้นที่	เนื้อที่ปลูก (ไร่)	เนื้อที่เก็บเกี่ยวผลผลิต (ไร่)	ผลผลิตที่เก็บเกี่ยวได้ (กิโลกรัม)	ราคาที่เกษตรกรขายได้เฉลี่ย (บาท/กิโลกรัม)
ทั้งประเทศ (62 จังหวัด)	28,318.72	14,837.28 (52.39%)	32,627,969.14	14.10
1. เลย	16,902.42	10,767.67	22,910,597.67	11.99
3. สมุทรสาคร	1,181.17	730.17	3,310,960.00	16.38
2. นครราชสีมา	2,128.96	635.50	996,661.00	22.23

นอกจากนี้ จากข้อมูลในตารางที่ 2.2 หากพิจารณาราคาที่เกษตรกรขายได้เฉลี่ยทั้งประเทศเท่ากับ 14.10 บาทต่อกิโลกรัม ซึ่งจังหวัดเลยเป็นจังหวัดที่มีพื้นที่เพาะปลูกและจำนวนผลผลิตที่เก็บเกี่ยวได้สูงที่สุด แต่เกษตรกรขายแก้วมังกรได้ในราคาที่ต่ำกว่าราคาเฉลี่ยของทั้งประเทศนั่นคือ 11.99 บาทต่อกิโลกรัม ซึ่งต่ำกว่าราคาเฉลี่ยของทั้งประเทศถึง 2.11 บาทต่อกิโลกรัม หรือคิดเป็นร้อยละ 15.03 ของราคาเฉลี่ยของทั้งประเทศ

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บาทต่อกิโลกรัม ในขณะที่จังหวัดสมุทรสาคร มีจำนวนผลผลิตที่เก็บเกี่ยวได้รองลงมา เกษตรกรขาย แก้วมังกรได้ในราคาที่สูงกว่าราคาเฉลี่ยของทั้งประเทศ คือ 16.38 บาทต่อกิโลกรัม และจังหวัด นครราชสีมาที่มีพื้นที่เพาะปลูกรองลงมาจากจังหวัดเลยแต่มีจำนวนผลผลิตที่เก็บเกี่ยวได้น้อยกว่า จังหวัดเลยเกือบ 23 เท่า กลับขายแก้วมังกรได้ในราคาที่สูงกว่าราคาเฉลี่ยของทั้งประเทศมากถึง 22.23 บาทต่อกิโลกรัม คิดเป็น 1.6 เท่าของราคาเฉลี่ยของทั้งประเทศ ถือได้ว่าเป็นตัวเลขที่บ่งบอกถึง ปัญหาสินค้าล้นตลาดควรแก่การเร่งแก้ไข

2.1.3 มาตรฐานสินค้าเกษตรเพื่อการส่งออกแก้วมังกรของไทย

ด้วยแก้วมังกรเป็นสินค้าเกษตรที่ประเทศไทยมีศักยภาพในการผลิต สามารถปลูกได้หลายพื้นที่ ของประเทศและเป็นที่ยอมรับของผู้บริโภค ปัจจุบันประเทศไทยมีการนำเข้าและส่งออกแก้วมังกร การกำหนดมาตรฐานแก้วมังกร จึงมีความสำคัญต่อการพัฒนาคุณภาพและความปลอดภัย สร้างความ น่าเชื่อถือให้เป็นที่ยอมรับมากขึ้น ทั้งในประเทศและการค้าระหว่างประเทศ คณะกรรมการมาตรฐาน สินค้าเกษตร สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ กระทรวงเกษตรและสหกรณ์ จึงเห็นสมควรให้ จัดทำมาตรฐานสินค้าเกษตร เรื่อง แก้วมังกร ประกาศใช้เมื่อปี พ.ศ. 2558 โดยสาระสำคัญดังนี้

มาตรฐานสินค้าเกษตรนี้ ใช้กับผลแก้วมังกร (pitayas, pitahayas, dragon fruit) ซึ่งได้มา จากพืชที่มีชื่อวิทยาศาสตร์ว่า *Selenicereus sp.* และ *Hylocereus spp.* วงศ์ Cactaceae พันธุ์ที่ผลิตเป็นการค้าเพื่อจำหน่ายในรูปผลผลิตสด หลังการจัดเตรียมและการบรรจุแล้ว โดยแบ่งแก้ว มังกรออกเป็น 3 กลุ่ม ซึ่งมีความแตกต่างที่เปลือก (Peel/Skin) และสีเนื้อข้างใน (Pulp) ได้แก่ กลุ่ม ที่ 1 เปลือกสีแดงเนื้อสีขาว (*Hylocereus undatus*), กลุ่มที่ 2 เปลือกสีแดงเนื้อสีแดง (*Hylocereus polyrhizus*) หรือ เปลือกสีแดงเนื้อชมพู (*Hylocereus spp.*) และกลุ่มที่ 3 เปลือกสีเหลืองหรือทอง เนื้อสีขาว (*Hylocereus sp.* และ *Selenicereus sp.*)

การแบ่งชั้นคุณภาพแก้วมังกรตามมาตรฐานสินค้าเกษตรนี้ แบ่งเป็น 3 ชั้นคุณภาพ ได้แก่ ชั้นพิเศษ (Extra class) ชั้นหนึ่ง (Class I) และชั้นสอง (Class II) โดยแก้วมังกรทุกชั้นคุณภาพต้อง เป็นไปตามข้อกำหนดขั้นต่ำ ซึ่งระบุว่าคุณภาพของแก้วมังกรขั้นต่ำต้องเป็นแก้วมังกรทั้งผล มีหัวและหรือ ส่วนของกิงติดอยู่ โดยมีความยาวไม่เกิน 2 เซนติเมตร ตรงตามพันธุ์ สด เนื้อแน่น ไม่มีหนาม สภาพดี ไม่มีรอยช้ำหรือไม่เน่าเสียที่ทำให้ไม่เหมาะสมต่อการบริโภค สะอาด ปราศจากสิ่งแปลกปลอม ที่มองเห็นได้ไม่มีรอยปริหรือรอยแตกที่มีผลกระทบต่อคุณภาพของ เนื้อแก้วมังกร ไม่มีศัตรูพืช ที่มีผลกระทบต่อรูปลักษณะทั่วไปของผล ไม่มีความเสียหายจากศัตรูพืช ที่มีผลกระทบต่อคุณภาพ ของเนื้อแก้วมังกร ไม่มีความชื้น ที่ผิดปกติจากภายนอก ทั้งนี้ไม่รวมถึงหยดน้ำที่เกิดหลังจากนำแก้วมังกรออกจากห้องเย็น ไม่มีความเสียหาย เนื่องจากอุณหภูมิต่ำ และหรืออุณหภูมิสูง และไม่มีการ และหรือรสชาติที่ผิดปกติ เว้นแต่จะมีข้อกำหนดเฉพาะของแต่ละชั้นคุณภาพ และเกณฑ์ความคลาดเคลื่อนที่ยอมรับได้ ตามที่ระบุไว้ แก้วมังกรต้องมีอายุการเก็บเกี่ยวที่เหมาะสม ขึ้นอยู่กับพันธุ์ ฤดูกาล แหล่งที่ปลูก และ หรือความต้องการของตลาด และอยู่ในสภาพที่ยอมรับได้เมื่อถึงปลายทาง

แก้วมังกรคุณภาพชั้นพิเศษ (Extra class) คือแก้วมังกรที่มีคุณภาพดีที่สุด ไม่มีความผิดปกติ ด้านรูปทรง ไม่มีตำหนิที่ผิวและเปลือก ในกรณีที่มีความผิดปกติหรือมีตำหนิ ต้องมองเห็นได้ไม่ชัดเจน และไม่มีผลกระทบต่อรูปลักษณะทั่วไป คุณภาพของเนื้อแก้วมังกร คุณภาพระหว่างการเก็บรักษา และ

เอกสารนี้เป็นลิขสิทธิ์ของสำนักงานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แก้วมังกรคุณภาพชั้นหนึ่ง (Class I) คือแก้วมังกรที่มีคุณภาพดี อาจมีความผิดปกติหรือตำหนิเล็กน้อยด้านรูปร่าง ตำหนิเล็กน้อยที่ผิวและเปลือก เช่น รอยขีดข่วน รอยแผลเป็นตื้นๆ และร่องรอยการทำลายของศัตรูพืช โดยขนาดของตำหนิที่ผิวและเปลือกโดยรวมต้องไม่เกินร้อยละ 5 ของพื้นที่ผิวของแก้วมังกร ทั้งนี้ความผิดปกติหรือตำหนิต้องไม่มีผลกระทบต่อรูปลักษณ์ทั่วไป คุณภาพของเนื้อแก้วมังกร คุณภาพระหว่างการเก็บรักษา และการจัดเรียงเสนอในภาชนะบรรจุ

แก้วมังกรคุณภาพชั้นสอง (Class II) คือแก้วมังกรที่มีคุณภาพไม่เข้าขั้นที่สูงกว่า แต่มีคุณภาพตามข้อกำหนดขั้นต่ำ แก้วมังกรในชั้นนี้อ่อนนุ่มทำให้มีความผิดปกติด้านรูปร่าง หรือตำหนิที่ผิวและเปลือก เช่น รอยขีดข่วน รอยแผลเป็นตื้นๆ และร่องรอยการทำลายของศัตรูพืช โดยขนาดของตำหนิที่ผิวและเปลือกโดยรวมต้องไม่เกินร้อยละ 10 ของพื้นที่ผิวของแก้วมังกร ทั้งนี้ความผิดปกติหรือตำหนิต้องไม่มีผลกระทบต่อรูปลักษณ์ทั่วไป คุณภาพของเนื้อแก้วมังกร คุณภาพระหว่างการเก็บรักษา และการจัดเรียงเสนอในภาชนะบรรจุ

สำหรับการจัดขนาดของแก้วมังกรพิจารณา จากน้ำหนักต่อผล ดังตารางที่ 2.4 และวิธีวิเคราะห์คุณภาพให้ใช้ขั้นตอนวิธีการดังตารางที่ 2.5

ตารางที่ 2.4 ขนาดของแก้วมังกร (National Bureau of Agricultural Commodity and Food Standards, Ministry of Agriculture and Cooperatives, 2015)

รหัสขนาด	น้ำหนักต่อผล(กรัม)		
	ผิวสีแดง เนื้อสีขาว (<i>Hylocereus undatus</i>)	ผิวสีแดง เนื้อสีแดง หรือ ผิวสีแดง เนื้อสีชมพู (<i>Hylocereus spp.</i>)	ผิวสีเหลืองหรือทอง เนื้อสีขาว (<i>Hylocereus sp.</i> และ <i>Selenicereus sp.</i>)
1	>600	>500	>350
2	>500-600	>400-500	>250-350
3	>400-500	>300-400	>200-250
4	>300-400	>250-300	>150-200
5	>250-300	200-250	100-150
6	>200-250	-	-


ตารางที่ 2.5 วิธีวิเคราะห์คุณภาพแก้วมังกร (National Bureau of Agricultural Commodity and Food Standards, Ministry of Agriculture and Cooperatives, 2015)

ข้อกำหนด	วิธีวิเคราะห์	หลักการ
1. คุณภาพตามข้อกำหนดขั้นต่ำ	ตรวจพินิจและการใช้ประสาทสัมผัส	-
2. ความผิดปกติด้านรูปร่าง	ตรวจพินิจ	-
3. ตำหนิที่ผิวและเปลือก	ตรวจพินิจและวัดขนาดเพื่อคำนวณพื้นที่ผิว	-
4. ขนาด	ชั่งน้ำหนัก	การวิเคราะห์โดย น้ำหนัก (Gravimetry)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2.2 โมเดลสี (Color Model)

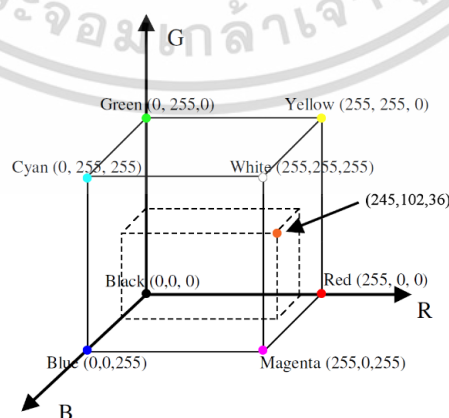
โมเดลสี (Color Model) เป็นระบบสีที่มีโครงสร้างของสีหลัก (Primary Color) ประกอบกันหลายช่องสัญญาณเกิดเป็นช่วงสี (Range of Colors) ที่สามารถนำมาแทนค่าสีที่มนุษย์มองเห็นในธรรมชาติได้ โดยโมเดลสีแต่ละประเภทมีการสร้างสีด้วยวิธีการที่แตกต่างกัน ทำให้มีโครงสร้างที่แตกต่างกัน ดังรูปที่ 2.4 ดังนั้นโมเดลสีแต่ละประเภทจึงถูกนำมาใช้เพื่อวัตถุประสงค์ที่แตกต่างกัน (Przybylek and Cena, 2021) ในที่นี้จะกล่าวถึงโมเดลสีที่นิยมนำมาใช้ในการประมวลผลภาพ ได้แก่ โมเดลสี RGB, HSV และ Lab



รูปที่ 2.4 แบบจำลองโมเดลสี (a) RGB (b) HSV และ (c) Lab (Phuangsaikai. et al.,2021)

2.2.2.1 โมเดลสี RGB

โมเดลสี RGB เป็นระบบสีที่เกิดจากการรวมกันของแม่สี (Primary Color) ทั้ง 3 สี ได้แก่ สีแดง (Red), สีเขียว (Green) และสีน้ำเงิน (Blue) ซึ่งเป็นช่องสัญญาณ (Channel) ของภาพดิจิทัลสี โดยแม่สีแต่ละสีมีระดับสีตั้งแต่ 0-255 ระดับ หากจำลองโมเดลสี RGB ในรูปแบบสามมิติจะได้แบบจำลองดังรูปที่ 2.5 ถ้ากำหนดค่าระดับสีให้แม่สี RGB (245,102,36) จะแสดงผลเป็นสีส้ม ถ้ากำหนดค่าระดับสีของแม่สีทั้งสามด้วยค่าสูงสุดคือ RGB (255,255,255) จะแสดงผลเป็นสีขาว ในทางกลับกันถ้ากำหนดค่าระดับสีของแม่สีทั้งสามด้วยค่าต่ำสุดคือ RGB (0,0,0) จะแสดงผลเป็นสีดำ เนื่องจากโมเดลสี RGB เป็นโมเดลสีแบบ additive นอกจากนี้โมเดลสี RGB เป็นระบบสีอิงอุปกรณ์ (device-dependent model) ในการแสดงผลของภาพเดียวกันด้วยอุปกรณ์ที่แตกต่างกัน อาจส่งผลให้ได้ค่าสี RGB ผลลัพธ์ที่แตกต่างกันได้ (Parekh, 2021)




รูปที่ 2.5 แบบจำลองสามมิติโมเดลสี RGB (ดัดแปลงจาก Ramella and Baja, 2013)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการประมวลผลภาพดิจิทัลเราสามารถแยกช่องสัญญาณของ RGB จาก 3 ช่องสัญญาณ เป็นช่องสัญญาณเดี่ยว (Single channel) ได้ ผลลัพธ์ที่ได้จะเป็นภาพระดับเทา ซึ่งการแยกช่องสัญญาณนี้ทำให้ง่ายต่อการนำไปประมวลผลมากกว่าการประมวลผลพร้อมกัน 3 ช่องสัญญาณ

2.2.2.2 โมเดลสี HSV

โมเดลสี HSV เป็นโมเดลสีที่มีความใกล้เคียงกับการรับรู้สีจากการมองเห็นของมนุษย์ ซึ่งประกอบด้วย Hue (H), Saturation (S) และ Value (V) ดังรูปที่ 2.6 โดย Hue คือโทนสีที่ถูกระบุด้วยค่ามุม (Angle) ของวงล้อสี (Color Wheel) ซึ่งมีค่าตั้งแต่ 0° - 360° โดย 0° หมายถึงสีแดง 60° หมายถึงสีเหลือง และ 120° หมายถึงสีเขียว ซึ่งในการประมวลผลภาพด้วย OpenCV ค่า Hue จะเหลือครึ่งหนึ่งนั่นคือ 0° - 180° นั่นหมายความว่า 0° หมายถึงสีแดง 30° หมายถึงสีเหลือง และ 60° หมายถึงสีเขียว Saturation คือค่าความอิ่มตัวของโทนสี ถ้าค่าความอิ่มตัวเท่ากับ 0 จะแสดงผลเป็นสีขาวเสมอ และ Value คือค่าความสว่างของโทนสี ถ้าค่าความสว่างเท่ากับ 0 จะแสดงผลเป็นสีดำ ในการประมวลผลภาพด้วย OpenCV ค่า Saturation และ ค่า Value จะมีค่าตั้งแต่ 0-255 ถ้ากำหนดให้ทั้งสองค่าเท่ากับ 255 จะแสดงผลตามโทนสีได้ชัดเจน เช่น สีแดงบริสุทธิ์ (Red Pure) จะมีค่า HSV (0,255,255) เป็นต้น (Burger and Burge, 2009; Opencv Python Tutorials, 2016)



รูปที่ 2.6 แบบจำลองสามมิติโมเดลสี HSV (ดัดแปลงจาก Li. et al., 2017)

แต่ด้วยการบันทึกภาพในปัจจุบันส่วนใหญ่ภาพที่ได้จะอยู่ในรูปแบบโมเดลสี RGB ดังนั้นหากต้องการประมวลผลภาพด้วยโมเดลสี HSV จะต้องทำการแปลงข้อมูลภาพจากโมเดลสี RGB เป็น HSV ดังสมการที่ 2.1-2.3 ตามลำดับ (Opencv Python Tutorials, 2016) ซึ่งจะได้ผลลัพธ์ดังรูปที่ 2.7

$$V \leftarrow \max(R, G, B) \quad (2.1)$$

$$S \leftarrow \begin{cases} \frac{V - \min(R, G, B)}{V} & \text{if } V \neq 0 \\ 0 & \text{otherwise} \end{cases} \quad (2.2)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$H \leftarrow \begin{cases} 60(G - B)/(V - \min(R, G, B)) & \text{if } V = R \\ 120 + 60(B - R)/(V - \min(R, B, B)) & \text{if } V = G \\ 240 + 60(R - G)/(V - \min(R, B, B)) & \text{if } V = B \\ 0 & \text{if } R = G = B \end{cases} \quad (2.3)$$


กำหนดให้ R แทน รหัสพิกเซลของภาพในช่องสัญญาณ Red Channel
 G แทน รหัสพิกเซลของภาพในช่องสัญญาณ Green Channel
 B แทน รหัสพิกเซลของภาพในช่องสัญญาณ Blue Channel
 H แทน รหัสพิกเซลของภาพในช่องสัญญาณ Hue Channel
 S แทน รหัสพิกเซลของภาพในช่องสัญญาณ Saturation Channel
 V แทน รหัสพิกเซลของภาพในช่องสัญญาณ Value Channel
 โดยผลลัพธ์ ถ้า $H < 0$ แล้ว $H = H + 360$ และ $0 \leq V \leq 1$, $0 \leq S \leq 1$, $0 \leq H \leq 360$
 หากเป็นภาพ 8 บิต ค่า $V = 255 * V$, $S = 255 * S$ และ $H = H / 2$



รูปที่ 2.7 ตัวอย่างการแปลงภาพโมเดลสี RGB เป็นภาพโมเดลสี HSV (Joseph, 2012)

2.2.2.3 โมเดลสี Lab

โมเดลสี Lab เป็นโมเดลสีที่ประกอบด้วย 3 องค์ประกอบได้แก่ L คือค่าความสว่าง (Lightness) มีค่าตั้งแต่ 0 (สีดำ) ถึง 100 (สีขาว) a คือค่าแสดงการไล่สีจากสีเขียวไปยังสีแดง มีค่าตั้งแต่ -128 (สีเขียว) ถึง +127 (สีแดง) และ b คือค่าแสดงการไล่สีจากสีน้ำเงินถึงสีเหลือง มีค่าตั้งแต่ -128 (สีน้ำเงิน) ถึง +127 (สีเหลือง) โดยแบบจำลองโมเดลสี Lab สามารถแสดงได้ดังรูปที่ 2.8 โมเดลสี Lab เป็นโมเดลสีที่ไม่อิงอุปกรณ์ (device-independent model) หมายความว่าในการแสดงผลของภาพเดียวกันด้วยอุปกรณ์ที่แตกต่างกัน ไม่ส่งผลให้ค่า Lab เปลี่ยนไป จะยังคงได้ค่าเดิมเสมอ ถือเป็นข้อดีของโมเดลสีนี้ ในการประมวลผลภาพด้วย OpenCV ค่า Lab จะถูกปรับให้อยู่ในช่วง 0-255 ทั้ง 3 ช่องสัญญาณ (Opencv Python Tutorials, 2016; Parekh, 2021)



รูปที่ 2.8 แบบจำลองโมเดลสี Lab (Beetsma, 2020)

หากต้องการประมวลผลภาพด้วยโมเดลสี Lab จะต้องทำการแปลงข้อมูลภาพจากโมเดลสี RGB เป็น Lab ดังสมการที่ 2.4-2.11 ตามลำดับ (Opencv Python Tutorials, 2016) ซึ่งจะได้ผลลัพธ์ดังรูปที่ 2.9 (Rosebrock, 2021)

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \leftarrow \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.4)$$

$$X \leftarrow X/X_n, \text{ Where } X_n = 0.950456 \quad (2.5)$$

$$Z \leftarrow Z/Z_n, \text{ Where } Z_n = 1.088754 \quad (2.6)$$

$$L \leftarrow \begin{cases} 116 * Y^{1/3} - 16, & \text{for } Y > 0.008856 \\ 903.3 * Y, & \text{for } Y \leq 0.008856 \end{cases} \quad (2.7)$$

$$f(t) = \begin{cases} t^{1/3} & , \text{for } t > 0.008856 \\ 7.787t + 16/116 & , \text{for } t \leq 0.008856 \end{cases} \quad (2.8)$$

$$\text{delta} = \begin{cases} 128 & , \text{for } 8\text{-bit image} \\ 0 & , \text{for floating-point image} \end{cases} \quad (2.9)$$


$$a \leftarrow 500(f(X) - f(Y)) + \text{delta} \quad (2.10)$$

$$b \leftarrow 200(f(Y) - f(Z)) + \text{delta} \quad (2.11)$$

กำหนดให้ R แทน รหัสพิกเซลของภาพในช่องสัญญาณ Red Channel
 G แทน รหัสพิกเซลของภาพในช่องสัญญาณ Green Channel
 B แทน รหัสพิกเซลของภาพในช่องสัญญาณ Blue Channel
 L แทน รหัสพิกเซลของภาพในช่องสัญญาณ Lightness Channel
 a แทน รหัสพิกเซลของภาพในช่องสัญญาณ a Channel
 b แทน รหัสพิกเซลของภาพในช่องสัญญาณ b Channel

โดยผลลัพธ์ หากเป็นภาพ 8 บิต ค่า $L=L*255/100$, $a = a+128$ และ $b = b+128$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.9 ตัวอย่างการแปลงภาพโมเดลสี RGB เป็นภาพโมเดลสี Lab (Rosebrock, 2021)

2.2.3 ประเภทของภาพดิจิทัล (Digital Image Types)

ประเภทของภาพดิจิทัลที่ใช้ในการประมวลผลภาพมี 3 ประเภท ได้แก่ ภาพสี (Color Image) ภาพระดับเทา (Gray Level Image) และภาพสองระดับ (Binary Image) (สนั่น, 2556)

2.2.3.1 ภาพสี (Color Image)

ภาพสีจะประกอบด้วยช่องสัญญาณ (Channel) ของโมเดลสี (Color Model) ที่ใช้ในการแสดงผลภาพ ดังรูปที่ 2.10 แสดงตัวอย่างภาพสีในโมเดลสี RGB ซึ่งเป็นโมเดลสีที่คอมพิวเตอร์ใช้ในการแสดงผลภาพ จะประกอบด้วยเมทริกซ์ 2 มิติ ของค่าพิกเซลของแต่ละพิกัด (x,y) ทั้งหมด 3 ช่องสัญญาณ ได้แก่ Red Channel, Green Channel และ Blue Channel แต่ละช่องสัญญาณจะใช้พื้นที่ในการจัดเก็บ 8 บิต ดังนั้นแต่ละพิกเซลของภาพสีจึงใช้พื้นที่ในการจัดเก็บ 24 บิต ทำให้สามารถแสดงสีได้ประมาณ 16.7 ล้านสี (สนั่น, 2556; Gonzalez. et al., 2004)




รูปที่ 2.10 ระบบพิกัดของภาพสี (Elgendy, 2020)

2.2.3.2 ภาพระดับเทา (Gray Scale Image)

ภาพระดับเทาคือภาพที่ไม่มีสี เป็นภาพที่แสดงถึงระดับความเข้มของแสง โดยทั่วไปแต่ละพิกเซลจะมีขนาดพื้นที่ในการจัดเก็บข้อมูล 8 บิต สามารถแสดงระดับความเข้มของแสงได้ 256 ระดับ จากมืด (สีดำ) ซึ่งมีค่าเป็น 0 ไปจนถึงสว่าง (สีขาว) นอกจากนี้ภาพระดับเทาสามารถเก็บรายละเอียดของพื้นผิว (Texture) ของวัตถุในภาพได้เป็นอย่างดี ซึ่งพื้นผิวของวัตถุภายในภาพสามารถนำไปใช้ในการวิเคราะห์ภาพได้ (สนั่น, 2556) ดังตัวอย่างในรูปที่ 2.11

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.11 ระบบพิกัดของภาพระดับเทา (Marques, 2011)


แต่ด้วยภาพดิจิทัลทั่วไปจะถูกบันทึกในรูปแบบภาพสี RGB ดังนั้นหากต้องการแสดงผลภาพระดับเทาต้องทำการแปลงภาพจากระบบสีอาร์จีบี (RGB) เป็น ระดับสีเทา (Gray Scale) โดยใช้สมการที่ 2.12 ในการแปลง (Opencv Python Tutorials, 2016)

$$\text{Gray}(x,y) = 0.299 * R(x,y) + 0.587 * G(x,y) + 0.114 * B(x,y) \quad (2.12)$$

โดย Gray(x,y) แทน ค่าความเข้มของระดับสีเทา ณ ตำแหน่ง (x,y)
 R(x,y) แทน ค่าความเข้มของสีแดง ณ ตำแหน่ง (x,y)
 G(x,y) แทน ค่าความเข้มของสีเขียว ณ ตำแหน่ง (x,y)
 B(x,y) แทน ค่าความเข้มของสีน้ำเงิน ณ ตำแหน่ง (x,y)

2.2.3.3 ภาพสองระดับ (Binary Image)

ภาพสองระดับคือภาพขาวดำ แต่ละพิกเซลจะมีเพียง 2 รหัสคือขาวและดำ โดยแทนเป็นรหัส 0 หรือ 1 ภาพสองระดับนิยมนำมาใช้ในการวิเคราะห์ภาพเช่นเดียวกัน แต่เนื่องจากมีแค่ 2 ระดับ ดังนั้นรายละเอียดของภาพจึงหายไปมีเพียงแต่ภาพโครงร่างของวัตถุเท่านั้น ดังตัวอย่างในรูปที่ 2.12 อย่างไรก็ตามภาพสองระดับอาจเป็นผลลัพธ์ที่เกิดจากการทำการประมวลผลภาพก็ได้ เช่นการหาขอบภาพ หรือการแยกวัตถุออกจากพื้นหลัง เป็นต้น (สนั่น, 2556)



รูปที่ 2.12 ระบบพิกัดของภาพสองระดับ (Marques, 2011)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3 การประมวลผลภาพ

การประมวลผลภาพ (Image Processing) คือวิธีการหรืออัลกอริทึมที่ใช้ภาพเป็นข้อมูลนำเข้า สำหรับการประมวลผลบางอย่างเพื่อให้ได้ผลลัพธ์ตามความต้องการ อาจประมวลผลภาพเพื่อตกแต่งภาพ ตัดต่อแก้ไขภาพ การปรับความสว่าง การทำให้ภาพคมชัด การทำให้ภาพมีรายละเอียดมากขึ้นกว่าเดิม การค้นหาองค์ประกอบภาพหรือลักษณะเด่นภายในภาพ เป็นต้น (สนั่น, 2556) ซึ่งอาจใช้เทคนิคการปรับขนาดภาพ (image resizing) เทคนิคการแปลงภาพสีเป็นภาพโทนเทา (convert color image to grayscale) เทคนิคการเพิ่มข้อมูลภาพ (Data Augmentation) หรือเทคนิคอื่นๆ (Elgendy, 2020) ที่สามารถประมวลผลภาพได้ตามความต้องการตามวัตถุประสงค์ที่กำหนดไว้ การประมวลผลภาพสามารถแบ่งเป็น 3 ระดับ ได้แก่ การประมวลผลภาพระดับต่ำ (Low-level Image Processing) การประมวลผลภาพระดับกลาง (Low-Level Image Processing) และการประมวลผลภาพระดับสูง (High-level Image Processing) (Gonzalez. et al., 2004; Marques, 2011)

การประมวลผลภาพระดับต่ำ เป็นการประมวลผลขั้นแรกหลังจากนำเข้าข้อมูลภาพลงในเครื่องคอมพิวเตอร์ ภาพที่ได้อาจมีส่วนที่ต้องการและไม่ต้องการปะปนกันอยู่ อาจมาในรูปแบบสัญญาณรบกวน (noise) ดังนั้นการประมวลผลภาพในระดับต่ำจึงประกอบด้วยวิธีการกำจัดสัญญาณรบกวน การทำให้ภาพให้คมชัด เพื่อให้ภาพมีคุณภาพมากขึ้น อินพุตและเอาต์พุตของการประมวลผลภาพระดับต่ำเป็นภาพ เหมาะแก่การนำไปประมวลผลในระดับต่อไป (Gonzalez. et al., 2004)

การประมวลผลภาพระดับกลาง เป็นการประมวลผลภาพที่เกี่ยวข้องกับงานต่างๆ เช่น การค้นหาองค์ประกอบภาพหรือลักษณะเด่นภายในภาพ (Extraction of attributes) การใช้อัลกอริทึมหรือกระบวนการประมวลผลภาพเพื่อระบุขอบภาพ (Edges Detection) แบ่งแยกรูปร่างวัตถุหรือข้อมูลภายในภาพออกจากกันเป็นส่วน (Image Segmentation) ตามวัตถุประสงค์ของการนำไปใช้อินพุตของการประมวลผลภาพระดับกลางเป็นภาพ แต่เอาต์พุตเป็นคุณลักษณะที่ดึงมาจากภาพ หรือเรียกว่า ฟีเจอร์ (Feature) ของภาพที่ถูกสกัด มีได้หลายแบบยกตัวอย่างเช่น สี (Color) พื้นผิว (Texture) รูปร่าง (Shape) ขอบภาพ (Edge) หรือเอกลักษณ์ของวัตถุแต่ละชิ้น เป็นต้น ซึ่งฟีเจอร์เหล่านี้จะเป็นข้อมูลในการวิเคราะห์ภาพในการประมวลผลภาพระดับสูงต่อไป (Gonzalez. et al., 2004)

การประมวลผลภาพระดับสูงเป็นการใช้ข้อมูลฟีเจอร์หรือผลลัพธ์จากการประมวลผลระดับกลางด้วยกระบวนการหรืออัลกอริทึม มีวัตถุประสงค์เพื่อให้คอมพิวเตอร์รู้จักและเข้าใจเนื้อหาของภาพได้ ส่งผลให้คอมพิวเตอร์สามารถจำแนกข้อมูลภาพ (Image Classification) ได้ หรือสามารถตรวจจับวัตถุในภาพ (Object Detection) ได้ ขึ้นอยู่กับวัตถุประสงค์ที่กำหนดไว้

จากการประมวลผลภาพทั้ง 3 ระดับ จะเห็นว่าการประมวลผลภาพไม่ได้เป็นกระบวนการเพียงแค่ปรับปรุงภาพหรือปรับเปลี่ยนภาพเพียงอย่างเดียว แต่ครอบคลุมถึงการวิเคราะห์ภาพ (Image Analysis) ด้วย ดังนั้นขั้นตอนของการประมวลผลภาพ จึงประกอบไปด้วย การเก็บข้อมูลภาพ (Image Acquisition) การเตรียมข้อมูลภาพ (Image Pre-processes) การแยกคุณลักษณะ (Feature Extraction) และการจำแนกภาพ (Image Classification) (Hameed. et al., 2018)

2.3.1 การเก็บข้อมูลภาพ (Image Acquisition)

การเก็บข้อมูลภาพหมายถึงวิธีการเก็บข้อมูลภาพด้วยเซนเซอร์ (Sensor) ทั้งในรูปแบบภาพ (Visual) และ ไม่ใช่ภาพ (non-visual) ขึ้นอยู่กับคุณลักษณะของข้อมูล ซึ่งมี 7 วิธี (Hameed. et al., 2018) ดังตารางที่ 2.6

ตารางที่ 2.6 การเปรียบเทียบเซนเซอร์สำหรับการจำแนกประเภทผลไม้และผัก (Hameed. et al., 2018)

Sensors	Visual /Non-visual	Sensor type	Features exploited	Advantages	Disadvantages
ภาพขาวดำ (B/W)	Visual	Passive	เรขาคณิต และพื้นผิว	มีผลเล็กน้อยจากแสง	วัตถุไม่มีสี
ภาพสี (RGB)	Visual	Passive	เรขาคณิต พื้นผิว และสี	สามารถใช้ประโยชน์จากลักษณะพื้นฐานทั้งหมดของวัตถุ	มีความไวต่อแสงสูง
สเปกตรัม (Spectral)	Visual	Passive	ข้อมูลสีและข้อมูลสเปกตรัม	มีข้อมูลเพิ่มเติมเกี่ยวกับการสะท้อนแสง	ใช้ทรัพยากรสูงในการคำนวณ
ความร้อน (Thermal)	Visual	Passive	สัญญาณบ่งบอกพลังงานความร้อน	ไม่แปรผันกับสีของวัตถุ	ขึ้นอยู่กับความแตกต่างของอุณหภูมิและเวลา
ภาพสีที่มีความลึก (RGBD, LSS)	Visual	Active	ภาพสีแบบ RGB และความลึกจากแสง	ได้ลักษณะภาพที่สมบูรณ์	ไม่มีตัวอธิบายคุณลักษณะ
ผิวสัมผัส (Tactile)	Non-visual	Passive	ความหยาบ, พื้นผิว, แรงเสียดทาน และเส้นโค้งเชิงพื้นที่	ใช้งานได้ดีกับสีและรูปร่างเดียวกัน	มีข้อจำกัดกับการวิเคราะห์ข้อมูลที่มีความแตกต่างกัน
อะคูสติก (Acoustic)	Non-visual	Both	ความยืดหยุ่นและสหสัมพันธ์	สามารถวิเคราะห์ความสดและความแน่นของผลไม้และผักได้	มีความบิดเบือนของเส้นขอบของวัตถุระดับกลาง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อย่างไรก็ตามการเก็บข้อมูลที่นำเสนอไว้ในตารางที่ 2.6 ไม่สามารถใช้งานได้เหมาะสมกับทุกข้อมูล อาจจะต้องเลือกและพิจารณาจากคุณลักษณะของข้อมูลภาพที่ต้องการประมวลผล เพื่อให้ได้ผลลัพธ์ตรงตามวัตถุประสงค์ที่กำหนดไว้

2.3.2 การเตรียมข้อมูลภาพ (Image Pre-processes)

เนื่องจากการเก็บข้อมูลอาจมีข้อมูลที่ไม่ต้องการ (Noise) และภาพที่มีความบิดเบือน (Distortion) นั้นหมายความว่าภาพที่ได้จากการเก็บข้อมูลมานั้นจะนำมาใช้ไม่ได้ในทันทีที่ต้องผ่านกระบวนการเตรียมข้อมูลให้พร้อมกับการนำไปใช้ ตัวอย่างเช่น เทคนิคการประมาณความเข้ม (Intensity estimation) การประมาณค่าทางเรขาคณิต (Geometric estimation) การแบ่งส่วนภาพ (Image Segmentation) การประมวลผลเบื้องต้น (Elementary processing) และการประมวลผลแบบองค์รวม (Holistic processing) เป็นต้น ซึ่งเทคนิคทั้งหมดที่กล่าวถึงนี้เป็นเทคนิคที่ช่วยสกัดและแบ่งส่วนข้อมูลภาพที่ต้องการหรือไม่ต้องการออกจากกันได้ ซึ่งจะช่วยให้ได้ข้อมูลภาพที่เฉพาะเจาะจงมากขึ้น ช่วยให้การวิเคราะห์ข้อมูลในลำดับถัดไปง่ายขึ้น แต่ทั้งนี้ต้องมั่นใจว่าข้อมูลภาพที่ยังคงเหลืออยู่เป็นข้อมูลภาพที่ถูกต้อง ไม่มีส่วนเกินหรือขาดหายไป (Hameed. et al., 2018)

2.3.3 การแยกคุณลักษณะ (Feature Extraction)

การแยกคุณลักษณะเป็นการหาตัวแทนของข้อมูลเพื่อใช้ในการเรียนรู้ว่าภาพนั้นคือภาพอะไร โดยทั่วไปจะใช้คุณลักษณะเกี่ยวกับสี (Color) รูปร่าง (Shape) ขนาด (Size) และพื้นผิว (Texture) ในการวิเคราะห์ภาพหรือจำแนกภาพ ซึ่งแน่นอนว่าข้อมูลภาพอาจจะไม่มีเพียงคุณลักษณะเดียวที่สามารถบ่งบอกลักษณะเฉพาะได้ ในการแยกคุณลักษณะเฉพาะของภาพด้วยกระบวนการเรียนรู้ของเครื่อง (Machine Learning) จำเป็นต้องนำข้อมูลภาพแปลงเป็น feature vector ก่อน ซึ่ง feature vector นี้จะเป็นอาร์เรย์ 1 มิติ ที่จะใช้ทดแทนการนำข้อมูลภาพทุกพิกเซลไปประมวลผล (Elgendy, 2020; Hameed. et al., 2018)

เทคนิคในการแยกคุณลักษณะมีมากมายหลากหลายเทคนิค แต่ไม่ว่าเราจะใช้เทคนิคใดในการแยกคุณลักษณะควรพิจารณาคุณสมบัติของการแยกคุณลักษณะนั้นว่ามีคุณสมบัติที่เหมาะสมหรือไม่ (Hameed. et al., 2018) ดังตารางที่ 2.7

ตารางที่ 2.7 คุณสมบัติของตัวบอกลักษณะ (Hameed. et al., 2018)

คุณสมบัติ	คำอธิบาย
ความแข็งแรงของคำอธิบาย	ความสามารถในระบุความแตกต่างระหว่างลักษณะที่เหมือนกันและไม่เหมือนกันของภาพ
ความทนทาน	รองรับต่อการบิดเบือนของข้อมูล ข้อมูลส่วนเกินและการเปลี่ยนแปลงเล็กน้อยระหว่างการจัดเก็บข้อมูลและการแปลงข้อมูล
ความต้านทาน	รองรับการแปลงข้อมูล เช่น Affine, projective และ color space
ความกระชับและการจัดทำดัชนี	ความสามารถในการลดขนาดหน่วยความจำและความซับซ้อนในการค้นหา
การจับคู่บางส่วน	ความสามารถในการรับรู้และดึงข้อมูลจากข้อมูลบางส่วน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.4 การจำแนกภาพ (Image Classification)

การจำแนกภาพเป็นการกระบวนการที่ใช้ในการระบุค่าตอบจากคำถามที่ว่าภาพนี้คือภาพอะไร ซึ่งเป็นการตอบปัญหาเพื่อนำไปสู่การพัฒนาแอปพลิเคชันอีกมากมายไม่ว่าจะเป็นแอปพลิเคชันสำหรับการเก็บเกี่ยวผลผลิตด้วยหุ่นยนต์ การวิเคราะห์หุ้คุณภาพผลไม้และผัก การระบุโรคของผลไม้และผัก และการวิเคราะห์ความเสียหายของผลไม้และผัก โดยส่วนใหญ่ักวิจัยใช้วิธีการเรียนรู้ของเครื่อง (Machine Learning) ในการจำแนกภาพ สามารถแบ่งโมเดลการเรียนรู้ออกเป็น 2 กลุ่ม ได้แก่ กลุ่มโมเดลการเรียนรู้ด้วยเทคนิคแมชชีนวิชัน (Machine Vision Technique) ตัวอย่างเช่น Support Vector Machine (SVM), K-Nearest Neighbour (KNN) และ ต้นไม้ตัดสินใจ (Decision Trees) เป็นต้น และกลุ่มโมเดลการเรียนรู้ด้วยเทคนิคโครงข่ายประสาทเทียม (Neural Networks Technique) ตัวอย่างเช่น Artificial Neural Networks (ANN) และ Convolutional Neural Networks (CNN) เป็นต้น (Hameed. et al., 2018)

โดยกลุ่มโมเดลการเรียนรู้ทั้งสองกลุ่มนี้มีความต้องการที่แตกต่างกัน หากต้องการใช้โมเดลการเรียนรู้ด้วยเทคนิคโครงข่ายประสาทเทียมจำเป็นต้องมีข้อมูลในปริมาณที่มากพอจึงจะได้โมเดลที่มีประสิทธิภาพหรือหากไม่สามารถหาข้อมูลได้เพียงพออาจต้องใช้วิธีการนำโมเดลที่ผ่านการเรียนรู้มาแล้ว (Pre-trained) มาเรียนรู้เพิ่มเติมแต่ข้อมูลจะต้องมีลักษณะเหมือนกับข้อมูลที่ใช้เรียนรู่มาก่อนหน้าด้วย ซึ่งก็ถือว่าเป็นข้อจำกัดอย่างหนึ่งของโมเดลกลุ่มนี้ แต่ข้อดีของโมเดลกลุ่มนี้คือโมเดลจะสามารถแยกคุณลักษณะของข้อมูลให้อัตโนมัติ ตรงกันข้ามกับโมเดลการเรียนรู้ด้วยเทคนิคแมชชีนวิชัน นักวิจัยจะเสียเวลากับการวิเคราะห์ข้อมูลเพื่อค้นหาว่าคุณลักษณะที่เหมาะสมด้วยตนเอง หากจะต้องใช้ทุกคุณลักษณะมาใช้งานอาจจะทำให้เสียเวลาหรือได้โมเดลที่มีประสิทธิภาพน้อยกว่าที่ควรจะเป็น แต่อย่างไรก็ตามไม่ว่านักวิจัยจะใช้เทคนิคใดก็ตาม ควรพิจารณาลักษณะข้อมูลและวัตถุประสงค์ของการวิจัยให้มีความสอดคล้องกัน เพื่อการได้มาซึ่งประสิทธิภาพของผลลัพธ์ที่น่าพอใจ (Hameed. et al., 2018)

2.4 การแบ่งส่วนภาพ (Image Segmentation)

การแบ่งส่วนภาพ (Image Segmentation) คือการประมวลผลเพื่อแบ่งภาพออกเป็น 2 ส่วนหรือมากกว่านั้น ซึ่งมีจุดประสงค์เพื่อแยกวัตถุ (Object) หรือลักษณะจุดเด่น (Feature) ออกจากพื้นหลัง (Background) ของภาพ ในแต่ละส่วนที่ถูกแบ่งออกเป็นบริเวณของกลุ่มพิกเซลที่มีคุณสมบัติเหมือนกัน การแบ่งส่วนภาพที่ถูกต้องจะทำให้ได้บริเวณของวัตถุหรือพื้นหลังที่ชัดเจน เมื่อสามารถแยกวัตถุออกมาได้แล้วก็สามารถนำภาพวัตถุไปประมวลผลในขั้นตอนต่อไปได้ ไม่ว่าจะเป็นการตรวจจับวัตถุ (object detection) การจดจำภาพ (image recognition) การแยกคุณลักษณะ (feature extraction) และงานการจัดหมวดหมู่หรือจำแนกกลุ่ม (classification tasks) เทคนิคที่ใช้ในการแบ่งส่วนภาพ ได้แก่ การแบ่งส่วนโดยใช้ค่าขีดแบ่ง (Thresholding- Based Segment) การแบ่งส่วนโดยใช้เส้นขอบ (Edge- Based- Segment) การแบ่งส่วนโดยใช้พื้นที่ (Region- Based Segment) และการแบ่งส่วนโดยใช้พลังงาน (Energy- Based Segment) (สนั่น, 2556; Abdulateef and Salman, 2021; Marques, 2011) โดยเทคนิคแต่ละแบบมีรายละเอียด ดังต่อไปนี้


2.4.1 การแบ่งส่วนภาพโดยใช้ค่าขีดแบ่ง (Thresholding- Based Segment)

การแบ่งส่วนภาพโดยใช้ค่าขีดแบ่ง เป็นการกำหนดค่าคงที่เพื่อใช้เป็นเกณฑ์ในการแบ่งส่วนภาพ โดยส่วนใหญ่จะเริ่มจากการแปลงข้อมูลภาพสีเป็นภาพระดับเทา แล้วนำข้อมูลของแต่ละพิกเซลจากภาพระดับเทาที่ได้ นั่นคือค่าระดับความเข้มของแสงของแต่ละพิกเซลมาคำนวณค่าทางคณิตศาสตร์เพื่อหาค่าคงที่หรือค่าขีดแบ่ง (Threshold Value) โดยกำหนดให้ พิกเซลใดในภาพระดับเทามีค่าระดับความเข้มของแสงมากกว่าค่าขีดแบ่งจะกำหนดค่าผลลัพธ์เท่ากับ 1 หากค่าใดมีค่าน้อยกว่าหรือเท่ากับค่าขีดแบ่งจะกำหนดค่าผลลัพธ์เท่ากับ 0 ดังสมการที่ 2.13

$$g(x,y) = \begin{cases} 1, & \text{if } f(x,y) > T \\ 0, & \text{otherwise} \end{cases} \quad (2.13)$$

โดย $g(x,y)$ แทน รหัสพิกเซลของภาพสองระดับ ณ ตำแหน่ง (x,y)
 $f(x,y)$ แทน ค่าความเข้มของระดับสีเทา ณ ตำแหน่ง (x,y)
 T แทน ค่าขีดแบ่งของภาพ

ดังนั้นผลลัพธ์ที่ได้จะเป็นภาพสองระดับที่มีการแบ่งส่วนของภาพเป็นส่วนของวัตถุและส่วนของพื้นหลัง ดังตัวอย่างในรูปที่ 2.13 ซึ่งส่วนของวัตถุจะเป็นสีขาวส่วนของพื้นหลังจะเป็นสีดำ สำหรับการคำนวณค่าขีดแบ่งมีหลากหลายวิธีไม่ว่าจะเป็นการใช้ค่าเฉลี่ย ค่าฮิสโตแกรม การกำหนดค่าขีดแบ่งโดยใช้วิธีพีทิล (P-Tile Algorithm) ฐานนิยม (Mode Method) การเลือกค่าขีดแบ่งแบบวนซ้ำ (Iterative Threshold Selection) และวิธีของโอดสุ (Otsu's Method) (สนั่น, 2556; Abdulateef and Salman, 2021; Marques, 2011)



รูปที่ 2.13 ตัวอย่างการแบ่งส่วนโดยใช้ค่าขีดแบ่ง (Marques, 2011)

2.4.2 การแบ่งส่วนภาพโดยใช้เส้นขอบ (Edge- Based- Segment)

การแบ่งส่วนภาพโดยใช้เส้นขอบ คือการนำข้อมูลภาพระดับเทามาพิจารณาขอบเขตของวัตถุด้วยเส้นขอบ โดยการค้นหาบริเวณที่ไม่ต่อเนื่อง (Discontinuity) ของค่าระดับเทาภายในภาพ ซึ่งบริเวณที่มีค่าระดับเทาที่ไม่ต่อเนื่อง คือบริเวณที่เป็นรอยต่อระหว่างวัตถุกับพื้นหลัง หรือบริเวณที่เป็นรอยละเอียดภายในภาพ ซึ่งโดยทั่วไปค่าระดับเทา ณ บริเวณนั้นจะมีค่าไม่คงที่ มีการเปลี่ยนแปลง โดยความไม่ต่อเนื่องนี้อาจเกิดจากความไม่ต่อเนื่องของพื้นผิว ความไม่ต่อเนื่องของความลึกของภาพ ความไม่ต่อเนื่องของสีหรือค่าระดับเทา และความไม่ต่อเนื่องของแสง (สนั่น, 2556)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

วิธีการหาเส้นขอบภาพสามารถแบ่งออกเป็น 2 กลุ่มได้แก่ ตัวดำเนินการเกรเดียนต์ (Gradient Operator) และ ตัวดำเนินการอนุพันธ์อันดับสอง (Second Derivative Operator) โดยตัวดำเนินการเกรเดียนต์ เป็นการหาเส้นขอบโดยการหาจุดต่ำสุดและจุดสูงสุดในรูปของอนุพันธ์อันดับหนึ่ง ตัวอย่างเช่น ตัวดำเนินการพรีวิท (Prewitt), โรเบิร์ต (Roberts) โซเบล (Sobel) และแคนนี่ (Canny) ส่วนตัวดำเนินการอนุพันธ์อันดับสอง เป็นการหาเส้นขอบโดยการหาจุดต่ำสุดและจุดสูงสุดในรูปของอนุพันธ์อันดับสอง ตัวอย่างเช่น ตัวดำเนินการลาปลาเซียน (operators Laplacian) และความแตกต่างของเกาส์เซียน (Difference of Gaussian) เป็นต้น (สนั่น, 2556; Abdulateef and Salman, 2021) ตัวอย่างการแบ่งส่วนภาพโดยใช้เส้นขอบแสดงดังรูปที่ 2.14 เป็นการใช้ตัวดำเนินการแคนนี่ (Canny Edge Detector) ในการค้นหาเส้นขอบของภาพ



รูปที่ 2.14 ตัวอย่างการแบ่งส่วนภาพโดยใช้เส้นขอบ (Abdulateef and Salman, 2021)

2.4.3 การแบ่งส่วนภาพโดยใช้พื้นที่ (Region- Based Segment)

การแบ่งส่วนภาพโดยใช้พื้นที่ เป็นการแบ่งส่วนภาพโดยพิจารณาตำแหน่งของพิกเซลและความเหมือนกันของคุณสมบัติของพิกเซลภายในพื้นที่ ถ้าพิกเซลที่อยู่ติดกันและมีคุณสมบัติเหมือนกันจะถูกจัดให้เข้ากลุ่มเดียวกัน (จักรกฤษ และจักรี, 2562; วิภาวรรณ, 2557; สุภาสพงษ์, 2555; Abdulateef and Salman, 2021; Marques, 2011) ซึ่งผลลัพธ์ที่ได้อาจจะได้ภาพที่ถูกแบ่งออกมากกว่า 2 ส่วน ดังรูปที่ 2.15



รูปที่ 2.15 ตัวอย่างการแบ่งส่วนภาพโดยใช้พื้นที่ (Abdulateef and Salman, 2021)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

วิธีการแบ่งส่วนภาพโดยใช้พื้นที่แบ่งออกเป็น 3 แบบ ได้แก่

2.4.3.1 เทคนิคการเติบโตของพื้นที่

เทคนิคการเติบโตของพื้นที่ (Region Growing Technique) เป็นกระบวนการขยายกลุ่มของจุดภาพหรือพื้นที่ย่อย (sub-region) ให้มีขนาดที่ใหญ่ขึ้นตามเกณฑ์ที่กำหนด โดยการขยายกลุ่มอาจจะเริ่มจากกลุ่มของพิกเซลที่เรียกว่า พิกเซลเมล็ด (Seed Pixels) และขยายพื้นที่ไปยังพิกเซลรอบข้างที่มีคุณสมบัติคล้ายกัน อาจพิจารณาจากค่าระดับความเข้มของแสงหรือสี เป็นต้น โดยการเลือกพิกเซลเมล็ดมักจะขึ้นอยู่กับลักษณะของภาพ ซึ่งหากเลือกได้ดีการแบ่งส่วนภาพด้วยวิธีนี้ก็จะได้ผลลัพธ์ที่ดีตามไปด้วย (สุภาสพงษ์, 2555; Abdulateef and Salman, 2021; Marques, 2011)

2.4.3.2 เทคนิคการรวมและแยกพื้นที่

เทคนิคการรวมและแยกพื้นที่ (region merging and splitting technique) เป็นเทคนิคในการรวมหรือแยกจุดภาพเพื่อให้เกิดวัตถุ โดยเทคนิคการรวมพื้นที่ (Merging) จะเริ่มจากการกำหนดพื้นที่เริ่มต้น (initial region) ซึ่งอาจเป็นจุดพิกเซลเพียงหนึ่งจุดแล้วทำการรวมพิกเซลอื่นที่เหมือนกันเข้าด้วยกันจนได้วัตถุที่ต้องการ ส่วนเทคนิคการแยกพื้นที่ (Splitting) จะเริ่มจากการกำหนดพื้นที่ขนาดใหญ่ (Large Segments) แล้วแบ่งส่วนย่อยให้มีขนาดเล็กลงจนกว่าจะได้วัตถุที่ต้องการ ที่ไม่เป็นพื้นที่เดียวกัน (Homogeneous) (สุภาสพงษ์, 2555; Abdulateef and Salman, 2021; Marques, 2011)

2.4.3.3 เทคนิคการแบ่งกลุ่ม

เทคนิคการแบ่งกลุ่ม (Clustering) เป็นการแบ่งกลุ่มพิกเซลที่มีคุณสมบัติคล้ายกัน ออกเป็นกลุ่มหรือเรียกว่า คลัสเตอร์ (Cluster) โดยแต่ละคลัสเตอร์ถูกสร้างขึ้นจากคุณสมบัติที่หลากหลาย เช่น ขนาด สี และพื้นผิว เป็นต้น ซึ่งคลัสเตอร์มี 2 รูปแบบ ได้แก่ คลัสเตอร์แบบลำดับชั้น (Hierarchical clustering) และคลัสเตอร์แบบไม่เป็นลำดับชั้น (Nonhierarchical Clustering) ข้อมูลที่ถูกแบ่งกลุ่มด้วยการคลัสเตอร์แบบลำดับชั้น จะถูกจัดกลุ่มตามลำดับชั้นแบบโครงสร้างต้นไม้ (Tree) มีรูทโหนดเป็นข้อมูลทั้งหมดและโหนดย่อยจะเป็นกลุ่มข้อมูลคลัสเตอร์ส่วนข้อมูลที่ถูกแบ่งกลุ่มแบบไม่เป็นลำดับชั้น เป็นกระบวนการจัดกลุ่มข้อมูลให้อยู่ในกลุ่มที่เหมาะสม ซึ่งกลุ่มเดียวกันจะมีคุณสมบัติคล้ายกัน แต่มีความแตกต่างจากกลุ่มอื่น และเป็นการแบ่งกลุ่มข้อมูลอย่างชัดเจนโดยไม่มีกลุ่มใดซ้อนทับกันอยู่ อัลกอริทึมที่นิยมใช้คือ เคมีนส์ (K-means) โดยอัลกอริทึม นี้จะแบ่งส่วนข้อมูล (Partition) ออกเป็น K กลุ่ม แทนค่าแต่ละกลุ่มด้วยค่าเฉลี่ยของกลุ่ม ซึ่งใช้เป็นจุดศูนย์กลาง (centroid) ของกลุ่มในการวัดระยะห่างของข้อมูลในกลุ่มเดียวกัน (วิภาวรรณ, 2557; Abdulateef and Salman, 2021; Marques, 2011)

2.4.4 การแบ่งส่วนภาพโดยใช้พลังงาน

การแบ่งส่วนภาพโดยใช้พลังงาน (Energy- Based Segment) เป็นการแบ่งส่วนโดยมีวัตถุประสงค์เพื่อเพิ่มประสิทธิภาพของแบ่งส่วนภาพโดยใช้วิธีการแอกทีฟคอนทัวร์ (Active contour) และวิธีแบบกราฟ (graph-based) (Abdulateef and Salman, 2021)

การแบ่งส่วนภาพโดยใช้วิธีการแอกทีฟคอนทัวร์คือการกำหนดรูปร่างของวัตถุเริ่มต้นที่คาดว่าครอบคลุมทุกส่วนของวัตถุในภาพแล้วทำการเปลี่ยนรูปร่างลดขนาดลงไปเรื่อยๆจนกว่าจะพบขอบเขตของวัตถุภายในภาพ วิธีการนี้จะให้ผลลัพธ์เป็นขอบเขตของวัตถุแบบปิด เส้นขอบที่ได้จะเรียบ และเป็นวิธีที่รวดเร็วกว่าวิธีดั้งเดิมอย่างเช่น การเติบโตของพื้นที่ (Region Growing) การใช้ค่าขีดแบ่ง

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Thresholding) และ การตรวจจับเส้นขอบ (Edge Detection) เป็นต้น แต่ถ้าหากกำหนดรูปร่างเริ่มได้ไม่ดีก็จะส่งผลให้ผลลัพธ์ที่ได้ไม่ดีตามไปด้วย (Abdulateef and Salman, 2021)

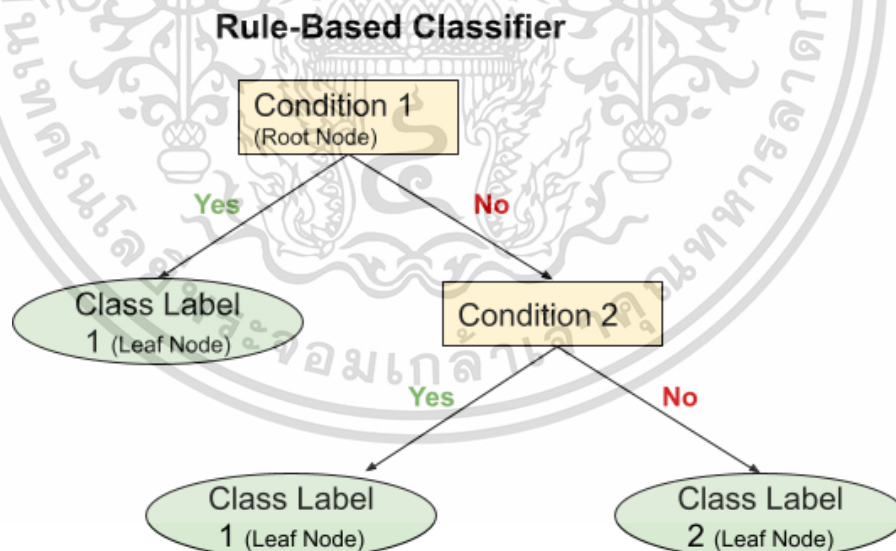
การแบ่งส่วนภาพโดยใช้วิธีแบบกราฟ เป็นวิธีการที่อาศัยทฤษฎีกราฟในการแบ่งกลุ่ม โดยการระบุตำแหน่งการตัดขั้นต่ำในกราฟ โดยมีเกณฑ์การตัดที่ต้องการลดความคล้ายคลึงระหว่างพิกเซลที่แยกออก ตัวอย่างการแบ่งส่วนภาพโดยใช้วิธีแบบกราฟ ได้แก่ Normalize Cut Graph Cut และ Local Variation เป็นต้น (Abdulateef and Salman, 2021)

2.5 โมเดลการจำแนกภาพ (Image Classification Model)

โมเดลการจำแนกภาพ เป็นโมเดลที่ใช้สำหรับช่วยตัดสินใจในการจัดหมวดหมู่หรือจัดประเภทกลุ่มของข้อมูลภาพ โดยการจำแนกภาพจะมีการสร้างโมเดลหรือตัวจำแนกกลุ่ม (Classifier) เพื่อทำนายหมวดหมู่หรือกลุ่มของข้อมูลภาพ (Class) (โกเมศ, 2561) ซึ่งในงานวิจัยครั้งนี้ให้ความสนใจกับการจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพที่มีด้วยกันทั้งหมด 7 สายพันธุ์ โดยมีการศึกษาโมเดลสำหรับการจำแนกภาพ ดังต่อไปนี้

2.5.1 การจำแนกด้วยกฎ (Rule Based Classifiers)

การจำแนกข้อมูลด้วยกฎ เป็นโมเดลที่ประมวลผลภายใต้ “เงื่อนไข” (condition) ที่ถูกกำหนดผลลัพธ์ไว้ ถ้าเงื่อนไขเป็นจริงให้ทำอะไร ถ้าเงื่อนไขเป็นเท็จให้ทำอะไร ซึ่งอาจประกอบด้วยหนึ่งเงื่อนไขหรือมากกว่า โดยแต่ละกฎจะถูกแสดงอยู่ในรูปแบบ IF condition THEN conclusion สามารถแสดงโมเดลได้ดังรูปที่ 2.16




รูปที่ 2.16 โครงสร้างโมเดลการจำแนกข้อมูลด้วยกฎ (Nidhi, 2022)

โครงสร้างโมเดลการจำแนกข้อมูลด้วยกฎ ประกอบด้วย เงื่อนไข (Condition หรือ Rule Antecedent) และผลลัพธ์ของกฎ (Class หรือ Rule Consequent) โดยเงื่อนไขจะถูกสร้างขึ้นจากการศึกษาคุณลักษณะของข้อมูลภาพ เช่น สี ขนาด พื้นผิว เป็นต้น ส่วนผลลัพธ์ของกฎจะเป็นการระบุหมวดหมู่ (Class) ของภาพที่ถูกกำหนดด้วยผู้เชี่ยวชาญหรือจากการศึกษาข้อมูลภาพ โมเดลการจำแนกด้วยวิธีการนี้เป็นวิธีการที่ง่ายแต่ก็มีความเสี่ยงต่อการให้ผลการจำแนกผิดพลาด เนื่องจากไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จะต้องมีองค์ความรู้มากพอที่จะครอบคลุมกรณีต่างๆที่จะเกิดขึ้นได้ ดังนั้นการสร้างโมเดลนอกจากจะต้องสร้างให้ครอบคลุมทุกกรณีที่จะเกิดขึ้นแล้ว การระบุเงื่อนไขและผลลัพธ์ของแต่ละกฎจะต้องไม่มีความขัดแย้งกัน หากเกิดกรณีที่ไม่มีการใดเลยที่สอดคล้องกับข้อมูล จะต้องมีการสร้างกฎที่เป็นปริยาย (Default Rule) ไว้ เพื่อให้โมเดลยังคงสามารถจำแนกข้อมูลได้ แต่ถึงอย่างไรก็ตามก็ควรมีการประเมินประสิทธิภาพของกฎเพื่อความมั่นใจในการนำไปใช้งาน (โกเมศ, 2561; อมรเดช, 2563; Nidhi, 2022)

2.5.2 การแยกคุณลักษณะตามเนื้อหา (Content-based)

สำหรับโมเดลจำแนกภาพด้วยการแยกคุณลักษณะตามเนื้อหานี้ โดยทั่วไปมุ่งเน้นศึกษาและค้นหาคุณลักษณะเด่น ที่สามารถนำมาใช้เป็นคุณลักษณะสำหรับการจำแนกภาพได้อย่างเหมาะสมกับวิธีการเรียนรู้ของเครื่อง ซึ่งต้องเสียเวลาในการค้นหาคุณลักษณะที่เหมาะสมกับวิธีการเรียนรู้ของเครื่องที่เลือกใช้ได้ คุณลักษณะของข้อมูลภาพสามารถแยกได้จากสี ขนาด รูปร่าง พื้นผิว เป็นต้น วิธีการเรียนรู้ของเครื่องส่วนใหญ่เลือกใช้ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM), K-Nearest Neighbour (KNN) และ ต้นไม้ตัดสินใจ (Decision Trees) เป็นต้น (Bani and Fekri, 2019; Jana. et al., 2017; Selvaraj. et al., 2010; Muhammad, 2014; Fu. et al., 2019; Reyes. et al., 2021) ดังนั้นงานหลักของโมเดลลักษณะนี้คือการแยกคุณลักษณะเพื่อใช้ในการทดลองกับวิธีการเรียนรู้ของเครื่องและเปรียบเทียบประสิทธิภาพ ดังรูปที่ 2.17 ประสิทธิภาพของโมเดลจะขึ้นอยู่กับคุณลักษณะที่ใช้ในจำแนกข้อมูลภาพผนวกกับประสิทธิภาพของวิธีการเรียนรู้ของเครื่องที่เลือกใช้



รูปที่ 2.17 โครงสร้างของโมเดลการแยกคุณลักษณะตามเนื้อหา (Elgendy, 2020)

2.5.3 การเรียนรู้เชิงลึก (Deep learning)

การเรียนรู้เชิงลึก (Deep learning) เป็นหนึ่งในวิธีการเรียนรู้ของเครื่อง (Machine learning) แบบอัตโนมัติที่กำลังได้รับความนิยม ให้ประสิทธิภาพในการทำนายสูง ทำงานแบบกล่องดำ (Black box) (Samek. et al., 2021) เลียนแบบการทำงานของระบบโครงข่ายประสาทของมนุษย์ (Neurons) โดยการสร้างโครงข่ายประสาท (Neural Network) ด้วยชั้นการประมวลผลแบบไม่เชิงเส้น (nonlinear processing) มาซ้อนกันหลายชั้น (Layer) (Elgendy, 2020; Schmidhuber, 2015;) แต่ละชั้นจะใช้ผลลัพธ์ของชั้นก่อนหน้าเป็นอินพุต จุดเด่นของการเรียนรู้เชิงลึกคือรองรับการแยกคุณลักษณะที่มีความคลุมเครือ โมเดลช่วยแยกคุณลักษณะให้อัตโนมัติ ผู้วิจัยมีหน้าที่เตรียมข้อมูลที่จะใช้ในการเรียนรู้เท่านั้น ถือว่าสร้างความสะดวกสบายให้กับผู้วิจัยเป็นอย่างมาก

องค์ประกอบของโมเดลการเรียนรู้เชิงลึกประกอบด้วย 3 ส่วน ได้แก่ ชั้นข้อมูลนำเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และ ชั้นผลลัพธ์ (Output Layer) ดังรูปที่ 2.18

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5.2.1 ชั้นข้อมูลนำเข้า (Input Layer)


เป็นชั้นที่นำข้อมูลเข้าสู่โมเดล จำนวนของนิวรอนหรือโหนด (Node) ขึ้นอยู่กับคุณลักษณะของข้อมูลผ่านการประมวลผลข้อมูลในระดับต่ำหรือระดับกลาง อาจมาในรูปแบบภาพสี ภาพระดับเทา หรือภาพสองระดับ หรืออาจเป็นคุณลักษณะของภาพ ไม่ว่าจะเป็น สี รูปร่าง พื้นผิว เส้นขอบ เป็นต้น (ไกรศักดิ์, 2565; ชิตพงษ์, 2563)

2.5.2.2 ชั้นซ่อน (Hidden Layer)

เป็นชั้นที่อยู่ตรงกลางระหว่างชั้นข้อมูลนำเข้าและชั้นผลลัพธ์ เป็นชั้นการเรียนรู้ของโมเดลที่มีการประมวลผลแบบไม่เชิงเส้น โดยทั่วไปแล้ว ชั้นซ่อนจะมีจำนวนชั้นและจำนวนโหนดไม่จำกัด การเพิ่มชั้นและจำนวนโหนดจะส่งผลต่อประสิทธิภาพของโมเดล โดยแต่ละโหนดต้องประกอบด้วยฟังก์ชันแบบไม่เป็นเชิงเส้น (Non-linear function) หรือฟังก์ชันกระตุ้น (Activation function) ซึ่งอาจจะเป็นฟังก์ชันกระตุ้นค่าแบ่ง (Threshold activation function) ฟังก์ชันกระตุ้นซิกมอยด์ (Sigmoid activation function) ฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทงก์เจนท์ (Hyperbolic tangent function: Tanh) หรือ ฟังก์ชันกระตุ้นเรกติไฟด์ไลน์เนี่ยยูนิท (Rectified linear units : ReLU) ก็ได้ ขึ้นอยู่กับคำตอบที่ต้องการ (ไกรศักดิ์, 2565; ชิตพงษ์, 2563)

2.5.2.3 ชั้นผลลัพธ์ (Output Layer)

เป็นชั้นที่เป็นคำตอบของโมเดล จำนวนโหนดในชั้นนี้ขึ้นอยู่กับรูปแบบของคำตอบที่ต้องการ อาจอยู่ในรูปแบบของสมการถดถอย (Regression) ในกรณีที่คำตอบเป็นลักษณะการระบุค่าหรือปริมาณ เช่น การพยากรณ์อากาศ การพยากรณ์หุ้น เป็นต้น จำนวนโหนดในชั้นผลลัพธ์จะมีเพียงโหนดเดียว หากคำตอบของโมเดลเป็นหมวดหมู่ (Category) หรือประเภท (Type) จำนวนโหนดในชั้นผลลัพธ์จะมีจำนวนเท่ากับจำนวนหมวดหมู่หรือประเภทของข้อมูลนั่นเอง (ไกรศักดิ์, 2565; ชิตพงษ์, 2563)



รูปที่ 2.18 โครงสร้างอย่างง่ายของโมเดลการเรียนรู้เชิงลึก (Krishna. et al.,2018)

นอกจากนี้การเรียนรู้เชิงลึกยังมีองค์ประกอบอื่นไม่ว่าจะเป็น กระบวนการเรียนรู้ (Training) ข้อมูลโดยการปรับค่าน้ำหนักเป็นค่าที่เหมาะสมที่สุด (Optimal weighted) ด้วยวิธีการแพร่กลับ (Back propagation) นั่นคือการเรียนรู้จากความผิดพลาดแล้วนำค่าผิดพลาดนั้นมาคำนวณหาค่าน้ำหนักใหม่ โดยมีการกำหนดค่าคงที่ในการปรับค่าน้ำหนักหรืออาจจะเรียกว่า “Step” หรือ “Learning rate” ซึ่งถูกรอบของการทำงานจะมีการปรับค่าน้ำหนักใหม่ทุกครั้งจนกว่าค่าน้ำหนักจะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ไม่เปลี่ยนแปลงหรือเปลี่ยนแปลงน้อย (Convergence) ถือเป็นค่าน้ำหนักที่เหมาะสมที่สุด (Optimization) จะมีผลทำให้การทำนายผลลัพธ์มีความแม่นยำมากยิ่งขึ้น ดังนั้น หากต้องการให้โมเดลการเรียนรู้เชิงลึกทำงานได้อย่างมีประสิทธิภาพ ควรกำหนดค่าพารามิเตอร์ต่างๆ ให้เหมาะสม ซึ่งส่งผลต่อประสิทธิภาพในการทำงานของโมเดลทั้งสิ้น (ไกรศักดิ์, 2565)

2.6 การวัดประสิทธิภาพโมเดล (Performance Evaluation)

การวัดประสิทธิภาพโมเดลเป็นขั้นตอนสำคัญที่ช่วยประเมินว่าโมเดลที่สร้างขึ้นนั้นสามารถนำไปใช้งานจริงได้หรือไม่ โดยส่วนใหญ่โมเดลที่ทำงานในลักษณะ จำแนก แยกแยะหรือจัดกลุ่ม (Classification) นิยมวัดประสิทธิภาพโมเดลด้วยตารางคอนฟิวชันเมทริกซ์ (Confusion Matrix) ที่สามารถนำไปสู่การคำนวณหาค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) ค่าความถ่วงดุล (F-measure) นอกจากนี้ยังมีการใช้เทคนิคการแบ่งข้อมูล k-fold Cross Validation เพื่อช่วยแบ่งข้อมูลสำหรับการวัดประสิทธิภาพโมเดลด้วย

2.6.1 ตารางคอนฟิวชันเมทริกซ์ (Confusion Matrix)

ตารางคอนฟิวชันเมทริกซ์ เป็นตารางที่ใช้ประเมินผลลัพธ์ของการจำแนกหรือการทำนาย (Prediction) เปรียบเทียบกับค่าจริง (Actual) หรือผลลัพธ์ที่ถูกต้องของข้อมูล จากการศึกษาโมเดลแบบจำแนกกลุ่มข้อมูลหากเป็นการจำแนกกลุ่มเพียง 2 กลุ่ม (Binary Classification) หรือเรียกว่า two-class prediction ตารางคอนฟิวชันเมทริกซ์ที่ได้จะมีลักษณะดังรูปที่ 2.19(a) หากเป็นการจำแนกกลุ่มมากกว่า 2 กลุ่ม (Multiclass Classification) ตารางคอนฟิวชันเมทริกซ์ที่ได้จะมีลักษณะดังรูปที่ 2.19(b) ซึ่งแต่ละช่องในตารางจะระบุจำนวนผลลัพธ์ที่โมเดลทำนายได้ ในการระบุจำนวนผลลัพธ์ให้ทำในลักษณะ 2 มิติ โดยฝั่งซ้ายแสดงค่าจริง ส่วนด้านบนแสดงค่าผลลัพธ์ที่โมเดลทำนายได้ (กานต์, 2552; กอบเกียรติ, 2563; Tait. et al.,2021)

		Predicted Class	
		A	B
True Class	A	TP	FN
	B	FP	TN

(a)

		Predicted Class		
		A	B	C
True Class	A	TP	FN	FN
	B	FP	TN	FN
	C	FP	FP	TN

(b)

รูปที่ 2.19 ตัวอย่างตารางคอนฟิวชันเมทริกซ์ (Tait. et al.,2021)

โดยช่อง TP ย่อมาจาก True Positive หมายถึงจำนวนผลลัพธ์ที่ทำนายถูกต้องในทางบวก ตัวอย่างเช่น ทำนายว่า “Yes” แต่ค่าจริงคือ “Yes”

TN ย่อมาจาก True Negative หมายถึงจำนวนผลลัพธ์ที่ทำนายถูกต้องในทางลบ ตัวอย่างเช่น ทำนายว่า “No” แต่ค่าจริงคือ “No”

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

FP ย่อมาจาก False Positive หมายถึงจำนวนผลลัพธ์ที่ทำนายผิดในทางบวก ตัวอย่างเช่น ทำนายว่า “Yes” แต่ค่าจริงคือ “No”

FN ย่อมาจาก False Negative หมายถึงจำนวนผลลัพธ์ที่ทำนายผิดในทางลบ ตัวอย่างเช่น ทำนายว่า “No” แต่ค่าจริงคือ “Yes”

ทั้งนี้จากตารางคอนฟิวชันเมทริกซ์สามารถนำไปคำนวณเพื่อระบุค่าความถูกต้อง ค่าความแม่นยำ ค่าความระลึก และค่าความถ่วงดุล ได้ดังนี้ (กอบเกียรติ, 2563; Tait. et al.,2021)

2.6.1.1 ค่าความถูกต้อง (Accuracy)

เป็นอัตราส่วนของการทำนายถูกต้องกับจำนวนข้อมูลทั้งหมด เป็นหนึ่งในตัวชี้วัดที่นิยมใช้ประเมินประสิทธิภาพของโมเดล ค่าความถูกต้องคำนวณได้จากสมการ 2.14

$$\text{Accuracy} = \frac{TP+TN}{TP+FN+FP+TN} \quad (2.14)$$

2.6.1.2 ค่าความแม่นยำ (Precision)

เป็นอัตราส่วนของผลการทำนายเชิงบวก คำนวณโดยสัดส่วนของจำนวนที่ทำนายถูกต้องในทางบวกกับจำนวนข้อมูลในเชิงบวกทั้งหมด ค่าความแม่นยำคำนวณได้จากสมการ 2.15

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2.15)$$

2.6.1.3 ค่าความระลึก (Recall)

เป็นการวัดความแม่นยำอีกมิติ ที่สนใจผลลัพธ์ที่ทำนายได้เทียบกับข้อมูลที่เป็นของจริง ค่าความระลึกคำนวณได้จากสมการ 2.16

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2.16)$$

2.6.1.4 ค่าความถ่วงดุล (F-measure)

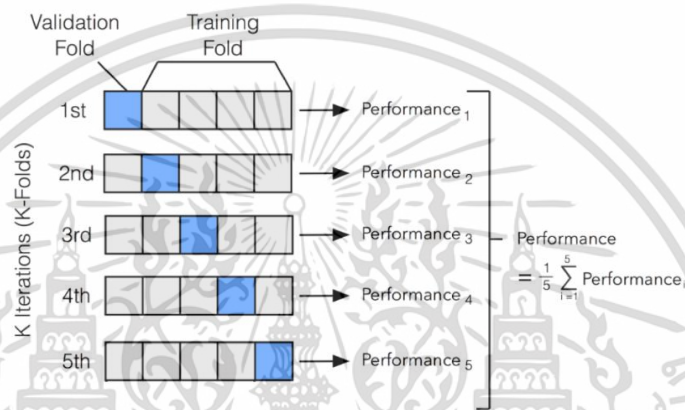
ค่าความถ่วงดุล แทนด้วย F-measure หรือ F-Score หรือ F1 Score ก็ได้ เป็นการวัดค่าความสัมพันธ์ระหว่างค่าความระลึกและค่าความแม่นยำ ถือว่าเป็นตัวชี้วัดที่ได้รับความนิยมเนื่องจากสามารถให้มุมมองโดยรวมของทั้งความแม่นยำและความระลึกตามที่มีอยู่โดยที่โมเดลสามารถมีความแม่นยำสูงแต่ความระลึกต่ำ หรือมีความแม่นยำต่ำแต่ความระลึกสูง ค่าความถ่วงดุลคำนวณได้จากสมการ 2.17

$$F = \frac{2(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (2.17)$$

2.6.2 การแบ่งข้อมูล k-fold Cross Validation

การแบ่งชุดข้อมูลเพื่อตรวจสอบความถูกต้อง โดยไม่สิ้นเปลืองข้อมูลในการตรวจสอบมากเกินไป ซึ่งชุดข้อมูลจะถูกแบ่งออกเป็นส่วนๆ แต่ละส่วนมีขนาดเท่ากัน หลังจากนั้นนำชุดข้อมูลไปฝึกหัด (Train) และทดสอบ (Test/ Validation) เวียนสลับกันไปให้ทุกส่วนของข้อมูลถูกทดสอบ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(กอบเกียรติ, 2563; Shwartz and David, 2014) ตัวอย่างเช่น กำหนดให้มีการแบ่งชุดข้อมูลออกเป็น 5 ส่วน (5-fold) นำ 1 ส่วนใช้สำหรับทดสอบ อีก 4 ส่วนที่เหลือใช้สำหรับฝึกหัด แล้วเวียนสลับชุดข้อมูลที่แบ่งได้เป็นชุดทดสอบ ในกรณีมีชุดข้อมูล 5 ส่วน ก็จะมีการเวียนสลับชุดข้อมูล 5 ครั้ง จึงเป็นที่มาของคำว่า k-fold Cross Validation ซึ่ง k คือจำนวนการแบ่งส่วนชุดข้อมูล จะเป็น 5 หรือ 10 หรือเท่าใดก็ได้ ในการเวียนสลับชุดข้อมูลแต่ละรอบจะได้ค่าประสิทธิภาพมา 1 ค่า หากแบ่งชุดข้อมูลเป็น 5 ส่วน ก็จะได้ค่าประสิทธิภาพมาทั้งหมด 5 ค่า ดังนั้นค่าประสิทธิภาพของโมเดลในภาพรวมทั้งระบบ คือการนำค่าประสิทธิภาพแต่ละรอบมาคำนวณหาค่าเฉลี่ย ดังรูปที่ 2.21 โดยทั่วไปนิยมแบ่งเป็น 10 ส่วน (กอบเกียรติ, 2563; Harikant, 2021; Shwartz and David, 2014)



รูปที่ 2.20 ตัวอย่างการแบ่งข้อมูล 5-fold Cross Validation (Harikant, 2021)

2.7 งานวิจัยที่เกี่ยวข้อง

Muresan and Oltean (2018) ได้นำเสนอชุดข้อมูลภาพ (Image Dataset) ที่มีชื่อว่า Fruits 360 ประกอบไปด้วยข้อมูลภาพผลไม้และผักที่ได้รับความนิยม จำนวน 120 ชนิด รวมทั้งสิ้น 82,213 ภาพ ซึ่งมีแก้วมังกรสีแดง (Pitahaya Red) บรรจุอยู่ด้วย 1 ชนิด ในขั้นตอนการเก็บข้อมูลภาพ Muresan and Oltean (2018) ได้นำผักและผลไม้ มาเสียบเข้ากับแท่งเหล็กที่เชื่อมต่อกับสว่านมอเตอร์ขนาด 3 rpm แล้วทำหมุนสว่านพร้อมกับบันทึกภาพเคลื่อนไหวเป็นเวลา 20 วินาที โดยมีกระดาษสีขาวเป็นพื้นหลัง ภาพเคลื่อนไหวที่ได้จะถูกแยกเฟรมออกมาเป็นภาพนิ่ง แล้วนำภาพนิ่งมาปรับพื้นหลังให้กลายเป็นสีขาวอย่างสม่ำเสมอ ดังนั้นชุดข้อมูลภาพที่ได้จะเป็นภาพผลไม้และผัก 1 ชนิดต่อ 1 ภาพ โดยมีพื้นหลังเป็นสีขาว เพื่อเป็นการทดสอบว่าชุดข้อมูลภาพที่สร้างขึ้นนี้สามารถนำไปใช้ในการจำแนกประเภทผลไม้และผักได้หรือไม่ Muresan and Oltean (2018) จึงนำชุดข้อมูลภาพที่ได้ไปทดลองกับโมเดลการเรียนรู้ด้วยโครงข่ายประสาทเทียม (Neural Networks) 10 แบบ โดยมีการปรับขนาดภาพเฉพาะส่วนของวัตถุ ให้มีขนาด 100 x 100 Pixel พร้อมทั้งแปลงภาพให้อยู่ในรูปแบบที่แตกต่างกัน 5 รูปแบบ ได้แก่ ภาพระดับเทา (Grayscale) ภาพสี RGB ภาพสี HSV ภาพ HSV + ภาพระดับเทา และ ภาพสี HSV + ภาพระดับเทา+ hue/saturation change+flips จากการทดลองนำชุดข้อมูลภาพไปทดลองกับโมเดลทั้ง 10 แบบ พบว่ากลุ่มภาพสี HSV + ภาพระดับเทา+ hue/saturation change + flips ได้ค่าความถูกต้อง (Accuracy on Test) สูงกว่ากลุ่มอื่น ให้ค่าความถูกต้องสูงสุดที่ 95.23% และต่ำสุด 93.79% จึงสรุปได้ว่า ชุดข้อมูลภาพนี้สามารถนำไปใช้ในการจำแนกประเภทผลไม้และผักได้

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Magalhães. et al. (2019) ได้ศึกษาการเปลี่ยนแปลงของผลแก้วมังกรสายพันธุ์ *Hylocereus polyrhizus* ซึ่งผลสุกจะมีเปลือกสีแดงเนื้อสีแดง โดยมีวัตถุประสงค์เพื่อช่วยวางแผนการจัดการผลแก้วมังกรให้เหมาะสมกับการเก็บเกี่ยวและการขนส่งออกสู่ตลาด ด้วยลักษณะสัณฐานวิทยา และการเปลี่ยนแปลงสีทั้งภายในและภายนอกของผลแก้วมังกรที่เจริญเติบโตหลังจากมีการผสมพันธุ์ของเกสร (Anthesis) พบว่าหลังจากการผสมพันธุ์ของเกสร 28-32 วัน ผลแก้วมังกรยังไม่สุก เปลือกมีสีเขียว ค่า Hue เท่ากับ 120 เป็นที่ยังไม่พร้อมเก็บเกี่ยว เมื่อผ่านไป 34 วัน ผลแก้วมังกรจะเริ่มสุก เปลือกมีเริ่มมีแดงปรากฏเล็กน้อยแต่เนื้อข้างในเปลี่ยนเป็นสีแดงอมม่วงแล้ว ค่า Hue เท่ากับ 60 เป็นระยะที่พร้อมเก็บเกี่ยว เหมาะกับการขนส่งระยะไกล แต่หากทิ้งไว้เป็นระยะเวลา 36-42 วันหลังการการผสมพันธุ์ของเกสร เปลือกผลแก้วมังกรจะเปลี่ยนเป็นแดงชัดเจนปลายกลีบมีสีเขียว ค่า Hue เนื้อข้างในจะมีสีแดงอมม่วงเข้มขึ้น เท่ากับ 20 เป็นผลแก้วมังกรที่สุกแล้ว พร้อมรับประทาน ดังนั้นเหมาะกับการขนส่งระยะใกล้หรือจำหน่ายพร้อมรับประทาน จากงานวิจัยสรุปได้ว่าสีเปลือกสามารถบ่งบอกระยะเวลาเจริญเติบโตของผลแก้วมังกรได้

Masithoh. et al. (2013) ได้นำเสนอเทคนิคการตรวจจับผลแก้วมังกรสายพันธุ์ *Hylocereus Undatus* ซึ่งผลสุกจะมีเปลือกสีแดงเนื้อสีขาว ในสภาวะแวดล้อมกลางแจ้ง วัตถุประสงค์เพื่อตรวจจับและนับจำนวนปริมาณของแก้วมังกรบนต้นได้ โดยการนำเทคนิคการแบ่งส่วนภาพ (Segmentation) ด้วยโมเดลสี HSV เพื่อแยกส่วนผลแก้วมังกรออกจากพื้นหลัง จากการทดลองพบว่า หากกำหนดค่า Hue ระหว่าง 299-360 ค่า S ระหว่าง 27-100 และค่า V ระหว่าง 23-100 ผลปรากฏว่าสามารถใช้เป็นค่าขีดแบ่งในการแบ่งส่วนภาพได้ โดยให้ค่าความถูกต้องสูงถึง 80%

He. et al. (2016) ได้นำเสนอโมเดลการเรียนรู้เชิงลึกชื่อว่า Resnet (Residual Networks) เป็นโมเดลที่เป็นที่รู้จักจากการแข่งขัน ImageNet Large Scale Visual Recognition Challenge 2015 (ILSVRC 2015) ซึ่งโมเดลนี้ได้รับรางวัลชนะเลิศอันดับหนึ่งในการแข่งขัน Classification task โครงสร้างของ Resnet ประกอบไปด้วย convolution layer และ maxpooling layers ในการสร้างโมเดลส่วน feature extraction และใช้ Average Pooling layers ในการสร้างโมเดลส่วน Classifier ถึงแม้ว่า Resnet จะมีชั้นเลเยอร์ที่ลึกกว่า VGG net ถึง 8 เท่า ซึ่งเป็นแชมป์เก่าจากการแข่งขันเดียวกันก็ตาม แต่ Resnet มีความซับซ้อนน้อยกว่า ประมวลผลได้มีประสิทธิภาพที่ดีกว่า พิสูจน์ให้เห็นได้จากผลการทดสอบรู้จำภาพ ImageNet ได้ผลการทดสอบ top-5 error rate ของชุดทดสอบเท่ากับ 3.5% ในขณะที่ VGG net มี top-5 error rate เท่ากับ 7.3%

Simonyan and Zisserman (2015) ได้ศึกษาผลกระทบของความลึกของชั้นเลเยอร์โมเดลการเรียนรู้เชิงลึก โดยใช้โครงสร้างของ VGG net โมเดล ซึ่งประกอบไปด้วย convolution layer และ maxpooling layers ในการสร้างโมเดลส่วน feature extraction และใช้ Fully Connected layers ในการสร้างโมเดลส่วน Classifier Simonyan and Zisserman (2015) ได้ปรับเปลี่ยนจำนวนชั้นของโมเดลด้วย Convolution layer ที่แตกต่างกัน 11, 13, 16 และ 19 ชั้น โดยการปรับเปลี่ยนจำนวนชั้นเลเยอร์นี้ส่งผลให้พารามิเตอร์ที่ได้จากโมเดลแตกต่างกัน ซึ่งผลการทดสอบรู้จำภาพ ImageNet พบว่า VGG 19 ชั้นได้ผล top-5 error rate ของชุดทดสอบ เท่ากับ 8.0% รองลงมาคือ VGG 16 ชั้น ได้ผล top-5 error rate ของชุดทดสอบ เท่ากับ 8.1% ซึ่งเป็นค่าที่แตกต่างกันเพียงเล็กน้อย นอกจากนี้ Simonyan and Zisserman (2015) ได้ทดสอบนำโมเดล 16 ชั้นและ 19 ชั้นมาเรียงต่อกัน ได้ผล top-5 error rate ของชุดทดสอบ เท่ากับ 6.8% ซึ่งเป็นผลลัพธ์ที่ดีกว่าโมเดล

VGG net ที่ใช้ในการแข่งขัน ImageNet Large Scale Visual Recognition Challenge 2014

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(ILSVRC 2014) ซึ่งได้รับรางวัลที่หนึ่งและสองของการประเภท localization และ classification task ตามลำดับ ถือว่าเป็นการพัฒนาโมเดลของตนเองได้อย่างยอดเยี่ยม

Sandler. et al. (2018) ได้นำเสนอโมเดลการเรียนรู้เชิงลึกที่มีชื่อว่า MobileNetV2 เป็นโมเดลที่ถูกคิดค้นขึ้นเพื่อสนับสนุนการพัฒนาแอปพลิเคชันบนมือถือที่มีขนาดเล็ก มีทรัพยากรในการประมวลผลที่จำกัด แต่ยังคงประสิทธิภาพเป็นที่น่าพอใจ ซึ่งใช้พื้นที่หน่วยความจำเพียง 400 Kb น้อยกว่า MobileNetV1 ถึง 4 เท่า ความพิเศษของ MobileNetV2 คือการนำ convolution layer และ residual bottleneck layers ในการสร้างโมเดลส่วน feature extraction และใช้ Average Pooling layers ในการสร้างโมเดลส่วน Classifier ส่งผลให้ขนาดของโมเดลมีขนาดเล็กลง เหมาะกับการนำไปพัฒนาโมบายแอปพลิเคชัน เมื่อเทียบประสิทธิภาพกับโมเดลอื่น ได้แก่ MobileNetV1 , ShuffleNet และ NasNet-A ผลการทดสอบรู้จำภาพ ImageNet ของชุดทดสอบ พบว่า MobileNetV2 มีค่าความถูกต้องสูงที่สุดคือ 72.0% และมีขนาดเล็กกว่าโมเดลอื่น

Cecotti. et al. (2020) ได้ทดสอบประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการตรวจจับองุ่นขาวอัลบาริโน (Albariño white grapes) และองุ่นแดงบาร์เบรา (Barbera red grapes) โดยใช้โมเดลการเรียนรู้เชิงลึกที่ผ่านการฝึกหัดมาแล้ว (pre-trained deep learning architectures) 11 โมเดล ได้แก่ ALEXnet, Densenet201, Googlenet, InceptionResNetV2, InceptionV3, ResNet18, ResNet50, ResNet101, Squeezenet, Vgg16 และ Vgg19 โดยแต่ละโมเดลมีความเหมือนและแตกต่างกันทั้งจำนวนชั้น layer ขนาดภาพนำเข้า (Input Size) จำนวนพารามิเตอร์ประเภทของเลเยอร์สำหรับการทำนาย (Layer of prediction part) ตำแหน่งของชั้นเลเยอร์สำหรับการทำนาย และจำนวนคุณลักษณะที่โมเดลแยกคุณลักษณะออกมาได้ (Features) จากการทดลองพบว่าโมเดลการเรียนรู้เชิงลึกที่สามารถใช้ได้เหมาะสมกับองุ่นขาวอัลบาริโนคือ Resnet50 ซึ่งมีประสิทธิภาพในการจำแนกเท่ากับ 99.6 ± 0.16 และองุ่นแดงบาร์เบราคือ Resnet101 ซึ่งมีประสิทธิภาพในการจำแนกเท่ากับ 99.48 ± 0.26 นั้นหมายความว่าหากต้องการสร้างโมเดลการเรียนรู้เชิงลึกเพื่อจำแนกประเภทองุ่นทั้งสองชนิดนี้ควรเลือกโมเดล Resnet มาปรับปรุง ซึ่งในอนาคตอาจจะนำไปพัฒนาเป็นแอปพลิเคชันเพื่อใช้สำหรับการดูแลไร่องุ่นต่อไปได้

Momeny. et al. (2020) ได้ศึกษาการจำแนกผลเชอร์รี่ที่มีรูปร่างปกติกับไม่ปกติ (regular and irregular shaped) ด้วย CNN เป็นอีกงานวิจัยหนึ่งที่แสดงให้เห็นถึงประสิทธิภาพของการเรียนรู้เชิงลึก โดย Momeny. et al. (2020) ได้นำภาพผลเชอร์รี่จำนวน 719 ภาพ ประกอบด้วยภาพเชอร์รี่ที่มีรูปร่างปกติ 307 ภาพ และภาพเชอร์รี่ที่มีรูปร่างไม่ปกติ 412 ภาพ โดยแต่ละภาพจะมีเพียงผลเชอร์รี่เพียงผลเดียวโดยมีพื้นหลังเป็นสีขาว เพื่อให้การประมวลผลเร็วขึ้น Momeny. et al. (2020) ได้ทำการเตรียมข้อมูลภาพเชอร์รี่ทั้งหมดด้วยการแยกส่วนพื้นหลังกับส่วนของผลเชอร์รี่ออกจากกัน โดยแปลงภาพต้นฉบับเป็นภาพไบนารีด้วยการใช้ Otsu threshold ในการคำนวณค่า threshold ในการสร้างภาพไบนารี เพื่อระบุพิกัดของพิกเซลที่เป็นส่วนพื้นหลังด้วยพิกเซลสีขาว และระบุพิกัดของพิกเซลที่เป็นส่วนของผลเชอร์รี่ด้วยพิกเซลสีดำ เมื่อได้ภาพไบนารีที่สมบูรณ์แล้ว Momeny. et al. (2020) ใช้ภาพไบนารีเป็นเกณฑ์ในการแยกส่วนพื้นหลังกับส่วนของผลเชอร์รี่ออกจากกัน ผลลัพธ์ที่ได้คือพื้นหลังของภาพต้นฉบับจะถูกเปลี่ยนเป็นพิกเซลสีขาวทั้งหมดคงเหลือไว้เพียงส่วนของผลเชอร์รี่ตามภาพต้นฉบับ แต่ด้วยจำนวนชุดข้อมูลภาพมีน้อยเกินไปสำหรับการเรียนรู้เชิงลึก Momeny. et al. (2020) จึงทำการเพิ่มจำนวนข้อมูลภาพ (Data augmentation) โดยใช้เทคนิคการกลับด้านภาพ (mirroring) , การหมุนภาพ (rotating) และการปรับแต่งสี (color manipulations) สามารถเพิ่มเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จำนวนข้อมูลภาพเพิ่มขึ้น 20 เท่า ซึ่งเพียงพอต่อการประมวลผลของ CNN ในการทดลอง Momeny. et al. (2020) ได้ทดลองใช้ CNN จำแนกผลเซอร์รีที่มีรูปร่างปกติกับไม่ปกติ เปรียบเทียบประสิทธิภาพกับการใช้ KNN, ANN, Fuzzy และ Ensemble Decision Trees (EDT) ในการจำแนกผลเซอร์รีที่มีรูปร่างปกติกับไม่ปกติจากคุณลักษณะพื้นผิวของ histogram of gradient (HOG) and Local binary pattern (LBP) จากการทดลองพบว่า CNN สามารถจำแนกผลเซอร์รีที่มีรูปร่างปกติกับไม่ปกติได้ถูกต้องมากที่สุดคิดเป็นร้อยละ 99.4

Osako. et al. (2020) ได้ศึกษาการใช้โมเดล VGG16 ในการตัดแยก 4 สายพันธุ์ของลึนจีใต้หวั่น จากผลการทดลองพบว่า VGG16 สามารถตัดแยกสายพันธุ์ลึนจีได้ถูกต้องเฉลี่ย 98.33% โดยภาพถ่ายที่ใช้ในการทดลองแต่ละภาพประกอบด้วยลึนจีด้านที่มีเส้นแบ่ง (suture-line side) และไม่มีเส้นแบ่ง (non suture-line side) รวมอยู่ด้วยกันในหนึ่งภาพ ก่อนการใช้โมเดล VGG16 ในการตัดแยกสายพันธุ์ Osako. et al. (2020) นำข้อมูลภาพเข้าโปรแกรมที่มีชื่อว่า SHAPE เพื่อประเมินรูปร่างลึนจีในเชิงปริมาณ ซึ่งเป็นคุณลักษณะรูปร่างที่นำไปใช้ในการ Train และ Test ด้วยโมเดล VGG16 ถึงแม้ว่า Osako. et al. (2020) จะไม่ได้เปรียบเทียบประสิทธิภาพโมเดล VGG16 กับโมเดลอื่น แต่จากผลการทดลองทั้งหมดก็สามารถยืนยันประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกได้เป็นอย่างดี

Elen and Avuçlu (2021) ได้นำเสนออัลกอริทึมสำหรับการจำแนกประเภทหลายคลาส (MultiClass Classification) โดยใช้ตัวแยกประเภทด้วยค่าความต่าง (Distance-based classifier) ที่มีชื่อว่า Standardized Variable Distances (SVD) อัลกอริทึม SVD เป็นอัลกอริทึมที่ใช้ค่า Distance ระหว่างข้อมูลทดสอบกับค่าเฉลี่ยของแอดทริบิวต์ในแต่ละคลาสและค่า Z-score ในการคำนวณคะแนนเพื่อใช้ตัดสินใจว่าข้อมูลทดสอบเป็นข้อมูลที่ใกล้เคียงกับคลาสใดมากที่สุด ข้อมูลที่ใช้เป็นชุดข้อมูล Wisconsin Breast Cancer Original (WBCO) ประกอบด้วย 9 แอดทริบิวต์ แบ่งข้อมูลเป็น 2 คลาส และ LED Display Domain (led7digit) ประกอบด้วย 7 แอดทริบิวต์ แบ่งข้อมูลเป็น 10 คลาส ในการทดลองได้นำชุดข้อมูลทดลองจำแนกประเภทด้วยอัลกอริทึมที่หลากหลาย ได้แก่ Decision Tree (DT), Random Forest (RF), k-Nearest Neighbor (k-NN), Multinomial Logistic Regression (MLR), Naïve Bayes (NB), Support Vector Machine (SVM) และ The Minimum Distance Classifier (MDC) เพื่อเปรียบเทียบประสิทธิภาพกับ SVD ซึ่งผลลัพธ์ที่ได้ SVD สามารถจำแนกประเภทของชุดข้อมูล WBCO และ led7digit ได้มีประสิทธิภาพสูงกว่าอัลกอริทึมอื่น รองลงมาคือ SVM และ k-NN ตามลำดับ

Bani and Fekri (2019) ได้ศึกษาการใช้คุณสมบัติพื้นผิวและสีสำหรับการค้นคืนภาพ ซึ่งแบ่งออกเป็น 2 ส่วน ได้แก่ ส่วนของการแยกคุณลักษณะ (features extraction) และส่วนการคำนวณความคล้าย (similarity matching) ซึ่งในส่วนการแยกคุณลักษณะจะถูกแบ่งออกเป็น 3 ขั้นตอน ได้แก่ ขั้นตอนที่ 1 การแยกคุณลักษณะพื้นผิวแบบโลคอล (local texture) โดยนำภาพนำเข้าปรับความคมชัดให้เบลอด้วย Gaussian Blur filter แล้วใช้ grey-level co-occurrence matrix (GLCM) แยกคุณลักษณะพื้นผิวออกมา 4 มุม ประกอบด้วย 0°, 90°, 180° และ 270° ขั้นตอนที่ 2 ใช้ colour histograms จากแต่ละ channel ของ R, G และ B ในการแยกคุณลักษณะสีแบบโกลบอล (Global Colour) ซึ่ง histograms ที่ได้จะถูกแบ่งส่วนออกเป็น 8 ส่วน และขั้นตอนที่ 3 ภาพนำเข้าจะถูกแยกคุณลักษณะพื้นผิวแบบโลคอลอีกครั้งด้วย Gabor filter bank เมื่อดำเนินการครบ 3 ขั้นตอนแล้วจะได้ Feature Vector ที่รวมคุณลักษณะที่แยกได้ทั้งหมดจากขั้นตอนที่กล่าวไปแล้ว หลังจากนั้นนำไปคำนวณความคล้ายด้วย Euclidean Distance ในการทดลองใช้ข้อมูลภาพ 10 คลาสจากฐานเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลภาพ Corel 5K ได้แก่ Africa, Beach, Building, Bus, Dinosaur, Elephant, Flower, Horse, Mountain, และ Food จากการทดลอง เมื่อกำหนดจำนวนภาพที่ค้นคืนได้ เท่ากับ 10, 20 และ 40 ค่า Precision เฉลี่ยเท่ากับ 86.04, 82.94 และ 76.27 ค่า recall เฉลี่ยเท่ากับ 8.60, 16.58 และ 30.51 ตามลำดับ

Jana. et al. (2017) ได้ศึกษาการใช้คุณลักษณะสีและพื้นผิวในการรู้จำผลไม้จากภาพถ่ายสภาวะธรรมชาติทั้งหมด 8 ชนิด ได้แก่ แอปเปิ้ล (Apple), ลูกแพร์เอเชีย (Asian pear), แตงกวา (Cucumber), มะม่วง (Mango), ส้ม (Orange), สับปะรด (Pineapple), ทับทิม (Pomegranate) และสตรอเบอร์รี่ (Strawberry) ด้วยอัลกอริทึม Support Vector Machine (SVM) คุณลักษณะดังกล่าวคือ คุณลักษณะพื้นผิวของ gray-level co-occurrence matrix (GLCM) 4 คุณสมบัติ ได้แก่ Contrast (Ct), Correlation (Cn), Energy (Ey) and Homogeneity (Hy) โดยแต่ละคุณสมบัติใช้ข้อมูล 4 ทิศทางได้แก่ แนวนอน (0°), แนวตั้ง (90°), แนวทแยงมุมซ้าย (45°) และแนวทแยงมุมขวา (135°) รวม 16 คุณลักษณะ และคุณลักษณะสีที่ได้จากโมเดลสี RGB โดยใช้คุณสมบัติทางสถิติของแต่ละช่องสัญญาณของโมเดลสี RGB ได้แก่ ค่าเฉลี่ย (Mean), ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความเบ้ (Skewness) และความโด่ง (Kurtosis) รวม 12 คุณลักษณะ จากการทดลองพบว่าการใช้คุณลักษณะสีและพื้นผิวทั้งหมด 28 คุณลักษณะ สามารถทำงานได้ดีกว่าการใช้คุณลักษณะสีหรือพื้นผิวอย่างใดอย่างหนึ่งเพียงคุณลักษณะเดียว ให้ค่าความถูกต้อง 83.33%

Selvaraj. et al. (2010) ได้ศึกษาการใช้คุณลักษณะสีและพื้นผิวเพื่อรู้จำภาพผลไม้ในซูปเปอร์มาร์เก็ต 15 ชนิด ได้แก่ พลัม (Plum), มันฝรั่งอะกาตะ (Agata Potato), มันฝรั่ง Asterix (Asterix Potato), เม็ดมะม่วงหิมพานต์ (Cashew), หัวหอม (Onion), ส้ม (Orange), มะนาว Taiti (Taiti Lime), กีวี (Kiwi), แอปเปิ้ลฟูจิ (Fuji Apple), แอปเปิ้ลแกรนนี่สมิธ (Granny-Smith Apple), แตงโม (Watermelon), แตงโมน้ำผึ้ง (Honeydew Melon), ผลไม้เนกเตอริน (Nectarine), วิลเลียมส์ แพร์ (Williams Pear) และ ไดมอนด์พีช (Diamond Peach) โมเดลสีที่ใช้คือโมเดลสี HSV โดยนำภาพผลไม้ที่อยู่ในรูปแบบโมเดลสี RGB แปลงเป็นโมเดลสี HSV แล้วนำทั้ง 3 ช่องสัญญาณมาแยกคุณลักษณะโดย H Channel และ S Channel ถูกนำไปวิเคราะห์คุณสมบัติทางสถิติ ได้แก่ ค่าเฉลี่ย (Mean), ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความเบ้ (Skewness) และความโด่ง (Kurtosis) คุณลักษณะที่ได้ทั้งหมดจากคุณสมบัติทางสถิติของ H Channel และ S Channel นี้เท่ากับ 8 คุณลักษณะ ส่วน V Channel ถูกนำไปวิเคราะห์เพื่อแยกคุณลักษณะพื้นผิวด้วย Co-occurrence matrix จำนวน 5 คุณลักษณะ ได้แก่ contrast, energy, local homogeneity, cluster shade และ cluster prominence รวม 13 คุณลักษณะ จากการทดลองพบว่าเมื่อใช้ Minimum Distance Criterion (MDC) รู้จำภาพผลไม้ด้วยคุณลักษณะสีและพื้นผิวร่วมกัน 13 คุณลักษณะ สามารถรู้จำภาพผลไม้ได้ดีกว่าการใช้คุณลักษณะสีหรือพื้นผิวอย่างใดอย่างหนึ่งเพียงคุณลักษณะเดียว ให้ค่าความถูกต้อง 86%

Muhammad (2014) ได้ศึกษาการใช้คุณลักษณะสี พื้นผิว รูปร่าง และขนาด ในการแยกสายพันธุ์อินทผลัมทั้ง 4 สายพันธุ์ ได้แก่ Ajwah, Sagai, Sellaj, และ Sukkary โดยแปลงภาพอินทผลัมออกเป็น 3 ช่องสัญญาณ ได้แก่ R Channel, G Channel และ B Channel ของโมเดลสี RGB แล้วนำไปสร้างฮิสโตแกรมด้วยอัลกอริทึม local binary pattern (LBP) และ Weber local descriptor (WLD) จากการทดลองพบว่าฮิสโตแกรมที่ได้มีรูปแบบ (pattern) ที่แตกต่างกันอย่างชัดเจน แต่ด้วยคุณลักษณะที่ได้มีปริมาณสูง นั่นคือจำนวนคุณลักษณะที่ได้จาก LBP histograms เท่ากับ 177 (3 เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

channels แต่ละchannel มี 59 bins) และจำนวนคุณลักษณะที่ได้จาก WLD histogram เท่ากับ 360 (3 channels แต่ละchannel มี 120 bins) ดังนั้นจึงนำ Fisher discrimination ratio (FDR) มาใช้ในการเลือกคุณลักษณะที่สำคัญ โดยเลือก 10 คุณลักษณะแรกที่ทำให้ค่า FDR มากที่สุด สำหรับคุณลักษณะรูปร่างและขนาด นำข้อมูลภาพไปวิเคราะห์ 4 คุณลักษณะ ได้แก่ Major axis length, Minor axis length, Ellipse eccentricity และ Area โดยในการทดลองมีการแบ่งการทดลองออกเป็น 3 แบบ ได้แก่ แบบที่ 1 ใช้ 10 คุณลักษณะ จาก LBP histograms แบบที่ 2 ใช้ 10 คุณลักษณะ จาก WLD histograms และแบบที่ 3 ใช้ 10 คุณลักษณะ จาก LBP หรือ WLD histograms ซึ่งการทดลองทั้งสามแบบจะใช้ 4 คุณลักษณะของรูปร่างและขนาดรวมด้วย นั้นหมายความว่า Muhammad (2014) ใช้คุณลักษณะในการแยกสายพันธุ์อินทผลัม 14 คุณลักษณะเท่านั้น อัลกอริทึมที่ใช้คือ SVM จากการทดลองพบว่า การทดลองแบบที่ 3 คือคุณลักษณะจาก LBP หรือ WLD histograms 10 คุณลักษณะร่วมกับคุณลักษณะรูปร่างและขนาด 4 คุณลักษณะ ให้ผลลัพธ์ที่ดีกว่าแบบอื่น ให้ค่าความถูกต้องสูงถึง 99%

Fu. et al. (2019) ได้นำเสนอการตรวจจับกล้วยด้วยคุณลักษณะสีและพื้นผิวในสภาวะแวดล้อมทางธรรมชาติ มีวัตถุประสงค์เพื่อพัฒนานวัตกรรมสำหรับการเก็บเกี่ยวกล้วยในสวนด้วยหุ่นยนต์ ซึ่งงานสำคัญที่ต้องให้หุ่นยนต์เรียนรู้คือตำแหน่งของเครือกล้วยที่อยู่บนต้นว่าอยู่ตำแหน่งใด โดยความยากของงานนี้คือสีของกล้วยและสีของต้นกล้วยมีสีเดียวกันคือสีเขียว ดังนั้นการจะให้หุ่นยนต์แยกแยะเครือกล้วยออกจากพื้นหลังเป็นงานที่ค่อนข้างยาก หากใช้คุณลักษณะสี RGB อย่างเดียวคงไม่เพียงพอ จึงพิจารณาโมเดลสีอื่นๆ โดยช่องสัญญาณความอิ่มตัวสี (S: Saturation Channel) และช่องสัญญาณความสว่างของแสง (V: Value Channel) จากโมเดลสี HSV ถูกนำมาใช้ในการทดลอง ด้วยการนำภาพต้นฉบับซึ่งเป็นภาพที่ถ่ายในเวลาที่มีปริมาณแสง (Illumination) แตกต่างกันได้แก่ ช่วงเวลาแสงแดดมาก (Sunny) ช่วงแสงแดดปานกลาง (Sunny Front Light) และช่วงแสงแดดน้อย (Cloudy) นำมาแปลงเป็นภาพโทนเทา (Grayscale) จากช่องสัญญาณความอิ่มตัวสี (S) และช่องสัญญาณความสว่างของแสง (V) ทำการแปลงภาพโทนเทาเป็นภาพขาวดำ (Binary Image) โดยใช้ฟังก์ชันของ Otsu แล้วนำภาพขาวดำจากทั้งสองช่องสัญญาณมาเปรียบเทียบกัน ซึ่งถ้าพิกเซลใดมีค่าเท่ากัน จะปรับพิกเซลนั้นให้เป็น 0 นั่นคือสีดำ แต่ถ้าพิกเซลใดไม่เท่ากันจะปรับพิกเซลนั้นให้เท่าค่าของพิกเซลที่ได้จากช่องสัญญาณความอิ่มตัวสี (S) หลังจากประมวลผลครบทุกพิกเซลแล้วจะทำการเปลี่ยนแปลงลักษณะรูปร่างหรือโครงร่างของภาพเพื่อลดพิกเซลที่ไม่ต้องการออกไป ด้วย Morphological Operation นอกจากนี้มีขั้นตอนการแยกคุณลักษณะรูปร่าง (Shape) ของเครือกล้วยด้วย Histogram of oriented gradients (HOG) และแยกคุณลักษณะพื้นผิว (Texture Feature) ของเครือกล้วยด้วย Local binary patterns (LBP) หลังจากแยกคุณลักษณะเรียบร้อยแล้ว นำภาพไปทดลองตรวจจับกล้วยด้วยอัลกอริทึม Support vector machine (SVM) และ อัลกอริทึม AdaBoost (AdaBoost algorithm) จากผลการทดลองพบว่า อัลกอริทึมที่นำ HOG, LBP และ SVM มาประมวลผลร่วมกันเป็นอัลกอริทึมที่มีประสิทธิภาพสูงสุดให้ค่าความถูกต้อง 89.63%

Reyes. et al. (2021) ได้ศึกษาการใช้คุณลักษณะสีในการจำแนกประเภทของเชอร์รี่ 5 ประเภท โดยการนำภาพผลเชอร์รี่ที่อยู่บนสายพานสีขาว แปลงภาพจาก RGB เป็น HSV แล้วนำช่องสัญญาณ R และ G ไปเทียบกับค่า Threshold ที่ได้จาก บัตรสีมาตรฐานของเชอร์รี่ เพื่อแบ่งส่วนภาพ (image segmentation) พื้นหลังออกจากผลเชอร์รี่ หลังจากนั้นนำช่องสัญญาณ R และ H เฉพาะส่วนของผลเชอร์รี่ คำนวณค่าทางสถิติ ได้แก่ ค่าเฉลี่ย (Mean) และค่าเบี่ยงเบนมาตรฐาน เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(standard deviation) เพื่อนำไปคำนวณค่าความน่าจะเป็นว่าภาพทดสอบมีค่าความน่าจะเป็นกับคลาสใดมากที่สุด จากการทดลองพบว่าค่าความถูกต้องในการจำแนกประเภทด้วยวิธีสามารถจำแนกได้ 100% แต่ด้วยข้อมูลภาพที่ใช้ Train จำนวน 63 ภาพ และ Test เพียง 36 ภาพ เป็นขนาดชุดข้อมูลที่ค่อนข้างน้อยอาจเป็นปัจจัยที่ส่งผลให้การจำแนกประเภทไม่ผิดพลาดเลย หากเพิ่มจำนวนชุดข้อมูลอาจได้ผลลัพธ์ที่เหมือนเดิมหรือแตกต่างออกไป

Hamza and Chtourou (2020) ได้ศึกษาวิธีการจำแนกแบบคลุมเครือ (fuzzy classification) ด้วยคุณลักษณะสีของเปลือกแอปเปิ้ลเพื่อประเมินความสุกงอมของผลแอปเปิ้ลตามระยะสุก 3 ระยะ ได้แก่ ยังไม่สุก (unripe) กึ่งสุก (turning-ripe) และสุกงอม (ripe) โดยเริ่มจากการแปลงภาพนำเข้าจาก RGB เป็น $L^*a^*b^*$ แล้วใช้ a^* และ b^* channel ในการแบ่งส่วนภาพผลไม้ (image segmentation) ด้วยอัลกอริทึม K nearest neighbour ออกเป็น 4 ส่วน ได้แก่ พื้นหลัง (background) พิกเซลสีดำ, พื้นที่สีเขียว (green area) พิกเซลสีเขียว, พื้นที่สีเหลือง (yellow area) พิกเซลสีเหลือง และพื้นที่สีแดง (red area) พิกเซลสีแดง ซึ่ง 3 ส่วนสุดท้ายจะถูกนำไปแยกคุณลักษณะสี (Features extraction phase) โดยคำนวณอัตราส่วนระหว่างจำนวนพิกเซลที่ปรากฏสีเขียว หรือสีเหลือง หรือสีแดง กับจำนวนพิกเซลส่วนของผลแอปเปิ้ลทั้งหมด ผลลัพธ์ที่ได้ก็คือ พื้นที่สีเขียว (green area) พื้นที่สีเหลือง (yellow area) และสีแดง (red area) นั่นเอง ในขั้นตอน fuzzy classification มีการใช้พื้นที่ทั้งสามสีที่คำนวณได้ไปสร้างกฎ (Rule) เพื่อใช้ในการประเมินความสุกงอมของผลแอปเปิ้ล กฎที่ได้มาจากพื้นที่สีในผลแอปเปิ้ลมี 3 สี ระยะการสุกงอม 3 ระยะ และแต่ละกฎจะประกอบด้วยระยะการสุกงอมของพื้นที่แต่ละสีของผลแอปเปิ้ล ดังนั้นตามหลักความน่าจะเป็น กฎที่ได้จะมีทั้งหมด 27 กฎ โดยผลลัพธ์ของแต่ละกฎจะอ้างอิงจาก Gaussian-shaped input MFs ของ Takagi-Sugeno FIS (TS-FIS) ในการทดลองใช้ข้อมูลภาพแอปเปิ้ลจำนวน 600 ภาพ โดยแบ่งออกเป็น 3 คลาส ได้แก่ ยังไม่สุก (unripe) กึ่งสุก (turning-ripe) และสุกงอม (ripe) คลาสละ 200 ภาพ ลักษณะของภาพจะประกอบด้วยผลแอปเปิ้ล 1 ผลต่อ 1 ภาพ แต่ละภาพแสดงคุณลักษณะสีที่บ่งบอกถึงระยะการสุกงอมอย่างชัดเจน นั่นคือแอปเปิ้ลที่ยังไม่สุกจะมีสีเขียว กึ่งสุกจะมีหลากสีผสมกันซึ่งเป็นการเปลี่ยนสีจากสีเขียวเป็นสีแดง และสุกงอมจะมีสีแดง โดยมีพื้นหลังเป็นสีขาว แบ่งภาพ 9:1 ส่วนสำหรับ Train และ Test ตามลำดับ ดำเนินการทดลองแบบ 10-Fold validation ผลการทดลองที่ได้พบว่าวิธีที่นำเสนอนี้ได้ค่าความถูกต้องสูงถึง 99.33% เมื่อนำ ANN และ SVM มาทดลองเพื่อเปรียบเทียบประสิทธิภาพ ได้ค่าความถูกต้อง 98.33% และ 96.66% ตามลำดับ

Trieu and Think (2021) ได้นำเสนอการจำแนกคุณภาพของแก้วมังกรจากลักษณะภายนอก โดยการใช้การประมวลผลภาพ การเรียนรู้ของเครื่องด้วย Support vector machine (SVM) และโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network) ประกอบไปด้วย 1) การลบพื้นหลังออกภาพด้วย SVM กับ Self-Training Method 2) การตรวจจับกบิลรอบผลแก้วมังกรด้วยโมเดลโครงข่ายประสาทแบบคอนโวลูชัน 3) การประมวลผลภาพเพื่อแยกคุณลักษณะความกว้าง ความยาวและตำหนิที่ปรากฏบริเวณผิวและเปลือกของผลแก้วมังกร และ 4) การประเมินขนาดของผลแก้วมังกรด้วยน้ำหนักและพื้นที่ของตำหนิที่ตรวจพบบริเวณผิวและเปลือกของแก้วมังกรเพื่อจำแนกกลุ่มคุณภาพของแก้วมังกรตามเกณฑ์ตามที่กำหนดไว้ในมาตรฐานการส่งออกของประเทศเวียดนาม ภาพถ่ายที่ใช้ในการทดลองเป็นภาพถ่ายที่บันทึกผลแก้วมังกรที่ถูกลำเลียงทางสายพานที่มีการติดตั้งกล้องบันทึกภาพ และ Loadcell Sensor เพื่อตรวจวัดน้ำหนักของแก้วมังกรแต่ละผล จากการทดลองพบว่าการใช้ SVM กับ Self-Training Method ในการลบพื้นหลังออกภาพให้ค่าความ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ถูกต้องเท่ากับ 92.90% การตรวจจับกิ่งสีรอบผลแก้วมังกรด้วยโมเดลโครงข่ายประสาทแบบคอนโวลูชันให้ค่าความถูกต้องเท่ากับ 97.38% และกระบวนการที่นำเสนอนี้สามารถจำแนกคุณภาพของแก้วมังกรได้ถูกต้อง 96.38%

Dubey. et al. (2013) ได้ศึกษาการตรวจจับส่วนที่ติดเชื้อของผลไม้ด้วยการแบ่งกลุ่มข้อมูลแบบเคมีน ชุดข้อมูลภาพที่ใช้ในการทดลองคือภาพแอปเปิ้ลที่มีการติดเชื้อ 3 แบบ ได้แก่ แอปเปิ้ลตกละเอียด แอปเปิ้ลเน่า และแอปเปิ้ลโรคต่าง โดยเริ่มจากการแปลงภาพนำเข้าจาก RGB เป็น $L^*a^*b^*$ แล้วใช้ a^* และ b^* channel นำข้อมูลภาพทั้งสองช่องสัญญาณแบ่งกลุ่มข้อมูลแบบเคมีน โดยกำหนดจำนวนกลุ่มข้อมูลเป็น 2, 3 4 และ 5 กลุ่ม จากผลการทดลองพบว่าการแบ่งกลุ่มข้อมูลเป็น 3 และ 4 กลุ่ม สามารถแบ่งส่วนที่ติดเชื้อได้ดีกว่า ซึ่งการตัดสินใจว่าส่วนใดเป็นส่วนติดเชื้อสามารถใช้ค่าเฉลี่ยของพิกเซลของ a^* และ b^* channel ได้ ทั้งนี้การนำเสนองานวิจัยของ Dubey. et al. (2013) เป็นแนวทางที่ช่วยลดเวลาในการประมวลผลลง หลีกเลี่ยงการแยกคุณลักษณะของข้อมูลภาพที่อาจมีหลายขั้นตอน

De Luna et al. (2019) ได้นำเสนอการจำแนกขนาดของมะเขือเทศ โดยใช้ ค่าขีดแบ่ง (Thresholding) การเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ชุดข้อมูลภาพที่ใช้ในการทดลองเป็นภาพมะเขือเทศที่ถูกบันทึกในห้องปฏิบัติการ ประกอบไปด้วย ขนาดเล็ก ขนาดกลาง และขนาดใหญ่ การทดลองดำเนินการด้วยการเตรียมข้อมูลภาพ การแบ่งส่วนภาพ การแยกคุณลักษณะทางเรขาคณิต ได้แก่ พื้นที่ เส้นรอบรูป และรัศมีวงกลม และการจำแนกขนาดของมะเขือเทศด้วยเทคนิคที่แตกต่างกันทั้ง 3 แบบ จากผลการทดลองพบว่าการใช้ค่าขีดแบ่งด้วยคุณลักษณะพื้นที่ให้ค่าความถูกต้องสูงกว่าคุณลักษณะอื่น มีค่าเท่ากับ 85.83% การใช้การเรียนรู้ของเครื่องด้วย Support vector machine (SVM) ให้ค่าความถูกต้องสูงกว่า K-Nearest Neighbors (KNN) และ Artificial Neural Network (ANN) มีค่าความถูกต้องเท่ากับ 95.00% และ การใช้การเรียนรู้เชิงลึกในการจำแนกขนาดมะเขือเทศพบว่าโมเดล VGG16 ให้ค่าความถูกต้องสูงกว่าโมเดล InceptionV3 และ โมเดล ResNet50 มีค่าความถูกต้องเท่ากับ 55.97% ดังนั้นจากการทดลองของ De Luna et al. (2019) แสดงให้เห็นว่าประสิทธิภาพของการจำแนกขนาดมะเขือเทศขึ้นอยู่กับเทคนิคที่ใช้ในการจำแนกด้วย ซึ่งการทดลองนี้ทำให้เห็นผลลัพธ์ที่ชัดเจนว่าการใช้การเรียนรู้ของเครื่องด้วย SVM เป็นแบบจำลองที่ดีที่สุดในการนำไปใช้จำแนกขนาดมะเขือเทศ

Narendra and Pinto (2021) ได้นำเสนอการตรวจหาข้อบกพร่องในผักและผลไม้โดยใช้การประมวลผลภาพและการเรียนรู้ของเครื่อง ชุดข้อมูลภาพที่ใช้ในการทดลองเป็นภาพผักและผลไม้ที่สมบูรณ์และติดเชื้อ 3 ชนิด ได้แก่ แอปเปิ้ล ส้ม และมะเขือเทศ การทดลองดำเนินการด้วยการเตรียมข้อมูลภาพ การแบ่งส่วนภาพให้เหลือเฉพาะส่วนของผักและผลไม้ การแยกคุณลักษณะทางสัญญาณวิทยา 6 คุณลักษณะ ได้แก่ ความยาว ความกว้าง พื้นที่ เส้นรอบวง การยืดตัว และความขรุขระ คุณลักษณะสี 15 คุณลักษณะจากโมเดลสี $L^*a^*b^*$ ได้แก่ ค่าเฉลี่ยของช่องสัญญาณ L^* , a^* และ b^* ส่วนเบี่ยงเบนมาตรฐานของ L^* , a^* และ b^* ช่วงของ L^* , a^* และ b^* เมตริกระยะสีของแต่ละองค์ประกอบสี L^* , a^* และ b^* , โครมา, เสดสี และ คะแนนสี และคุณลักษณะพื้นผิว 2 คุณลักษณะของอัลกอริทึม Segmentation-based Fractal Texture Analysis (SFTA) ได้แก่ พลังงาน (energy) และความแปรปรวน (contrast) รวมทั้งหมด 23 คุณลักษณะ และตรวจหาข้อบกพร่องในผักและผลไม้ด้วย Naïve Bayes จากผลการทดลองพบว่าวิธีการดังกล่าวสามารถตรวจหาข้อบกพร่องในผัก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และผลไม้ได้ถูกต้อง 87.00% โดยตรวจหาข้อบกพร่องของภาพส้มได้ถูกต้อง 93.00% ในขณะที่การตรวจหาข้อบกพร่องของภาพแอปเปิ้ลถูกต้องเท่ากับภาพมะเขือเทศ มีค่าเท่ากับ 83.00%

นพรุจ และ ณัฐวุฒิ (2563) นำเสนอการประมวลผลภาพสำหรับการจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์โดยการจำลองการมองเห็นของมนุษย์ด้วยวิธีการเรียนรู้เชิงลึก ชุดข้อมูลภาพที่ใช้เป็นภาพมะม่วงสายพันธุ์โชคอนันต์ จำนวน 800 ภาพ แบ่งออกเป็น 4 กลุ่ม ได้แก่ มะม่วงคุณภาพระดับเกรด A คุณภาพระดับเกรด B คุณภาพระดับเกรด C และคุณภาพระดับเกรด D คือมะม่วงเน่า ในการทดลองแบ่งชุดข้อมูลภาพสำหรับการเรียนรู้ (Training Dataset) และทดสอบ (Testing Dataset) แบบจำลอง สัดส่วน 75% และ 25% ตามลำดับ ใช้เทคนิคการทดลองซ้ำแบบ 10-folds cross validation สำหรับแบบจำลองการเรียนรู้เชิงลึก ใช้ภาษา Python ในการพัฒนา โดยใช้ไลบรารีสำหรับพัฒนา Deep Learning ร่วมกันคือ Keras และ Tensorflow กำหนดค่า epoch เท่ากับ 50 จากผลการทดลองพบว่าแบบจำลองการเรียนรู้เชิงลึกด้วยอัลกอริธึม CNN มีประสิทธิภาพสูง เหมาะสำหรับการประมวลผลภาพเพื่อจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์ ให้ค่าถูกต้องเท่ากับ 99.79%

Fu. et al. (2022) ได้นำเสนอการวัดคุณภาพของผลไม้โดยพิจารณาจากความสดด้วยการเรียนรู้เชิงลึก ชุดข้อมูลที่ใช้ในการทดลองเป็นชุดข้อมูลภาพผลไม้ 6 ชนิด ได้แก่ แอปเปิ้ล, กล้วย, แก้วมังกร, ส้ม, ลูกแพร์ และกีวี ผลไม้แต่ละชนิดจะถูกบันทึกภาพ 3 ระยะ ได้แก่ ระยะเน่าเสียแล้ว ระยะกำลังเน่าเสีย และระยะสดสมบูรณ์ โดยมีการกำหนดคะแนนความสดให้มีความตั้งแต่ 0-10 คะแนน โดย 0 คะแนนหมายถึงผลไม้เน่าเสียแล้ว 10 คะแนนหมายถึงผลไม้มีความสดสมบูรณ์ กระบวนการดำเนินการทดลองประกอบไปด้วยการปรับปรุงคุณภาพของข้อมูลภาพ (Image Quality Enhancement) การเพิ่มข้อมูล (Image Augmentation) การตรวจจับตำแหน่งและจำแนกชนิดผลไม้ (Object Detection and Classification) และการวัดคุณภาพของผลไม้ด้วยการโมเดลการเรียนรู้เชิงลึก จากผลการทดลองพบว่าการใช้โมเดล YOLO ในการตรวจจับตำแหน่งและจำแนกชนิดผลไม้ร่วมกับการประเมินคะแนนความสดของผลไม้ทั้ง 6 ชนิดด้วย CNN โมเดล พบว่าโมเดล AlexNet มีอัตราความผิดพลาด (Error Rate) น้อยที่สุดสำหรับการฝึกหัด มีค่าเท่ากับ 3.50% และโมเดล VGG16 มีอัตราความผิดพลาดน้อยที่สุดสำหรับการทดลอง มีค่าเท่ากับ 3.93%

Fitri. et al. (2021) ได้นำเสนอการจำแนกคุณภาพของแก้วมังกรเปลือกแดงเนื้อขาว (*Hylocereus undatus*) ด้วยการประมวลผลภาพและโมเดลการจำแนกคุณภาพด้วย Backpropagation ในกระบวนการประมวลผลภาพ Fitri. et al. (2021) ใช้ภาพช่องสัญญาณ blue ของโมเดลสี RGB ในการแบ่งส่วนพื้นหลังออกจากส่วนผลแก้วมังกร โดยแปลงภาพ blue ให้เป็นภาพไบนารีด้วยค่าเกณฑ์เท่ากับ 125 แล้วนำภาพที่เหลือเพียงส่วนของผลแก้วมังกรไปแยกคุณลักษณะทางสัญญาณวิทยา ประกอบด้วย ความยาว เส้นผ่านศูนย์กลาง พื้นที่ เส้นรอบรูป และค่าเมทริกซ์ ซึ่งคุณลักษณะดังกล่าวถูกนำไปใช้ประมวลผลต่อด้วยโมเดล Backpropagation ที่มีโครงสร้างแตกต่างกัน จากผลการทดลองพบว่า โมเดล Backpropagation ที่มีโครงสร้างแบบ 5,8,5,3 กำหนด learning rate เท่ากับ 0.05 ให้ค่าความถูกต้องในการจำแนกคุณภาพดีกว่าโครงสร้างอื่น มีค่าความถูกต้องเท่ากับ 96.95% สำหรับชุดฝึกหัด และ 86.67% สำหรับชุดทดสอบ

Fitri. et al. (2022) ได้นำเสนอการจำแนกคุณภาพของแก้วมังกรเปลือกแดงเนื้อแดง (*Hylocereus costaricensis*) ด้วยการประมวลผลภาพและโมเดลการจำแนกคุณภาพที่แตกต่างกัน 3 โมเดล ได้แก่ K-Nearest Neighbor (KNN), Naïve Bayes และ Backpropagation ในกระบวนการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เตรียมข้อมูลภาพแก้วมังกรเปลือกแดงเนื้อแดง Fitri. et al. (2022) ยังคงใช้วิธีการเดิมเช่นเดียวกับการเตรียมข้อมูลภาพแก้วมังกรเปลือกแดงเนื้อขาว Fitri. et al. (2021) ภาพช่องสัญญาณ blue ของโมเดลสี RGB ถูกใช้ในการแบ่งส่วนพื้นหลังออกจากส่วนผลแก้วมังกรและแปลงภาพ blue ให้เป็นภาพไบนารีด้วยค่าเกณฑ์เท่ากับ 125 แต่การจำแนกคุณภาพของแก้วมังกรเปลือกแดงเนื้อแดง Fitri. et al. (2022) ใช้คุณลักษณะทางสีพื้นฐานวิทยาเพียง 4 คุณลักษณะ ได้แก่ ความยาว เส้นผ่านศูนย์กลาง พื้นที่ และเส้นรอบรูป ซึ่งคุณลักษณะดังกล่าวจะถูกนำไปใช้ประมวลผลต่อด้วยโมเดลการจำแนกคุณภาพด้วย KNN, Naïve Bayes และ Backpropagation จากผลการทดลองพบว่า โมเดล Backpropagation ที่มีโครงสร้างแบบ 4,8,3 กำหนด learning rate เท่ากับ 0.3 ให้ค่าความถูกต้องในการจำแนกประเภทดีกว่าโมเดลอื่น มีค่าความถูกต้องเท่ากับ 98.61% สำหรับชุดฝึกหัด และ 86.67% สำหรับชุดทดสอบ

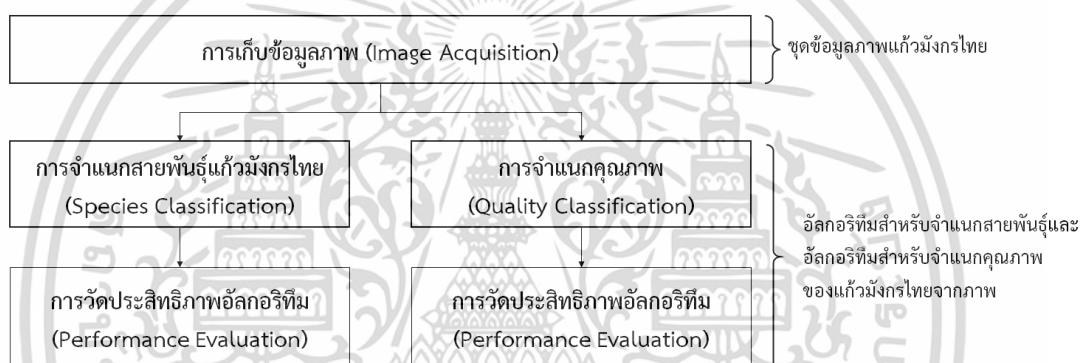


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

วิธีการดำเนินงานวิจัย

งานวิจัยนี้นำเสนอการจำแนกสายพันธุ์และการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ โดยใช้เทคนิคการประมวลผลภาพด้วยคอมพิวเตอร์และการเรียนรู้ของเครื่อง ซึ่งมีการสร้างชุดข้อมูลภาพแก้วมังกรไทยขึ้นมาใหม่และการทดลองเพื่อพัฒนาอัลกอริทึมที่เหมาะสมที่สุดในการจำแนกสายพันธุ์และการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ จากการศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องได้ออกแบบขั้นตอนวิธีการดำเนินงานวิจัย ประกอบไปด้วย 4 ขั้นตอนหลัก ได้แก่ 1) การเก็บข้อมูลภาพ (Image Acquisition) 2) การจำแนกสายพันธุ์แก้วมังกรไทย (Species Classification) 3) การจำแนกคุณภาพ (Quality Classification) และ 4) การวัดประสิทธิภาพอัลกอริทึม (Performance Evaluation) ดังรูปที่ 3.1 โดยมีรายละเอียดดังนี้



รูปที่ 3.1 ขั้นตอนวิธีดำเนินงานวิจัย

3.1 การเก็บข้อมูลภาพ (Image Acquisition)

ในการวิจัยครั้งนี้มีการค้นหาข้อมูลภาพแก้วมังกรจากแหล่งข้อมูลขนาดใหญ่ใน Kaggle.com พบข้อมูลภาพแก้วมังกรบรรจุอยู่ในชุดข้อมูล Fruit-360 (Muresan and Oltean, 2018) เพียง 1 ชนิดเท่านั้นซึ่งไม่เพียงพอต่อความต้องการของงานวิจัยนี้ ดังนั้นจึงมีขั้นตอนการเก็บข้อมูลภาพเพื่อสร้างชุดข้อมูลขึ้นมาใหม่ โดยการสร้างชุดข้อมูลใหม่ที่มีการลงพื้นที่สำรวจและศึกษาข้อมูลการเพาะปลูกแก้วมังกรในประเทศไทย พบว่าแหล่งเพาะปลูกที่ให้ผลผลิตมากที่สุดในประเทศไทยคือพื้นที่จังหวัดเลย (Department of agricultural extension, Ministry of Agriculture and Cooperatives, 2020) ดังนั้นผู้วิจัยจึงดำเนินการเก็บข้อมูลภาพด้วยการเก็บตัวอย่างแก้วมังกรไทยมาบันทึกภาพในห้องปฏิบัติการและบันทึกภาพผลแก้วมังกรบนต้นในสภาวะแวดล้อมกลางแจ้ง โดยมีรายละเอียดดังนี้


3.1.1 ตัวอย่างแก้วมังกร

ในการวิจัยครั้งนี้ได้ทำการศึกษาเกี่ยวกับข้อมูลสายพันธุ์ของแก้วมังกรที่เพาะปลูกในประเทศไทยและการลักษณะของผลแก้วมังกรของแต่ละชั้นคุณภาพและเกณฑ์การแบ่งกลุ่มแก้วมังกรตามขนาดของผลแก้วมังกร เพื่อใช้ในการทดลองพัฒนาอัลกอริทึมการจำแนกสายพันธุ์และการจำแนก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


คุณภาพของแก้วมังกรไทยจากภาพ โดยกลุ่มตัวอย่างแก้วมังกรที่ใช้งานวิจัยนี้มาจากแหล่งเพาะปลูกในเขตพื้นที่อำเภอเมืองเลย อำเภอภูเรือ และอำเภอด่านซ้าย ของจังหวัดเลย

กลุ่มตัวอย่างแก้วมังกรที่นำมาใช้ในการทดลองจำแนกสายพันธุ์แก้วมังกรไทยจากภาพประกอบไปด้วยแก้วมังกรทั้งหมด 7 สายพันธุ์ แบ่งเป็นกลุ่มที่ 1 เปลือกสีแดงเนื้อสีขาว 2 สายพันธุ์ ได้แก่ พันธุ์ขาวจัมโบ้ (Jumbo White) , พันธุ์ขาวเวียดนาม (Vietnamese White) กลุ่มที่ 2 เปลือกสีแดงเนื้อสีแดง หรือ เปลือกสีแดงเนื้อชมพู 4 สายพันธุ์ ได้แก่ พันธุ์ชมพูจินดา (Pink), พันธุ์แดงสยาม (Siam Red), พันธุ์แดงไต้หวัน (Taiwan Red), พันธุ์แดงทับทิม (Ruby Red) และกลุ่มที่ 3 เปลือกสีเหลืองหรือทอง เนื้อสีขาว 1 สายพันธุ์ ได้แก่ พันธุ์เหลืองอิสราเอล (Israel Yellow) ดังรูปที่ 3.2



รูปที่ 3.2 แสดงตัวอย่างแก้วมังกรโดยแบ่งตามสายพันธุ์

สำหรับกลุ่มตัวอย่างแก้วมังกรที่นำมาใช้ในการทดลองจำแนกคุณภาพของแก้วมังกรไทยจากภาพ เป็นแก้วมังกรสายพันธุ์ขาวจัมโบ้ 2 กลุ่มตัวอย่าง ได้แก่ ตัวอย่างแก้วมังกรที่แบ่งกลุ่มตามขนาดของผลแก้วมังกร ประกอบไปด้วยรหัสขนาด 1-6 ดังรูปที่ 3.3 และตัวอย่างแก้วมังกรที่แบ่งกลุ่มตามชั้นคุณภาพของผลแก้วมังกร ประกอบด้วย 3 ชั้นคุณภาพหลัก ได้แก่ ชั้นพิเศษ (Extra class) ชั้นหนึ่ง (Class I) และชั้นสอง (Class II) และ 1 ชั้นคุณภาพเพิ่มเติม คือชั้นสาม (Class III) ซึ่งเป็นชั้นคุณภาพที่เพิ่มเข้ามาในการวิจัยครั้งนี้เนื่องจากมีวัตถุประสงค์ต้องการจำแนกแก้วมังกรที่มีคุณภาพต่ำกว่ามาตรฐานที่กระทรวงกำหนดไว้ ดังรูปที่ 3.4



รูปที่ 3.3 แสดงตัวอย่างแก้วมังกรโดยแบ่งตามรหัสขนาด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้เผยแพร่ไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.4 แสดงตัวอย่างแก้วมังกรโดยแบ่งตามชั้นคุณภาพ

3.1.2 ชุดข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกสายพันธุ์แก้วมังกรไทย

ชุดข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกสายพันธุ์แก้วมังกรไทยในการวิจัยครั้งนี้ ประกอบไปด้วย ชุดข้อมูลภาพในห้องปฏิบัติการและชุดข้อมูลภาพในสภาวะแวดล้อมกลางแจ้ง

3.1.2.1 ชุดข้อมูลภาพในห้องปฏิบัติการ


ในการเก็บข้อมูลภาพในห้องปฏิบัติการ (Laboratory) สำหรับพัฒนาอัลกอริทึมจำแนกสายพันธุ์แก้วมังกรไทย ผู้วิจัยนำตัวอย่างแก้วมังกรมาบันทึกภาพในห้องปฏิบัติการ โดยแก้วมังกรเหล่านี้มีอายุหลังเก็บเกี่ยวไม่เกิน 1 สัปดาห์ อุปกรณ์ที่ใช้ในการเก็บข้อมูลภาพ ประกอบไปด้วย กล้องสตูดิโอแบบพกพาขนาด 40x40 เซนติเมตร มีการติดตั้งไฟแอลอีดี 1 แถวบริเวณขอบด้านบนของกล้อง ใช้สำหรับเป็นพื้นที่วางผลแก้วมังกรและจัดสภาพแสงสว่างในการบันทึกภาพ ผ้ากำมะหยี่สีดำใช้สำหรับเป็นพื้นหลัง โทรศัพท์เคลื่อนที่ที่ใช้สำหรับบันทึกภาพ แท่นวางโทรศัพท์เคลื่อนที่ ใช้สำหรับวางโทรศัพท์เคลื่อนที่ขณะบันทึกภาพ แสดงดังรูปที่ 3.5



รูปที่ 3.5 อุปกรณ์ที่ใช้ในการเก็บข้อมูลภาพในห้องปฏิบัติการ

หลังจากจัดเตรียมอุปกรณ์ที่ใช้ในการเก็บข้อมูลภาพเรียบร้อยแล้ว ผู้วิจัยบันทึกภาพแก้วมังกรด้วยกล้องของโทรศัพท์เคลื่อนที่ ซึ่งตั้งค่าขนาดภาพในอัตราส่วน 1:1 ปิดการทำงานของฟิลเตอร์ทั้งหมด และวางผลแก้วมังกรในกล้องสตูดิโอที่บุพื้นหลังด้วยผ้ากำมะหยี่สีดำ เปิดไฟแอลอีดีที่ถูกติดตั้งบริเวณขอบด้านบนของกล้องสตูดิโอ เพื่อให้แสงสว่างเพียงพอต่อการมองเห็น ดังแสดงในรูปที่ 3.6(a)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.6 แสดงตัวอย่างวิธีการเก็บข้อมูลภาพในห้องปฏิบัติการ

ในการถ่ายภาพกำหนดให้ผลแก้วมังกรอยู่ตรงกลางภาพมากที่สุด โดยใช้เส้นแบ่งเก้าช่องเป็นตัวช่วยในการวางเลย์เอาต์ของภาพ ดังแสดงในรูปที่ 3.6(b) นอกจากนี้ผู้วิจัยใช้เทคนิคในการเก็บข้อมูลภาพจากการศึกษางานวิจัยของ Muresan and Oltean (2018) ด้วยการหมุนวัตถุให้ได้ 360 องศาเท่าที่เป็นไปได้ และ Osako. et al. (2020) การใช้พื้นหลังเป็นสีดำเพื่อดึงความโดดเด่นของผลไม้ออกมา ดังนั้นภาพที่ได้จึงมีลักษณะดังรูปที่ 3.7



รูปที่ 3.7 ตัวอย่างข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการ

โดยภาพที่ได้มีขนาด 3,456x3,456 พิกเซล ภาพแต่ละภาพมีเพียงแก้วมังกรหนึ่งผลหนึ่งสายพันธุ์ ในหนึ่งสายพันธุ์ใช้ตัวอย่างแก้วมังกรมากกว่า 1 ผล โดยหลังจากเก็บชุดข้อมูลแล้วมีการนำชุดข้อมูลให้นักพฤกษศาสตร์และเกษตรกรเจ้าของสวน เป็นผู้ตรวจสอบการกำกับป้าย (Label) อีกครั้งเพื่อความถูกต้องของการระบุชื่อสายพันธุ์ จำนวนภาพที่ได้ในแต่ละสายพันธุ์แสดงในตารางที่ 3.1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 จำนวนภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละสายพันธุ์

สายพันธุ์	จำนวน
พันธุ์ขาวจัมโบ้ (Jumbo White)	1,172
พันธุ์ขาวเวียดนาม (Vietnamese White)	1,190
พันธุ์ชมพูจินดา (Pink)	1,309
พันธุ์แดงสยาม (Siam Red)	1,869
พันธุ์แดงไต้หวัน (Taiwan Red)	1,184
พันธุ์แดงทับทิม (Ruby Red)	1,110
พันธุ์เหลืองอิสราเอล (Israel Yellow)	1,920
รวม	9,754

3.1.2.2 ชุดข้อมูลภาพในสภาวะแวดล้อมกลางแจ้ง

สำหรับการเก็บข้อมูลภาพแก้วมังกรในสภาวะแวดล้อมกลางแจ้ง (Outdoor) นั้น เพื่อสร้างสภาวะแวดล้อมให้ใกล้เคียงกับความเป็นจริงมากที่สุด เปรียบเสมือนเกษตรกรหรือนักท่องเที่ยวสามารถใช้กล้องของโทรศัพท์เคลื่อนที่ในการจำแนกสายพันธุ์แก้วมังกรที่ตนเองเห็นใน ณ ขณะใด ขณะหนึ่งซึ่งไม่สามารถระบุแน่ชัดได้ว่าจะเป็นช่วงเวลาใด สภาพแสงเท่าไร การตั้งค่าอัตราส่วนของภาพแบบใด ผู้วิจัยจึงใช้กล้องของโทรศัพท์เคลื่อนที่ในการบันทึกภาพด้วยอัตราส่วนของภาพแบบอิสระ ได้แก่ 3:4 และ 9:16 ซึ่งเป็นอัตราส่วนทั่วไปของกล้องบันทึกภาพที่ถูกติดตั้งบนโทรศัพท์เคลื่อนที่ ในสภาวะแสงและช่วงเวลาแบบอิสระเช่นกัน โดยภาพที่ได้เป็นภาพแก้วมังกรที่ผลยังอยู่บนต้น เจริญเติบโตถึงระยะพร้อมเก็บเกี่ยว แต่ละภาพมีแก้วมังกรหนึ่งผลหนึ่งสายพันธุ์ มีพื้นหลังที่ซับซ้อนขึ้น ไม่ว่าจะเป็นท้องฟ้า พื้นดิน พื้นหญ้า กิ่ง เป็นต้น ดังแสดงในรูปที่ 3.8 ภาพแต่ละภาพมีขนาดและจำนวนที่แตกต่างกันในแต่ละสายพันธุ์รายละเอียดแสดงในตารางที่ 3.2



รูปที่ 3.8 ตัวอย่างข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.2 จำนวนภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งของแต่ละสายพันธุ์

สายพันธุ์/ขนาด	ขนาด	จำนวน	รวม
พันธุ์ขาวจัมโบ้ (Jumbo White)	2,240X4,608	356	1,241
	3,000X4,000	303	
	3,456X4,608	258	
	3,120X4,160	125	
	2,448X3,264	108	
	4,608X3,456	39	
	4,608X2,240	23	
	3,264X2,448	10	
	4,160X3,120	5	
	1,932X2,576	4	
	4,000X3,000	4	
	1,440X1,080	3	
	960X719	1	
	810X1,080	1	
2,576X1,932	1		
พันธุ์ขาวเวียดนาม (Vietnamese White)	2,240X4,608	1,089	2,478
	2,128X4,608	474	
	3,456X4,608	469	
	1,504X3,264	139	
	4,608X3,456	106	
	960X1,280	64	
	3,120X4,160	61	
	3,000X4,000	22	
	3,264X1,504	19	
	1,188X2,576	12	
	4,608X2,240	11	
	4,160X3,120	8	
1,280X960	3		
3,072X4,096	1		
พันธุ์ชมพูจินดา (Pink)	960X1,280	641	1,013
	1,280X960	225	
	3,456X4,608	97	
	2,240X4,608	42	
	4,608X3,456	7	
1,440X1,080	1		

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

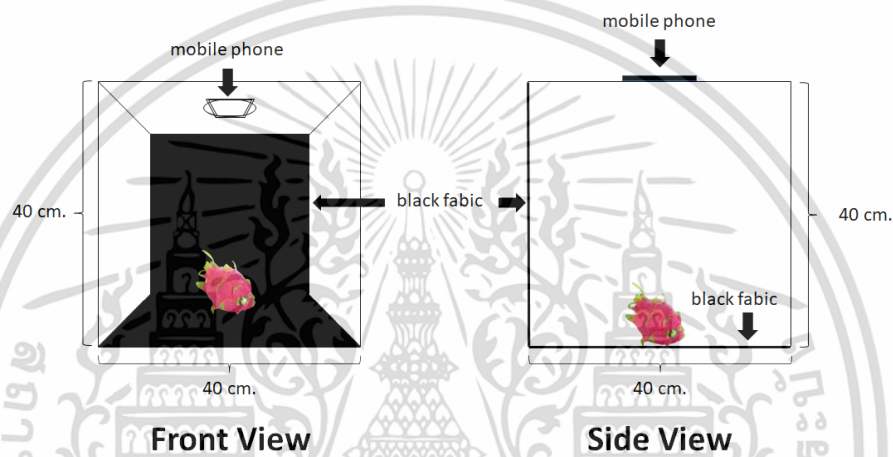
ตารางที่ 3.2 จำนวนภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งของแต่ละสายพันธุ์ (ต่อ)

สายพันธุ์/ขนาด	ขนาด	จำนวน	รวม
พันธุ์แดงสยาม (Siam Red)	960X1,280	518	950
	1,280X960	377	
	2,448X3,264	30	
	3,456X4,608	19	
	4,608X3,456	3	
	2,240X4,608	2	
	3,264X2,448	1	
พันธุ์แดงไต้หวัน (Taiwan Red)	1,280X960	363	1,021
	2,128X4,608	311	
	2,240X4,608	271	
	960X1,280	36	
	3,456X4,608	32	
	4,608X2,128	8	
พันธุ์แดงทับทิม (Ruby Red)	2,240X4,608	481	871
	3,456X3,456	140	
	4,608X3,456	87	
	1,920X1,920	60	
	1,108X1,478	43	
	2,448X3,264	32	
	3,456X4,608	23	
	4,608X2,240	4	
1,280X1,280	1		
พันธุ์เหลืองอิสราเอล (Israel Yellow)	960X1,280	1,127	1,493
	1,280X960	218	
	3,456X4,608	76	
	2,240X4,608	38	
	2,448X3,264	11	
	1,440X1,080	9	
	1,280X952	6	
	720X960	3	
	810X1,080	3	
	4,608X2,240	1	
960X720	1		
รวม			9,067

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


3.1.3 ชุดข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย

ชุดข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทยในการวิจัยครั้งนี้ เป็นชุดข้อมูลภาพที่บันทึกในห้องปฏิบัติการของแก้วมังกรสายพันธุ์ขาวจัมโบ้ (Jumbo White) โดยผู้วิจัยนำตัวอย่างแก้วมังกรสายพันธุ์ดังกล่าวที่มีอายุหลังเก็บเกี่ยวไม่เกิน 1 สัปดาห์ มาบันทึกภาพ อุปกรณ์ที่ใช้ในการเก็บข้อมูลภาพ ประกอบไปด้วย กล้องสตูดิโอแบบพกพาขนาด 40x40 เซนติเมตร ติดตั้งไฟแอลอีดี 1 แถวบริเวณขอบด้านบนของกล่อง มีการเจาะช่องวงกลมด้านบนของกล่อง ซึ่งกล่องสตูดิโอนี้ใช้สำหรับเป็นพื้นที่วางผลแก้วมังกรและจัดสภาพแสงสว่างในการบันทึกภาพ ผ้ากำมะหยี่สีดำใช้สำหรับเป็นพื้นหลัง โทรศัพท์เคลื่อนที่ที่ใช้สำหรับบันทึกภาพ ซึ่งจะวางบริเวณด้านบนของกล่องสตูดิโอ โดยให้เลนส์กล้องอยู่บริเวณช่องวงกลมที่ถูกเจาะไว้ด้านบนของกล่อง ดังรูปที่ 3.9



รูปที่ 3.9 ตัวอย่างวิธีเก็บข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย

หลังจากจัดเตรียมอุปกรณ์ที่ใช้ในการเก็บข้อมูลภาพเรียบร้อยแล้ว ผู้วิจัยบันทึกภาพแก้วมังกรด้วยกล้องของโทรศัพท์เคลื่อนที่ ซึ่งตั้งค่าขนาดภาพในอัตราส่วน 1:1 ปิดการทำงานของฟิลเตอร์ทั้งหมด และวางผลแก้วมังกรในกล่องสตูดิโอที่บุพื้นหลังด้วยผ้ากำมะหยี่สีดำ เปิดไฟแอลอีดีที่ถูกติดตั้งบริเวณขอบด้านบนของกล่องสตูดิโอ เพื่อเพิ่มแสงสว่าง ในขณะที่ถ่ายภาพเปิดใช้ฟังก์ชันเส้นแบ่งเก้าช่องเป็นตัวช่วยในการวางเลย์เอาต์ของภาพและตำแหน่งของผลแก้วมังกรให้อยู่ตรงกลางมากที่สุด ดังแสดงในรูปที่ 3.10 นอกจากนี้ผู้วิจัยใช้เทคนิคในการเก็บข้อมูลภาพจากการศึกษางานวิจัยของ Muresan and Oltean (2018) ด้วยการหมุนวัตถุให้ได้ 360 องศาเท่าที่เป็นไปได้ และ Osako. et al. (2020) การใช้พื้นหลังเป็นสีดำเพื่อดึงความโดดเด่นของผลไม่ออกมา ดังนั้นภาพที่ได้จึงมีลักษณะดังรูปที่ 3.11



รูปที่ 3.10 แสดงตัวอย่างการวางเลย์เอาต์ของภาพและตำแหน่งของผลแก้วมังกรของการเก็บ

ข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.11 ตัวอย่างข้อมูลภาพสำหรับพัฒนาอัลกอริทึมจำแนกคุณภาพของแก้วมังกรไทย

ภาพที่ได้มีขนาด 3,456x3,456 พิกเซล เพื่อความถูกต้องในการระบุขนาด แก้วมังกรแต่ละผล จะถูกชั่งน้ำหนักหน่วยเป็นกรัมก่อนบันทึกภาพ ดังนั้นภาพแต่ละภาพมีเพียงแก้วมังกรหนึ่งผลหนึ่งรหัส ขนาดแต่ละรหัสขนาดใช้ตัวอย่างแก้วมังกรมากกว่า 1 ผล โดยหลังจากเก็บชุดข้อมูลแล้วมีการนำชุดข้อมูลให้เกษตรกรเจ้าของสวน เป็นผู้กำกับป้าย (Label) เพื่อระบุชั้นคุณภาพของแก้วมังกรแต่ละภาพ จำนวนภาพที่ได้ในแต่ละขนาดและชั้นคุณภาพแสดงในตารางที่ 3.3 และ 3.4 ตามลำดับ

ตารางที่ 3.3 จำนวนภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละรหัสขนาด

รหัสขนาด	น้ำหนักต่อผล (กรัม)	จำนวน
1	>600	1,375
2	>500-600	708
3	>400-500	482
4	>300-400	622
5	>250-300	146
6	>200-250	223
รวม		3,556

ตารางที่ 3.4 จำนวนภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละชั้นคุณภาพ

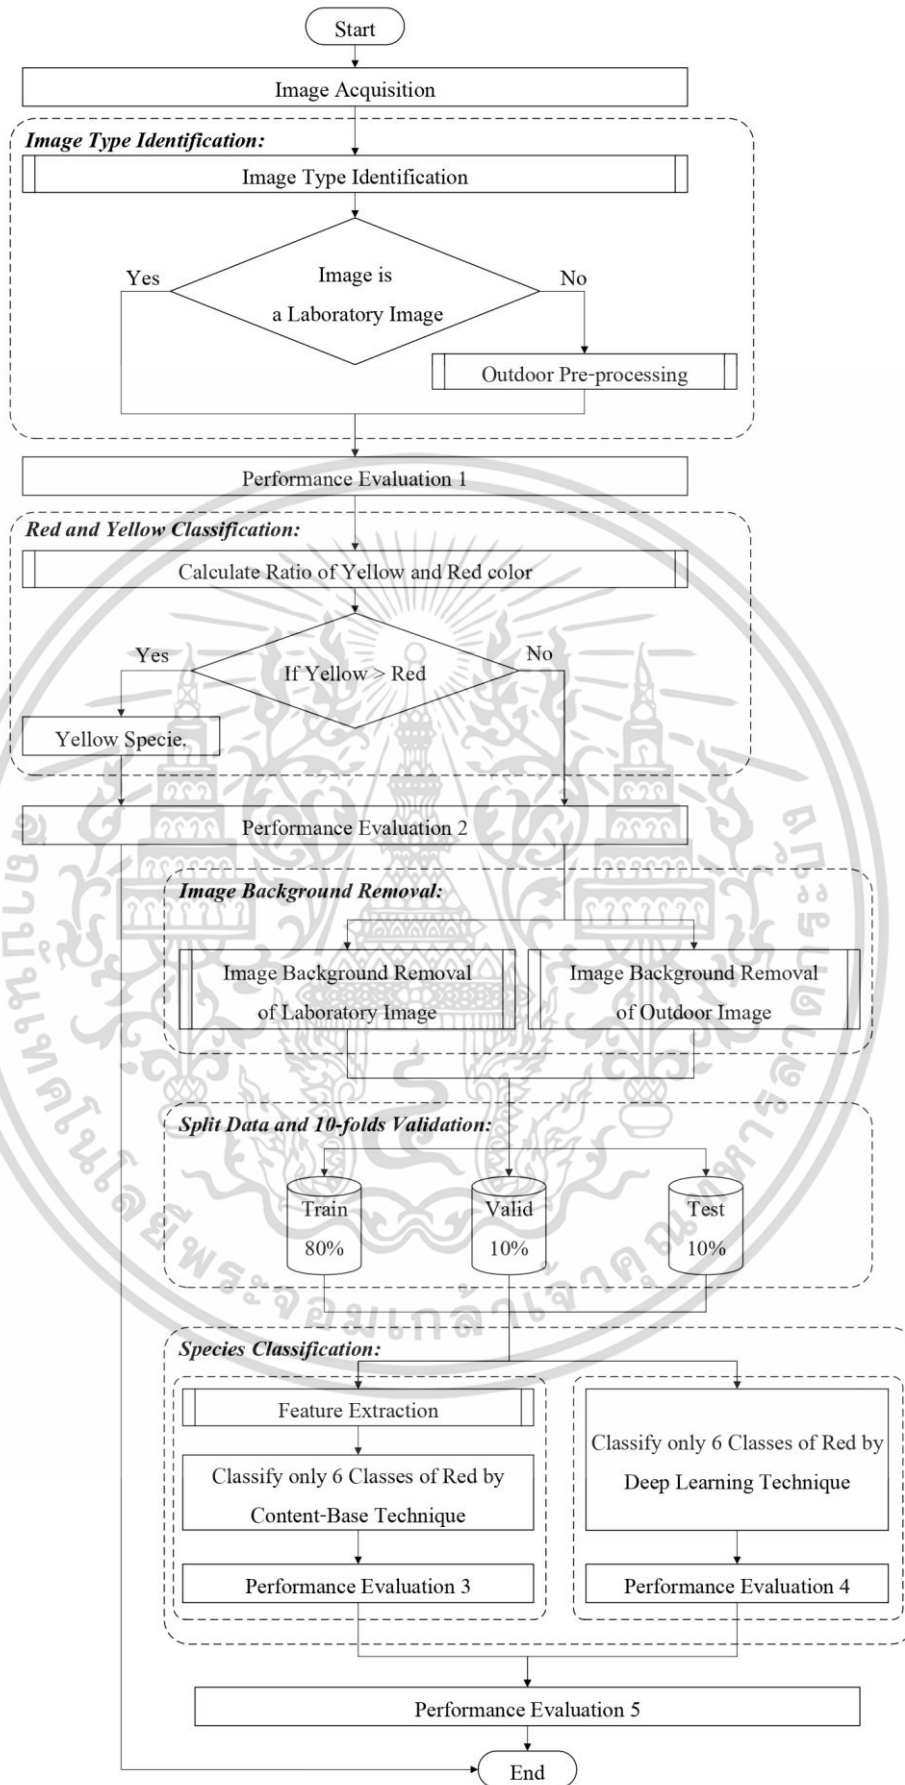
รหัสชั้นคุณภาพ	ชั้นคุณภาพ	จำนวน
C0	ชั้นพิเศษ (Extra class)	387
C1	ชั้นหนึ่ง (Class I)	513
C2	ชั้นสอง (Class II)	643
C3	ชั้นสาม (Class III)	2,013
รวม		3,556

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2 การพัฒนาอัลกอริทึมสำหรับจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ

จากการศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องในบทที่ 2 พบว่าการประมวลผลภาพด้วยการเรียนรู้ของเครื่อง (Machine Learning) ได้รับความนิยมนำมาใช้ในการสร้างโมเดลสำหรับการจำแนกภาพ ซึ่งสามารถแบ่งเทคนิคที่สร้างโมเดลได้เป็น 3 เทคนิค ได้แก่ 1) การสร้างกฎในการจำแนกภาพ (Rule-based) 2) เทคนิคการแยกคุณลักษณะตามเนื้อหา (Content based Technique) และ 3) การเรียนรู้เชิงลึก (Deep Learning) และจากการศึกษาลักษณะสัญญาณวิทยาของผลแก้วมังกรไทยทั้ง 7 สายพันธุ์พบว่า สายพันธุ์ที่มีความแตกต่างจากสายพันธุ์อื่นมากที่สุดคือสายพันธุ์เหลืองอิสราเอล เนื่องจากเป็นแก้วมังกรสายพันธุ์เดียวที่มีเปลือกสีเหลือง ส่วนแก้วมังกรอีก 6 สายพันธุ์ที่เหลือล้วนมีเปลือกสีแดงเช่นกันทั้งสิ้นจึงทำให้ลักษณะสัญญาณวิทยาค่อนข้างคลุมเครือ ดังนั้นในการวิจัยครั้งนี้ ผู้วิจัยจึงนำเทคนิคการสร้างโมเดลทั้ง 3 เทคนิคมาประยุกต์ใช้ในการวางแผนการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพที่สามารถประมวลผลได้ทั้งภาพที่ถูกบันทึกในห้องปฏิบัติการและภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ดังรูปที่ 3.12

จากรูปที่ 3.12 แสดงแผนการทดลองการจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพที่สามารถประมวลผลได้ทั้งภาพที่ถูกบันทึกในห้องปฏิบัติการและภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง หลังจากเก็บข้อมูลภาพตั้งรายละเอียดที่กล่าวไปแล้วในหัวข้อ 3.1.2 ผู้วิจัยนำข้อมูลภาพประมวลผลเพื่อระบุประเภทของภาพ (Image Type Identification) ประกอบไปด้วยภาพที่ถูกบันทึกในห้องปฏิบัติการ (Laboratory Image) และภาพในสภาวะแวดล้อมกลางแจ้ง (Outdoor Image) ด้วยเทคนิคการสร้างกฎ (Rule-based) หากพบว่าเป็นภาพในสภาวะแวดล้อมกลางแจ้งจะทำการเตรียมข้อมูลภาพเพื่อขจัดพิกเซลที่ไม่เกี่ยวข้องออกจากภาพก่อนนำเข้าสู่ขั้นตอนถัดไป ในทางตรงกันข้ามถ้าพบว่าเป็นภาพที่ถูกบันทึกในห้องปฏิบัติการจะนำข้อมูลภาพเข้าสู่ขั้นตอนถัดไปได้ทันทีเมื่อผ่านการระบุประเภทของภาพแล้ว ขั้นตอนถัดไปคือการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก (Red and Yellow Classification) ซึ่งเป็นการจำแนกกลุ่มแก้วมังกรออกเป็นสองกลุ่ม ได้แก่ กลุ่มเปลือกสีเหลือง (Yellow) และกลุ่มเปลือกสีแดง (Red) หากพบแก้วมังกรกลุ่มเปลือกสีเหลืองโมเดลจะสามารถทำนายสายพันธุ์แก้วมังกรได้ทันที นั่นคือสายพันธุ์เหลืองอิสราเอลและจบการทำงาน หากพบแก้วมังกรกลุ่มเปลือกสีแดงจะทำการลบพื้นหลังออกจากภาพ (Image Background Removal) ซึ่งภาพที่ถูกบันทึกในห้องปฏิบัติการ และภาพในสภาวะแวดล้อมกลางแจ้ง มีกระบวนการลบพื้นหลังออกจากภาพแตกต่างกัน โดยข้อมูลภาพหลังจากลบพื้นหลังเรียบร้อยแล้วจะถูกแบ่งข้อมูลด้วยเทคนิคการแบ่งข้อมูลแบบ 10-folds Validation โดยแต่ละ Fold ประกอบไปด้วยข้อมูลภาพ 3 ชุด ได้แก่ ชุดฝึกชุดทดสอบและชุดทดสอบ ในสัดส่วนร้อยละ 80 ร้อยละ 10 และร้อยละ 10 ของข้อมูลกลุ่มตัวอย่างทั้งหมด ชุดข้อมูลภาพทั้งหมดจะถูกนำไปทดสอบจำแนกสายพันธุ์แก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา (Content based Technique) และการเรียนรู้เชิงลึก (Deep Learning) ซึ่งจะถูกวัดประสิทธิภาพว่าเทคนิคใดมีประสิทธิภาพดีที่สุดสำหรับการจำแนกสายพันธุ์แก้วมังกรเฉพาะกลุ่มเปลือกสีแดงก่อนจบการทำงาน แต่ละขั้นตอนของการทดลองการจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ มีรายละเอียดดังนี้




รูปที่ 3.12 แผนการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ โดยสงวนสิทธิ์ในเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.1 การระบุประเภทของภาพ (Image Type Identification)

เนื่องจากชุดข้อมูลภาพที่ใช้ในการพัฒนาอัลกอริทึมสำหรับจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ มี 2 ประเภท ได้แก่ ภาพที่ถูกบันทึกในห้องปฏิบัติการ และภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง โดยชุดข้อมูลภาพทั้งสองประเภทมีลักษณะแตกต่างกัน ดังที่กล่าวไปแล้วในหัวข้อ 3.1.2 ซึ่งส่งผลให้การประมวลผลภาพของทั้งสองประเภทแตกต่างกันไปด้วย ดังนั้นในการดำเนินงานวิจัยครั้งนี้ จึงมีกระบวนการระบุประเภทของภาพเกิดขึ้น เพื่อให้การประมวลผลทั้งหมดถูกต้องตามลักษณะของภาพแต่ละประเภท โดยมีขั้นตอนแสดงดังรูปที่ 3.13



รูปที่ 3.13 ผังงานแสดงขั้นตอนการระบุประเภทของภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากลักษณะของภาพที่ถูกบันทึกในห้องปฏิบัติการเป็นภาพที่มีพื้นหลังเรียบไม่ซับซ้อน แตกต่างจากภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งที่มีพื้นหลังซับซ้อนมากกว่า ดังนั้นผู้วิจัยจึงมีการเตรียมข้อมูลภาพ (Pre-processing) เพื่อแบ่งส่วนพิกเซลพื้นหลังออกจากพิกเซลผลแก้วมังกร และใช้คุณสมบัติทางสถิติ ได้แก่ ค่าเฉลี่ย (Mean) ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) และความโด่ง (Kurtosis) ในการระบุประเภทของภาพ ข้อมูลที่ใช้ในการทดลองการระบุประเภทภาพเป็นชุดข้อมูลภาพที่ได้จากการสุ่มภาพประเภทละ 700 ภาพ (สายพันธุ์ละ 100 ภาพ) รวม 2 ประเภทเป็น 1,400 ภาพ นำมาศึกษาเพื่อหาขั้นตอนวิธีการเตรียมข้อมูลที่สามารถนำมาใช้ในการระบุประเภทของภาพได้


3.2.1.1 การเตรียมข้อมูลภาพ (Image Pre-processing)

การเตรียมข้อมูลภาพเป็นการแบ่งส่วนพิกเซลพื้นหลังออกจากพิกเซลผลแก้วมังกร ด้วยการแปลงภาพโมเดลสี RGB ให้เป็นภาพสองระดับที่สามารถนำมาใช้แยกส่วนพิกเซลทั้งสองส่วนออกจากกันได้ และด้วยลักษณะของภาพที่ถูกบันทึกในห้องปฏิบัติการและภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งที่มีพื้นหลังซับซ้อนแตกต่างกัน ดังนั้นผู้วิจัยจึงตั้งสมมติฐานว่าความแตกต่างของพิกเซลพื้นหลังของภาพทั้งสองประเภทส่งผลให้ค่าสถิติของพิกเซลพื้นหลังแตกต่างกันด้วย


ดังนั้นผู้วิจัยจึงใช้ชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการในการศึกษาขั้นตอนการเตรียมข้อมูลภาพ โดยผู้วิจัยนำภาพต้นฉบับมาลดขนาดลงตามสัดส่วนให้มีขนาดไม่เกิน 300x300 พิกเซล เพื่อลดเวลาในการประมวลผล และลดมิติของภาพจาก 3 ช่องสัญญาณเหลือเพียง 1 ช่องสัญญาณด้วยโมเดลสี RGB HSV และ Lab รวมถึงภาพระดับเทา (Gray Scale) ด้วย ดังรูปที่ 3.14 แล้วแปลงแต่ละช่องสัญญาณเป็นภาพสองระดับ (binary) ด้วยค่าเฉลี่ยของพิกเซล (Mean Threshold) ทั้งหมดของแต่ละช่องสัญญาณ ผลลัพธ์ที่ได้แสดงในรูปที่ 3.15

จากรูปที่ 3.15 ภาพสองระดับที่มีความใกล้เคียงกับภาพต้นฉบับมากที่สุดคือภาพสองระดับที่ได้จาก R channel ของโมเดล RGB หลังจากนั้นนำภาพสองระดับดังกล่าวมาขจัดพิกเซลเล็กๆที่ไม่ต้องการด้วย Morphological opening และลดขอบด้วย Erosion แล้วใช้ภาพผลลัพธ์ในการแบ่งส่วนพิกเซลพื้นหลังออกจากพิกเซลผลแก้วมังกร ดังแสดงในรูปที่ 3.16 โดยพิกเซลที่มีสีดำหมายถึงพื้นหลัง พิกเซลสีขาวหมายถึงผลแก้วมังกร

เมื่อนำขั้นตอนการแบ่งส่วนพื้นหลังกับผลแก้วมังกรในรูปที่ 3.16 ทดลองใช้กับภาพอื่นๆ ซึ่งมีบางภาพที่ส่วนของขี้แก้วมังกรหายไป ดังรูปที่ 3.17(a) ซึ่งผู้วิจัยเห็นว่าควรรักษาส่วนนี้เอาไว้ จึงเพิ่มการทำงานเพื่อเติมส่วนของขี้ที่หายไปด้วยการ Fill Hole ดังรูปที่ 3.17(b) ซึ่งได้ผลลัพธ์ดังรูปที่ 3.17(c) โดยอัลกอริทึมทั้งหมดที่ใช้ในการเตรียมข้อมูลภาพแสดงในรูปที่ 3.18 สำหรับขั้นตอนการคำนวณค่า mean threshold แสดงในรูปที่ 3.19 และเมื่อนำชุดข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งมาประมวลผลด้วยขั้นตอนการเตรียมข้อมูลที่น่าเสนอไปนั้น พบว่าได้ผลลัพธ์ที่แตกต่างกันดังรูปที่ 3.20 ซึ่งเป็นไปตามสมมติฐาน



รูปที่ 3.14 ตัวอย่างการแปลงภาพสีเป็นภาพระดับเทา 10 รูปแบบ

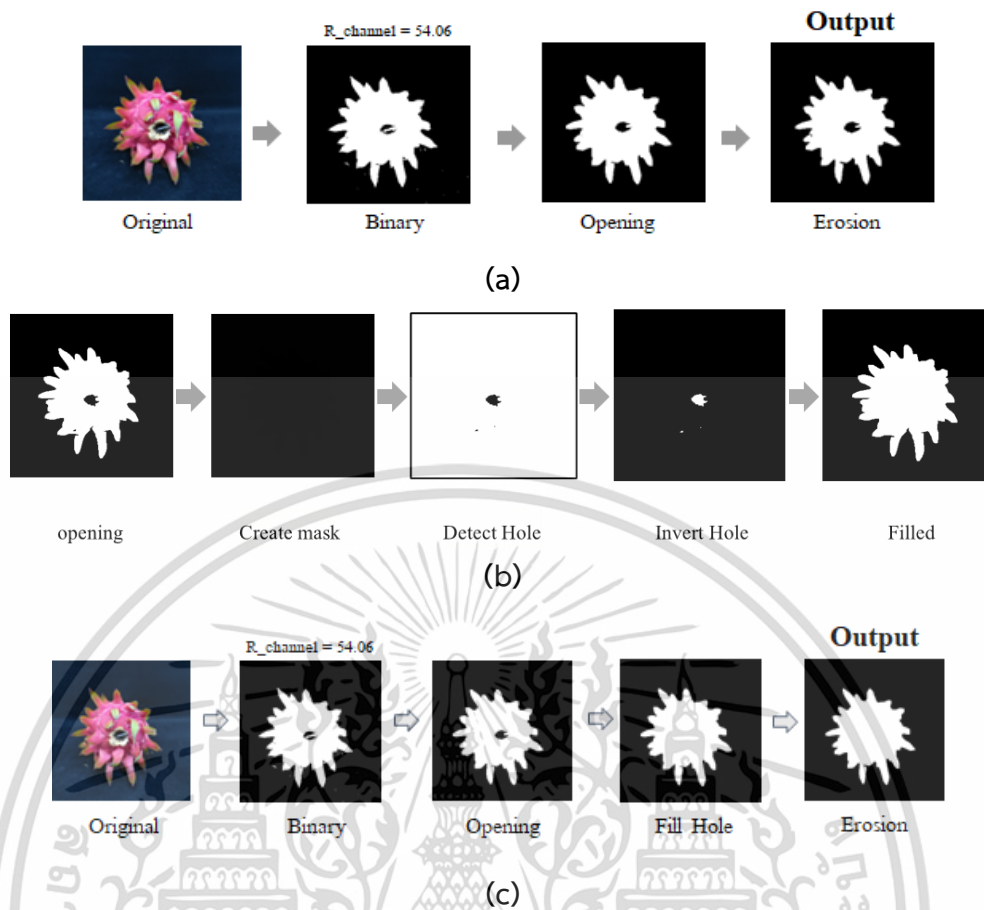


รูปที่ 3.15 การแปลงภาพระดับเทาเป็นภาพสองระดับด้วยค่าขีดแบ่ง mean threshold

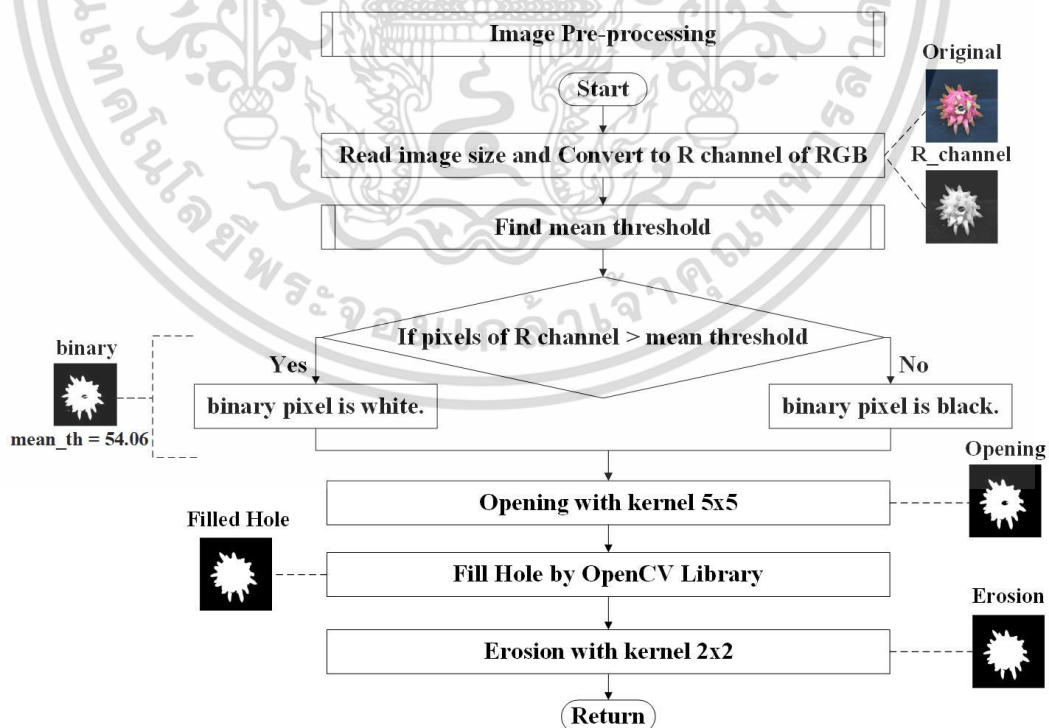


รูปที่ 3.16 ขั้นตอนการแบ่งส่วนพื้นที่หลังกับผลแก้วมังกร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.17 การปรับปรุงขั้นตอนการแบ่งส่วนพื้นหลังกับผลแก้วมึนกรด้วยการ Fill Hole




รูปที่ 3.18 ผังงานแสดงขั้นตอนการเตรียมข้อมูลภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



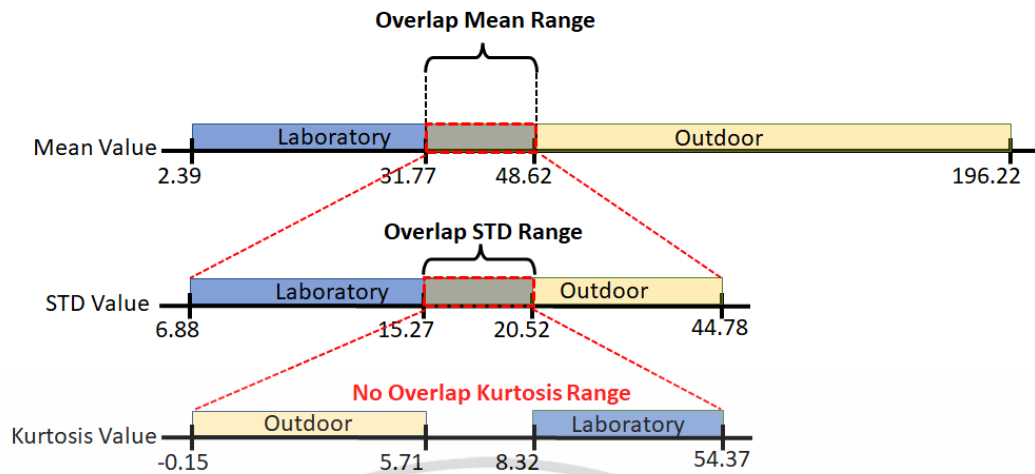
รูปที่ 3.19 ผังงานแสดงขั้นตอนการคำนวณค่า mean threshold



รูปที่ 3.20 ตัวอย่างผลลัพธ์ที่ได้จากการเตรียมข้อมูลภาพ

3.2.1.2 คุณสมบัติทางสถิติของภาพแต่ละประเภท

หลังจากกระบวนการเตรียมข้อมูลภาพ ผลลัพธ์ที่ได้จากการเตรียมข้อมูลเป็นภาพสองระดับที่มีพิกเซลสีดำเป็นพื้นหลัง (BG) ดังแสดงในแถวที่สองของรูปที่ 3.20 จากผลลัพธ์ที่ได้พบว่าภาพที่ถูกบันทึกในห้องปฏิบัติการมีค่าเฉลี่ยของพิกเซลพื้นหลังในระดับสีเทาตั้งแต่ 2.39 ถึง 48.62 และภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้งมีค่าเฉลี่ยของพิกเซลพื้นหลังในระดับสีเทาตั้งแต่ 31.77 ถึง 196.22 ปัญหาที่พบคือค่าเฉลี่ยของพิกเซลพื้นหลังในระดับสีเทาของภาพทั้งสองประเภทมีช่วงค่าเฉลี่ยที่ซ้อนทับกัน นั่นคือช่วง 31.77-48.62 และเมื่อพิจารณาสถิติอื่นของช่วงที่ซ้อนทับกัน พบว่าสถิติอื่นๆ เช่น ค่าฐานนิยม ค่ามัธยฐาน ส่วนเบี่ยงเบนมาตรฐาน และความเบ้ ยังคงซ้อนทับกันอยู่ ดังนั้นจึงเลือกศึกษาสถิติที่ซ้อนทับกันน้อยที่สุด นั่นคือ ส่วนเบี่ยงเบนมาตรฐาน จากช่วงค่าเฉลี่ยที่ซ้อนทับกันพบว่าภาพที่ถูกบันทึกในห้องปฏิบัติการมีความเบี่ยงเบนมาตรฐานของพิกเซลพื้นหลังในระดับสีเทาตั้งแต่ 6.88 ถึง 20.52 และภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้งตั้งแต่ 15.27 ถึง 44.78 ต่อมาที่ช่วงค่าเบี่ยงเบนมาตรฐานที่ซ้อนทับกัน พบว่าความโด่งของพิกเซลพื้นหลังในช่วงระดับสีเทาไม่ซ้อนทับกัน ภาพในห้องปฏิบัติการมีความโด่งของพิกเซลพื้นหลังในระดับสีเทาตั้งแต่ 0.15 ถึง 5.71 และภาพกลางแจ้งมีค่าตั้งแต่ 8.32 ถึง 54.37 ดังแสดงในรูปที่ 3.21



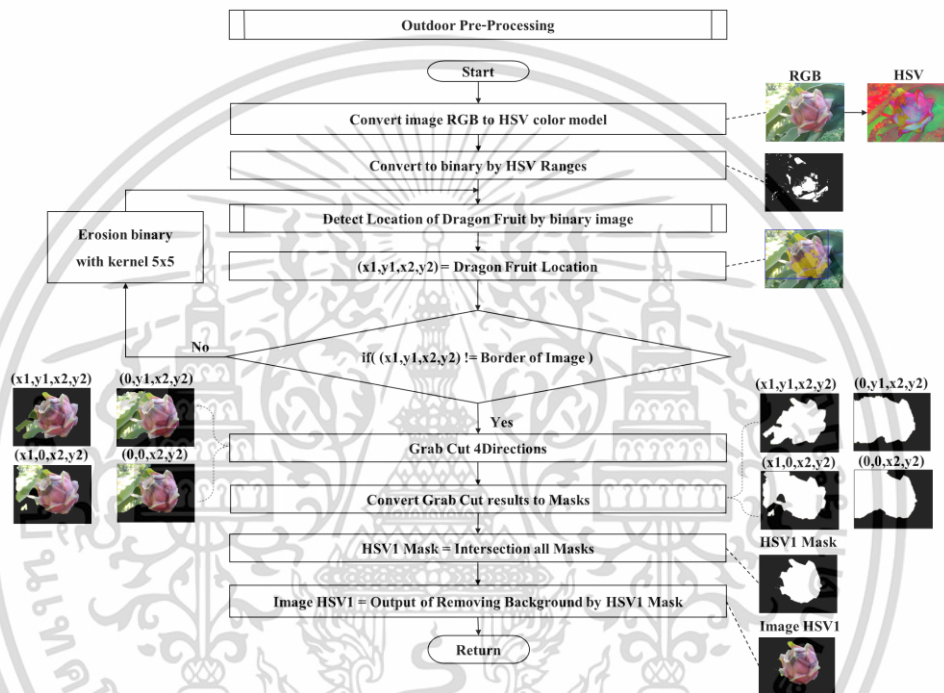
รูปที่ 3.21 แสดงคุณสมบัติทางสถิติของภาพแต่ละประเภท

ดังนั้นกระบวนการระบุประเภทของภาพจึงมีกระบวนการดังรูปที่ 3.13 เริ่มด้วยการปรับขนาดภาพต้นฉบับให้มีขนาดไม่เกิน 300x300 พิกเซล ตามสัดส่วน แทนข้อมูลช่องสัญญาณ R ของโมเดลสี RGB ด้วยภาพ R และแทนข้อมูลภาพระดับสีเทา (Gray Scale) ด้วยภาพ Gray หลังจากนั้นนำภาพ R ไปผ่านกระบวนการเตรียมข้อมูลตามขั้นตอนดังรูปที่ 3.18 และ 3.19 เพื่อแบ่งส่วนพิกเซลพื้นหลังออกจากพิกเซลผลแก้วมังกร กำหนดให้ผลลัพธ์ที่ได้จากการเตรียมข้อมูลแทนด้วยหน้ากาก MKR ซึ่งหน้ากาก MKR เป็นภาพสองระดับที่มีพิกเซลสีดำเป็นพื้นหลัง (BG) ดังแสดงในแถวที่สองของรูปที่ 3.20 ซึ่งถ้าภาพใดที่ไม่พบพิกเซลพื้นหลัง สรุปได้ว่าเป็นภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ในทางกลับกันให้คำนวณค่าเฉลี่ย (Mean: MP) ค่าเบี่ยงเบนมาตรฐาน (Standard Deviation: STD) และความโด่ง (Kurtosis: KS) ของพิกเซลพื้นหลัง (BG) จากภาพ Gray ที่พิกัดเดียวกันกับพิกเซลสีดำใน MKR


จากค่าสถิติทั้งสาม ให้พิจารณาค่าเฉลี่ยของพิกเซลพื้นหลังของภาพทั้งสองประเภท ซึ่งจากที่กล่าวไปแล้วว่าค่าเฉลี่ยของพิกเซลพื้นหลังของภาพทั้งสองประเภทมีช่วงที่ซ้อนทับกัน เพื่อให้ระบุประเภทของภาพได้อย่างชัดเจน ภาพที่มีค่าเฉลี่ยน้อยกว่า 31.77 คือภาพที่ถูกบันทึกในห้องปฏิบัติการ ภาพที่มีค่าเฉลี่ยมากกว่า 48.62 คือภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง หากรูปภาพใดอยู่ในช่วงค่าเฉลี่ยที่ซ้อนทับกัน นั่นคือค่าเฉลี่ยระหว่าง 31.77-48.62 ให้พิจารณาค่าเบี่ยงเบนมาตรฐานของพิกเซลพื้นหลังแทน หากค่าเบี่ยงเบนมาตรฐานของพิกเซลพื้นหลังน้อยกว่า 15.27 ภาพนั้นเป็นภาพที่ถูกบันทึกในห้องปฏิบัติการ หากค่าเบี่ยงเบนมาตรฐานของพิกเซลพื้นหลังมากกว่า 20.52 ภาพนั้นเป็นภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ในทำนองเดียวกัน ภาพใดๆที่มีค่าเบี่ยงเบนมาตรฐานที่ซ้อนทับกัน นั่นคือค่าเฉลี่ยระหว่าง 15.27-20.52 ให้พิจารณาค่าความโด่งของพิกเซลพื้นหลังแทน ภาพใดมีค่าความโด่งของพิกเซลพื้นหลังตั้งแต่ 8.32 ถึง 54.37 ภาพนั้นเป็นภาพที่ถูกบันทึกในห้องปฏิบัติการ ในทางกลับกัน ภาพนั้นเป็นภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง

3.2.2 การเตรียมข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง (Outdoor Pre-processing)

หลังจากนำข้อมูลภาพไปประมวลผลเพื่อระบุประเภทของภาพแล้ว หากพบว่าเป็นภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งจะทำการเตรียมข้อมูลภาพเพื่อลบพิกเซลที่ไม่เกี่ยวข้องออกจากภาพ ก่อนนำเข้าสู่ขั้นตอนถัดไป ซึ่งในขั้นตอนการเตรียมข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งนี้มีวัตถุประสงค์เพื่อแบ่งส่วน (Segmentation) พื้นหลัง (background) ออกจากผลแก้วมังกร ด้วยการสร้างหน้ากาก (Mask) ที่สามารถใช้ในการแบ่งส่วนทั้งสองส่วนออกจากกันได้ โดยมีขั้นตอนดังผังงานในรูปที่ 3.22 และ 3.23



รูปที่ 3.22 ผังงานของการเตรียมข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง



รูปที่ 3.23 ผังงานการตรวจจับตำแหน่งผลแก้วมังกร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผังงานในรูปที่ 3.22 เริ่มต้นด้วยการนำภาพต้นฉบับซึ่งเป็นภาพโมเดลสี RGB แปลงเป็นโมเดลสี HSV หลังจากนั้นแปลงภาพ HSV เป็นภาพสองระดับ (Binary Image) โดยใช้ค่า HSV Range เป็นค่าขีดแบ่ง (Threshold) ในการแปลงภาพ พิกเซลใดในภาพ HSV อยู่ในช่วงดังกล่าวจะถูกปรับเป็นพิกเซลขาวในทางตรงกันข้ามจะถูกปรับเป็นพิกเซลสีดำ

ค่า HSV Range นี้ ได้มาจากการสุ่มภาพแก้วมังกรที่ถูกเปลี่ยนพื้นหลังเป็นสีขาวเรียบร้อยแล้ว จำนวน 700 ภาพ (สายพันธุ์ละ 100 ภาพ) โดยภาพจะมีขนาด 100x100 พิกเซล และมีพื้นหลังสีขาว ดังรูปที่ 3.24 มาคำนวณหาช่วงของค่า Hue (H) โดยอ้างอิงจากโมเดลสี HSV ด้วย Algorithm 1 สำหรับแก้วมังกรเปลือกสีเหลือง ดังรูปที่ 3.25 และ Algorithm 2 สำหรับแก้วมังกรเปลือกสีแดง ดังรูปที่ 3.26 ซึ่งผลลัพธ์ที่ได้คือช่วงของค่า H ของแก้วมังกรเปลือกสีเหลืองมีค่าตั้งแต่ 23-37 ของโมเดลสี HSV ใน OpenCV และช่วงของค่า H ของแก้วมังกรเปลือกสีแดงมีค่าตั้งแต่ 0-23 และ 151-179 สำหรับค่า Saturation (S) และ Value (V) กำหนดให้ค่าตั้งแต่ 100-255



รูปที่ 3.24 ตัวอย่างข้อมูลภาพที่ใช้ในการหาช่วงค่า Hue สำหรับแก้วมังกรเปลือกสีเหลืองและสีแดง (HSV Range)

Algorithm 1: Find Hue Range of Yellow

Data: Input Image with v_channel and h_channel from HSV Model.

Result: min(hue_value), max(hue_value)

```

1: for each r ∈ rows of image do
2:   for each c ∈ columns of image do
3:     if v_channel[r,c] != 1 && h_channel[r,c] >=22.5 && h_channel[r,c] <=37.5 then
4:       /* yellow color range from the HSV color wheel is 45 to 75. */
5:       append h_channel[r,c] in h_val[]

```

รูปที่ 3.25 อัลกอริทึมหาช่วงค่า Hue สำหรับแก้วมังกรเปลือกสีเหลือง

Algorithm 2: Find Hue Range of Red

Data: Input Image with v_channel and h_channel from HSV Model.

Result: min(hue_value), max(hue_value)

```

1: for each r ∈ rows of image do
2:   for each c ∈ columns of image do
3:     if v_channel[r,c] != 1 && h_channel[r,c] >150 then
4:       /* red color range from the HSV color wheel is 300 to 360. */
5:       append h_channel[r,c] in h_val[]

```

รูปที่ 3.26 อัลกอริทึมหาช่วงค่า Hue สำหรับแก้วมังกรเปลือกสีแดง


เมื่อแปลงภาพ HSV เป็นภาพสองระดับโดยใช้ค่า HSV Range เรียบร้อยแล้ว นำภาพสองระดับที่ได้ไปประมวลผลเพื่อระบุตำแหน่ง (Location) ช่องผลแก้วมังกรด้วยโปรแกรมย่อย Detect ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Location of Dragon Fruit by binary image ซึ่งจะทำให้การแบ่งส่วนภาพสองระดับเป็น block จำนวนไม่เกิน 80×160 blocks โดยด้านที่สั้นกว่าจะถูกแบ่งเป็น 80 ส่วน และด้านที่ยาวกว่าจะถูกแบ่งเป็น 160 ส่วน หากหารไม่ลงตัวให้ปัดเศษขึ้น นั่นหมายความว่าถ้าภาพมีขนาดเท่ากับ $4,608 \times 2,240$ พิกเซล ขนาดของ block จะเท่ากับ 29×28 พิกเซล ดังนั้นภาพจะถูกแบ่งออกเป็นจำนวน 158×80 blocks ดังรูปที่ 3.23

block ใดมีจำนวนพิกเซลสีขาว (white pixel) มากกว่าหรือเท่ากับจำนวนพิกเซลสีดำ (black pixel) ให้กำหนดว่าเป็นส่วนของผลแก้วมังกร ตำแหน่งของ block ทั้งหมดที่เป็นส่วนหนึ่งของแก้วมังกรคือตำแหน่งของผลไม้ ถ้ารวม block ทั้งหมดเป็นสี่เหลี่ยมผืนผ้าเดียวกัน และกำหนดให้ x_1 เท่ากับค่าต่ำสุดของพิกัด x y_1 เท่ากับค่าต่ำสุดของพิกัด y x_2 เท่ากับค่าสูงสุดของพิกัด x และ y_2 เท่ากับค่าสูงสุดของพิกัด y พิกัด (x_1, y_1) คือมุมตะวันตกเฉียงเหนือของสี่เหลี่ยมผืนผ้า และพิกัด (x_2, y_2) คือมุมตะวันออกเฉียงใต้ของสี่เหลี่ยมผืนผ้า ดังนั้นพิกัด (x_1, y_1, x_2, y_2) นี้จะเป็นขอบเขตที่ใช้ในการแบ่งส่วนภาพด้วยวิธีแบบกราฟ (Graph Cut) ซึ่งจะต้องไม่เท่ากับขอบภาพ (Border of image) ก่อนนำไปใช้จึงนำพิกัด (x_1, y_1, x_2, y_2) ที่ได้ มาตรวจสอบว่าเป็นพิกัดเดียวกันกับขอบของภาพหรือไม่ หากเป็นตำแหน่งเดียวกันกับขอบภาพจะทำการลดขนาดขอบเขตลงด้วยการทำ Erosion ภาพสองระดับใหม่ กำหนดขนาด kernel เท่ากับ 5×5 แล้วนำภาพสองระดับนี้ไปประมวลผลเพื่อระบุตำแหน่งของผลแก้วมังกรอีกครั้งจนกว่าพิกัด (x_1, y_1, x_2, y_2) ที่ได้ไม่เท่ากับขอบของภาพ

หลังจากนั้นกำหนดให้พิกัด (x_1, y_1, x_2, y_2) เป็นขอบเขตของกรอบสี่เหลี่ยมที่จะใช้ในการแบ่งส่วนภาพพื้นหลังออกจากผลแก้วมังกรด้วยวิธีแบบกราฟ 4 แบบ (Graph Cut 4 Directions) ได้แก่ (x_1, y_1, x_2, y_2) $(0, y_1, x_2, y_2)$ $(x_1, 0, x_2, y_2)$ และ $(0, 0, x_2, y_2)$ นำผลลัพธ์ที่ได้จากการ Graph Cut 4 Directions ซึ่งเป็นภาพสี RGB มาแปลงเป็นหน้ากาก (Mask) ที่เป็นภาพสองระดับ โดยกำหนดให้ส่วนของผลแก้วมังกรเป็นพิกเซลสีขาว ส่วนของพื้นหลังเป็นสีดำ นำ Mask ทั้ง 4 มาหาพิกเซลสีขาวร่วมกัน ด้วยการ Intersection mask ผลลัพธ์ที่ได้คือหน้ากาก (Mask) ที่เป็นภาพสองระดับ แทนด้วย HSV1 Mask

หน้ากาก HSV1 Mask นี้ สามารถนำมาใช้แบ่งส่วนพื้นหลังออกจากผลแก้วมังกรได้ โดยพิกเซลสีดำหมายถึงพิกเซลพื้นหลัง พิกเซลสีขาวหมายถึงพิกเซลผลแก้วมังกร พิกัดใดในภาพสี RGB ที่มีพิกัดเดียวกันกับพิกเซลพื้นหลังจะถูกเปลี่ยนค่าพิกเซลพิกัดนั้นให้เท่ากับ 0 ผลลัพธ์ที่ได้จะเป็นภาพสี RGB ที่มีพื้นหลังบางส่วนหรือทั้งหมดเป็นสีดำ แทนด้วย Image HSV1 ตัวอย่างภาพที่ได้จากขั้นตอนนี้แสดงในรูปที่ 3.27

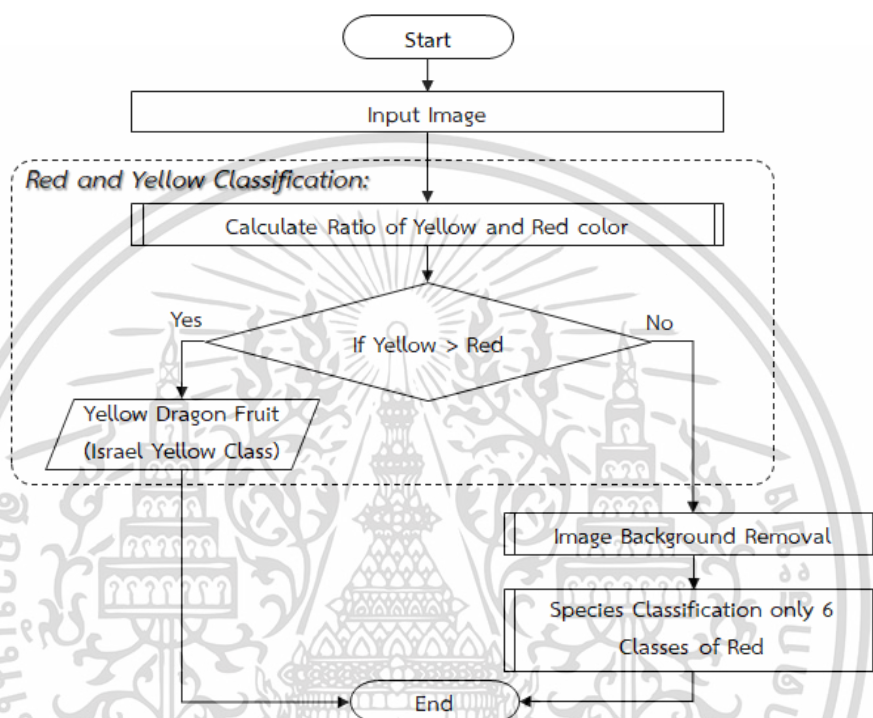


รูปที่ 3.27 ตัวอย่างผลลัพธ์ของการเตรียมข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง
(a) ภาพต้นฉบับ (b) ภาพ Image HSV1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.3 การจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก (Red and Yellow Classification)

ด้วยลักษณะสีเปลือกของผลแก้วมังกรไทยทั้ง 7 สายพันธุ์ สามารถแบ่งกลุ่มแก้วมังกรออกเป็น 2 กลุ่มตามสีของเปลือก ได้แก่ กลุ่มเปลือกสีเหลืองและกลุ่มเปลือกสีแดง ดังนั้นกระบวนการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกนั้นจะเป็นการคำนวณหาค่าร้อยละของสีเหลืองและสีแดงที่ปรากฏในภาพ หากค่าร้อยละของสีใดมากกว่าก็ถือว่าแก้วมังกรมีเปลือกสีนั้น ซึ่งสามารถใช้ระบุสีของเปลือกแก้วมังกรได้ โดยมีกระบวนการดังรูปที่ 3.28



รูปที่ 3.28 กฎการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก

เริ่มต้นด้วยการคำนวณค่าร้อยละของสีเหลืองและสีแดง (Calculate Ratio of Yellow and Red color) จากสีเปลือกของผลแก้วมังกร หากภาพใดมีค่าร้อยละของสีเหลือง (Yellow Ratio) มากกว่าค่าร้อยละของสีแดง (Red Ratio) นั้นหมายความว่าภาพนั้นคือภาพแก้วมังกรกลุ่มเปลือกสีเหลือง ซึ่งมีสายพันธุ์เดียวสามารถทำนายสายพันธุ์แก้วมังกรเป็นสายพันธุ์เหลืองอิสราเอลได้ทันทีและจบการทำงาน ในทางตรงกันข้ามหมายความว่าภาพนั้นคือภาพแก้วมังกรกลุ่มเปลือกสีแดง โมเดลจะทำการประมวลผลภาพต่อในขั้นตอนถัดไป กระบวนการนี้ช่วยลดจำนวนข้อมูลในการประมวลผลลงเหลือเพียงการประมวลผลกับแก้วมังกรกลุ่มเปลือกสีแดงเท่านั้น

ในการคำนวณค่าร้อยละของสีเหลืองและสีแดงจากสีเปลือกผลแก้วมังกรนั้น ผู้วิจัยใช้คุณลักษณะสีของโมเดลสี HSV ในการคำนวณตามผังงานในรูปที่ 3.29

โดยกำหนดให้ H = ช่องสัญญาณ Hue ของภาพ
 S = ช่องสัญญาณ Saturation ของภาพ
 V = ช่องสัญญาณ Value ของภาพ
 RC = จำนวนพิกเซลที่อยู่ในช่วงค่าสีแดง
 YC = จำนวนพิกเซลที่อยู่ในช่วงค่าสีเหลือง
 N = จำนวนพิกเซลทั้งหมด

จากรูปที่ 3.29 เริ่มต้นการประมวลผลด้วยการแปลงภาพสีโมเดล RGB ให้เป็นภาพสีโมเดล HSV ก่อน แล้วแปลงภาพอีกครั้งให้เป็นภาพสองระดับโดยใช้ค่า HSV Range ที่ได้จากการทดลองที่กล่าวไปแล้วในหัวข้อ 3.2.2 เป็นค่าขีดแบ่งในการแปลงภาพ ซึ่งพิกเซลใดมีค่า HSV อยู่ในช่วงที่กำหนดจะเปลี่ยนเป็นสีขาว ถ้าไม่อยู่ในช่วงจะเป็นสีดำ นั่นคือค่า H ตั้งแต่ 23-37 สำหรับเปลือกสีเหลือง ส่วนเปลือกสีแดงจะถูกแบ่งเป็นสองช่วงได้แก่ 0-23 และ 151-179 โดยแต่ละภาพจะถูกนับจำนวนพิกเซลที่อยู่ในช่วงของสีเหลืองและช่วงของสีแดง ผ่านตัวแปร YC และ RC ตามลำดับ


เมื่อนับจำนวนพิกเซลครบทุกพิกเซลแล้ว จะทำการคำนวณค่าร้อยละของสีเหลืองและสีแดง ด้วยสมการที่ 3.1 และ 3.2 ตามลำดับ

$$\text{Yellow Ratio} = \left(\frac{YC}{N} \right) * 100 \quad (3.1)$$

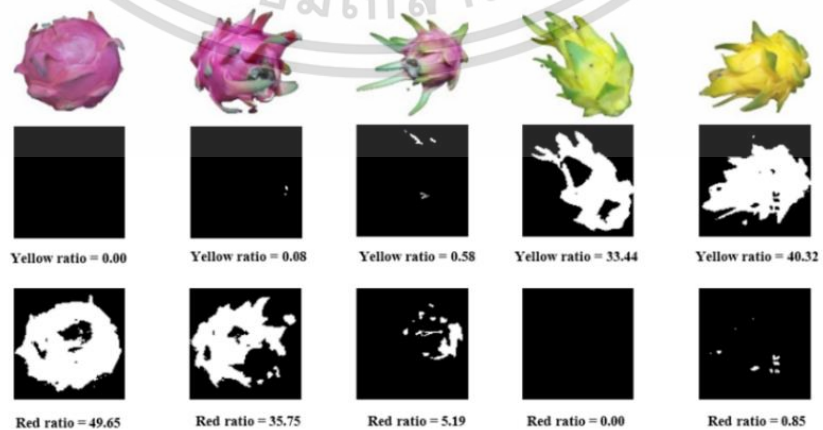
$$\text{Red Ratio} = \left(\frac{RC}{N} \right) * 100 \quad (3.2)$$

หากค่าร้อยละของสีใดมากกว่าก็ถือว่าแก้วม้งมีเปลือกสีนั้น ซึ่งค่า HSV Range ที่ใช้นั้นสามารถจำแนกกลุ่มแก้วม้งกรจากสีเปลือกได้ ดังตัวอย่างผลการทดลองในรูปที่ 3.30 แฉวแรกแสดงภาพแก้วม้งกรที่ถูกเปลี่ยนพื้นหลังเป็นสีขาวเรียบร้อยแล้ว แฉวที่สองแสดงภาพสองระดับที่ได้จากการใช้ช่วงค่า H ของสีเหลืองเป็นค่าขีดแบ่งและค่าร้อยละของสีเหลือง (Yellow Ratio) และแฉวที่สามแสดงภาพสองระดับที่ได้จากการใช้ช่วงค่า H ของสีแดงเป็นค่าขีดแบ่งและค่าร้อยละของสีแดง (Red Ratio) สังเกตได้ว่ากลุ่มแก้วม้งกรเปลือกสีแดงจะมีค่าร้อยละสีแดงมากกว่าสีเหลือง กลุ่มแก้วม้งกรเปลือกสีเหลืองจะมีค่าร้อยละของสีเหลืองมากกว่าสีแดง นั่นหมายความว่าสามารถใช้ค่าร้อยละของสีเหลืองและสีแดงในการสร้างกฎการจำแนกกลุ่มแก้วม้งกรด้วยสีเปลือกได้

จากแผนการทดลองในรูปที่ 3.12 จะเห็นว่าหากเป็นภาพที่ถูกบันทึกในห้องปฏิบัติการจะสามารถนำภาพต้นฉบับมาจำแนกกลุ่มแก้วม้งกรด้วยสีเปลือกได้โดยไม่ต้องเตรียมข้อมูลภาพ แตกต่างจากภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งที่ต้องผ่านการเตรียมข้อมูลภาพเพื่อลบพิกเซลที่ไม่เกี่ยวข้องออกจากภาพก่อน ถึงจะสามารถนำมาจำแนกกลุ่มแก้วม้งกรด้วยสีเปลือกได้ ดังตัวอย่างผลการทดลองในรูปที่ 3.31 ภาพที่ใช้ในการประมวลผลถ้าเป็นภาพที่ถูกบันทึกในห้องปฏิบัติการจะเป็นภาพต้นฉบับ ส่วนภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งจะเป็นภาพที่ถูกเตรียมข้อมูลมาแล้ว




รูปที่ 3.29 ผังงานการคำนวณค่าร้อยละของสีเหลืองและสีแดงจากสีเปลือกผลแก้วมังกร



รูปที่ 3.30 ตัวอย่างการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกจากภาพที่ถูกลบพื้นหลังแล้ว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)



(b)

รูปที่ 3.31 ตัวอย่างการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกด้วย (a) ภาพที่ถูกบันทึกในห้องปฏิบัติการและ (b) ภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง

3.2.4 การลบพื้นหลัง (Image Background Removal)

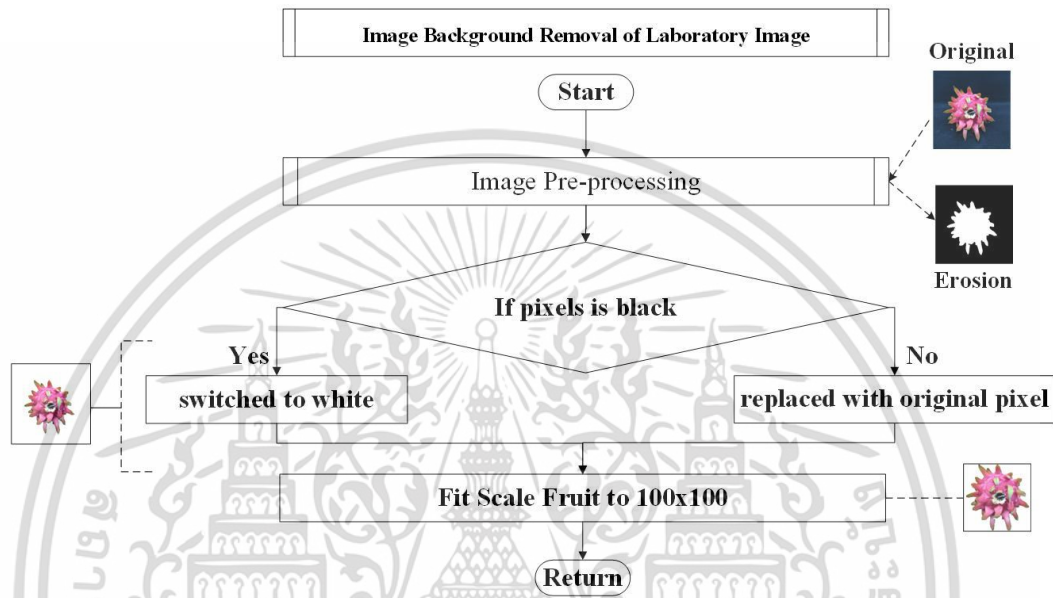
การลบพื้นหลังเป็นกระบวนการที่มีวัตถุประสงค์เพื่อเปลี่ยนพิกเซลพื้นหลังให้เป็นสีขาว ซึ่งชุดข้อมูลภาพจะเหลือเพียงชุดข้อมูลภาพของกลุ่มแก้วมังกรเปลือกสีแดงเท่านั้น เนื่องจากชุดข้อมูลภาพของกลุ่มแก้วมังกรเปลือกสีเหลืองถูกจำแนกกลุ่มออกไปแล้วในขั้นตอนก่อนหน้านี้ โดยกระบวนการลบพื้นหลังของภาพที่ถูกบันทึกในห้องปฏิบัติการและการลบพื้นหลังของภาพที่ถูกบันทึกในสภาวะ

แวดล้อมกลางแจ้งมีกระบวนการที่แตกต่างกัน โดยมีรายละเอียดดังนี้

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


3.2.4.1 การลบพื้นหลังของภาพที่ถูกบันทึกในห้องปฏิบัติการ

จากผลลัพธ์ของการเตรียมข้อมูลภาพ ดังแสดงในรูปที่ 3.20 พบว่ากระบวนการเตรียมข้อมูลภาพสามารถสร้างภาพสองระดับที่สามารถนำมาใช้แบ่งส่วนพิกเซลพื้นหลังออกจากพิกเซลของผลแก้วมังกรได้ โดยเฉพาะภาพที่ถูกบันทึกในห้องปฏิบัติการให้ผลลัพธ์ที่ดีกว่าภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ดังนั้นผู้วิจัยจึงใช้ผลลัพธ์ที่ได้จากกระบวนการเตรียมข้อมูลภาพมาใช้ในการลบพื้นหลังของภาพที่ถูกบันทึกในห้องปฏิบัติการ โดยมีกระบวนการดังผังงานในรูปที่ 3.32



รูปที่ 3.32 ผังงานแสดงขั้นตอนการลบพื้นหลังของข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการ

จากรูปที่ 3.32 หลังจากเตรียมข้อมูลภาพเรียบร้อยแล้ว นำผลลัพธ์ที่ได้มาใช้เป็นหน้ากาก (Mask) สำหรับการลบพื้นหลัง แทนด้วยหน้ากาก Erosion โดยพิกเซลใดในภาพต้นฉบับที่อยู่ตำแหน่งเดียวกันกับพิกเซลสีดำของหน้ากาก Erosion จะถูกเปลี่ยนเป็นพิกเซลสีขาว ในทางตรงกันข้ามให้คงข้อมูลพิกเซลของภาพต้นฉบับไว้เช่นเดิม และปรับขนาดเฉพาะส่วนผลแก้วมังกรให้เหลือขนาด 100x100 พิกเซล บนพื้นหลังสีขาวเช่นเดิม ดังแสดงในรูปที่ 3.33




รูปที่ 3.33 ตัวอย่างการปรับขนาดภาพเฉพาะส่วนผลแก้วมังกร

3.2.4.2 การลบพื้นหลังของภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง

จากรูปที่ 3.27 เป็นผลลัพธ์ที่ได้จากกระบวนการเตรียมข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง รายละเอียดดังหัวข้อ 3.2.2 พบว่ากระบวนการเตรียมข้อมูลภาพที่ถูกบันทึกในเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สภาวะแวดล้อมกลางแจ้งยังไม่สามารถลบพิกเซลพื้นหลังออกจากพิกเซลของผลแก้วมังกรได้ทั้งหมด ดังนั้นผู้วิจัยจึงใช้ผลลัพธ์ที่ได้จากกระบวนการเตรียมข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งนี้ มาใช้ในการลบพื้นหลังที่ยังคงเหลืออยู่ในภาพ โดยมีกระบวนการดังผังงานในรูปที่ 3.34



รูปที่ 3.34 ผังงานแสดงขั้นตอนการลบพื้นหลังของข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง

จากรูปที่ 3.34 ประกอบไปด้วยโปรแกรมย่อย 2 โปรแกรมย่อย ได้แก่ โปรแกรมย่อยการลบพื้นหลังที่คงเหลือด้วยโมเดลสี HSV (Remaining Background Removal by HSV Color Model) และ โปรแกรมย่อยการลบพื้นหลังด้วยโมเดลสี Lab (Background Removal by Lab Color Model) โดยทั้งสองโปรแกรมย่อยนี้จะให้ผลลัพธ์เป็นภาพสองระดับที่จะใช้ป็นหน้ากากในการลบพื้นหลังที่ยังคงเหลืออยู่ในภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ได้แก่ หน้ากาก HSV2 Mask และ A Mask

เมื่อนำหน้ากากทั้งสองมาหาพิกัดสีขาวร่วมกันด้วยการ Intersection mask ได้ผลลัพธ์เป็นภาพสองระดับเช่นเดิม แทนด้วยหน้ากาก HSVA Mask นำหน้ากาก HSVA Mask ไปปรับปรุงภาพด้วยการ Erosion (kernel=5x5) เพื่อลบพิกเซลที่ไม่เกี่ยวข้องและเติมส่วนด้วย Fill Hole function ของ OpenCV Library แล้วใช้หน้ากาก HSVA Mask เป็นหน้ากาก (mask) ในการลบพื้นหลังออกจากภาพ โดยพิกเซลสีดำหมายถึงพิกเซลพื้นหลัง พิกเซลสีขาวหมายถึงพิกเซลผลแก้วมังกร พิกัดใดในภาพสี RGB ต้นฉบับ ที่มีพิกัดเดียวกับกับพิกเซลพื้นหลังของหน้ากาก HSVA Mask จะถูกเปลี่ยนค่าพิกเซลพิกัดนั้นให้เท่ากับ 255 (สีขาว) ผลลัพธ์ที่ได้จะเป็นภาพผลแก้วมังกรที่มีพื้นหลังสีขาว และขั้นตอนสุดท้ายคือการปรับขนาดภาพเฉพาะส่วนผลแก้วมังกรให้มีขนาด 100x100 พิกเซล


1. โปรแกรมย่อยการลบพื้นหลังที่คงเหลือด้วยโมเดลสี HSV

โปรแกรมย่อยการลบพื้นหลังที่คงเหลือด้วยโมเดลสี HSV (Remaining Background Removal by HSV Color Model) เป็นกระบวนการลบส่วนพื้นหลังที่ยังคงเหลืออยู่ โดยข้อมูลนำเข้าเป็นภาพผลลัพธ์ที่ได้จากกระบวนการเตรียมข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง (Outdoor Pre-processing) ประกอบไปด้วย ภาพ Image HSV1 หน้ากาก HSV1 Mask และค่าพิกัด (x_1, y_1, x_2, y_2) ซึ่งข้อมูลเหล่านี้จะถูกนำไปเป็นค่าเริ่มต้นของการประมวลผลตามขั้นตอนในผังงานดังรูปที่ 3.35 โดยเริ่มจากการประมวลผลโปรแกรมย่อย Check Mask and Image ในผังงานดังรูปที่ 3.36 โดยมีการนำ Image HSV1 ไปคำนวณค่า Yellow Ratio ใหม่อีกครั้ง และ HSV1 Mask ไปตรวจจับตำแหน่งใหม่ แทนด้วยพิกัด (a_1, b_1, a_2, b_2) ด้วยโปรแกรมย่อย Detect Location of Dragon Fruit by binary image ในผังงานดังรูปที่ 3.23 นำพิกัด (a_1, b_1, a_2, b_2) ที่ได้ ไปลบพื้นหลังออกจากภาพด้วยวิธีการ 4 แบบ (Graph Cut 4 Directions) ผลลัพธ์ที่ได้คือภาพสองระดับ แทนด้วยหน้ากาก RM Mask


กรณีภาพที่ถูกลบพื้นหลังออกหมดแล้ว จะมีค่า Yellow Ratio ของ Image HSV1 เท่ากับ 0 โดยที่ ตำแหน่งใหม่ (a_1, b_1, a_2, b_2) จะต้องไม่เท่ากับตำแหน่งเดิม (x_1, y_1, x_2, y_2) แต่หากไม่เป็นไปตามเงื่อนไขดังกล่าว หน้ากาก RM Mask จะถูกนำไปเป็น Mask ในการลบพื้นหลังออกจากภาพต้นฉบับอีกครั้ง โดยพิกเซลสีดำหมายถึงพิกเซลพื้นหลัง พิกเซลสีขาวหมายถึงพิกเซลผลแก้วมังกร พิกัดใดในภาพสี RGB ที่มีพิกัดเดียวกันกับพิกเซลพื้นหลังจะถูกเปลี่ยนค่าพิกเซลพิกัดนั้นให้เท่ากับ 0 ผลลัพธ์ที่ได้จะเป็นภาพสี RGB แทนด้วย Image HSV2 หลังจากนั้นคำนวณค่า Yellow Ratio ของ Image HSV2 พร้อมทั้งเพิ่มค่าตัวแปร NR ด้วย 1 เพื่อใช้นับจำนวนครั้งในการลบพื้นหลัง ซึ่งจะไม่ให้มีการลบพื้นหลังซ้ำเกิน 3 ครั้ง

หลังจากนั้นตรวจสอบค่า Yellow Ratio ของ Image HSV2 หากมีค่าเท่ากับ 0 และพิกัด (a_1, b_1, a_2, b_2) ไม่เท่ากับพิกัดเดิม (x_1, y_1, x_2, y_2) จะกำหนดให้หน้ากาก HSV2 Mask มีค่าเท่ากับหน้ากาก RM Mask และจบการทำงานของโปรแกรมย่อยทันที เนื่องจากถือว่าพื้นหลังถูกลบออกหมดแล้ว แต่หากไม่เป็นไปตามเงื่อนไขจะทำการลบพื้นหลังต่อโดยใช้หน้ากาก RM Mask เป็นข้อมูลเริ่มต้นในการลบพื้นหลังซ้ำในครั้งต่อไป ด้วยการใช้หน้ากาก RM Mask สร้างข้อมูลนำเข้าชุดใหม่ขึ้นมา ได้แก่ การระบุพิกัด (x_1, y_1, x_2, y_2) ใหม่ ด้วยโปรแกรมย่อย Detect Location of Dragon Fruit by binary image สร้างหน้ากาก HSV1 Mask ใหม่ ด้วยวิธีแบบกราฟ 4 แบบ (Graph Cut 4 Directions) โดยใช้พิกัด (x_1, y_1, x_2, y_2) ใหม่ และสร้าง Image HSV1 ด้วย HSV1 Mask ใหม่

หลังจากนั้นนำหน้ากาก HSV1 Mask และ Image HSV1 ชุดใหม่ไปประมวลผลด้วยโปรแกรมย่อย Check Mask and Image อีกครั้ง เพื่อคำนวณค่า Yellow Ratio ระบุพิกัด (a_1, b_1, a_2, b_2) และสร้างหน้ากาก RM Mask ใหม่อีกครั้ง ซึ่งหน้ากาก RM Mask ใหม่นี้จะถูกนำไปใช้สร้างภาพ Image HSV2 และคำนวณ Yellow Ratio ของภาพ Image HSV2 ใหม่ พร้อมทั้งเพิ่มค่าตัวแปร NR ด้วย 1 เช่นเดิมภาพที่ถูกลบพื้นหลังออกหมดแล้วจะมีค่า Yellow Ratio เท่ากับ 0 โดยที่พิกัด (a_1, b_1, a_2, b_2) ไม่เท่ากับพิกัด (x_1, y_1, x_2, y_2) หากเป็นไปตามเงื่อนไขจะหยุดการลบส่วนพื้นหลัง กำหนดให้หน้ากาก HSV2 Mask เท่ากับหน้ากาก RM Mask ในทางตรงกันข้ามจะทำการลบพื้นหลังวนซ้ำเช่นเดิมแต่ไม่เกิน 3 รอบ เนื่องจากอาจลบพื้นหลังออกมากเกินไปจนทำให้ส่วนผลแก้วมังกรถูกลบออกไปด้วย ผลลัพธ์ที่ได้จากขั้นตอนนี้แสดงดังรูปที่ 3.38(b)



รูปที่ 3.35 ผังงานโปรแกรมย่อยการลบพื้นหลังที่คงเหลือด้วยโมเดลสี HSV

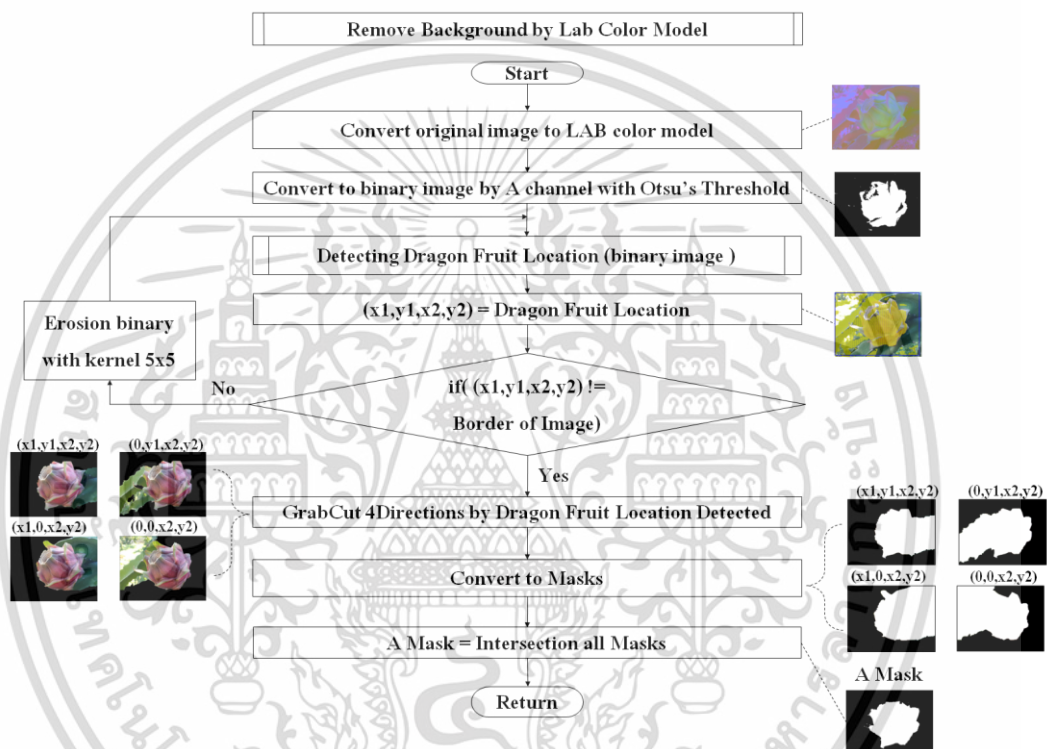


รูปที่ 3.36 ผังงานโปรแกรมย่อย Check Mask and Image

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


2. โปรแกรมย่อยการลบพื้นหลังด้วยโมเดลสี Lab

โปรแกรมย่อยการลบพื้นหลังด้วยโมเดลสี Lab (Background Removal by Lab Color Model) มีขั้นตอนประมวลผลดังผังงานรูปที่ 3.37 โดยเริ่มต้นด้วยการนำภาพต้นฉบับของภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้ง ซึ่งเป็นภาพโมเดลสี RGB แปลงเป็นโมเดลสี Lab หลังจากนั้นแยกช่องสัญญาณ a channel ออกมาแปลงเป็นภาพสองระดับโดยใช้ Otsu' Threshold แล้วนำภาพสองระดับที่ได้ไปประมวลผลเพื่อระบุตำแหน่งของผลแก้วมังกรด้วยโปรแกรมย่อย Detect Location of Dragon Fruit by binary image ในผังงานดังรูปที่ 3.23 ให้ผลลัพธ์เป็นพิกัด (x_1, y_1, x_2, y_2)



รูปที่ 3.37 ผังงานโปรแกรมย่อยการลบพื้นหลังด้วยโมเดลสี Lab

นำพิกัด (x_1, y_1, x_2, y_2) ที่ได้ มาตรวจสอบว่าเป็นพิกัดเดียวกับขอบของภาพหรือไม่ ในกรณีที่ พิกัด (x_1, y_1, x_2, y_2) เป็นพิกัดเดียวกันกับขอบภาพ จะทำการ Erosion ภาพสองระดับใหม่ด้วย kernel = 5x5 เพื่อลดขนาดขอบเขตก่อนอ่านตำแหน่งใหม่อีกครั้ง จนกว่าพิกัด (x_1, y_1, x_2, y_2) ที่ได้ไม่เท่ากับขอบของภาพ หลังจากนั้นกำหนดให้พิกัด (x_1, y_1, x_2, y_2) เป็นพิกัดของกรอบสี่เหลี่ยมที่จะใช้ในการจัดพื้นหลังออกจากภาพด้วยวิธีแบบกราฟ 4 แบบ (Graph Cut 4 Directions) ได้แก่ (x_1, y_1, x_2, y_2) $(0, y_1, x_2, y_2)$ $(x_1, 0, x_2, y_2)$ และ $(0, 0, x_2, y_2)$ นำผลลัพธ์ที่ได้จากการ Graph Cut 4 Directions มาแปลงเป็น Mask กำหนดให้ส่วนของผลแก้วมังกรเป็นพิกเซลสีขาว ส่วนของพื้นหลังเป็นสีดำ นำ Mask ทั้ง 4 มาหาพิกเซลสีขาวร่วมกัน (Intersection mask) ผลลัพธ์ที่ได้คือภาพสองระดับ แทนด้วยหน้ากาก A Mask สามารถนำมาใช้ลบพื้นหลังออกจากภาพได้ ผลลัพธ์ที่ได้จากโปรแกรมย่อยนี้แสดงดังรูปที่ 3.38 (c)



รูปที่ 3.38 ตัวอย่างภาพผลลัพธ์ของกระบวนการลบพื้นหลัง (a) ภาพนำเข้า HSV1 (b) ภาพ HSV2 Mask เป็นภาพผลลัพธ์ที่ได้จากโปรแกรมย่อยการลบพื้นหลังที่คงเหลือด้วยโมเดลสี HSV (c) ภาพ A Mask เป็นภาพผลลัพธ์ที่ได้จากโปรแกรมย่อยการลบพื้นหลังด้วยโมเดลสี Lab (d) ภาพ HSV4 Mask เป็นภาพผลลัพธ์ที่ได้จากการ intersection A Mask กับ HSV2 Mask (e) ภาพผลลัพธ์ที่ได้จากลบพื้นหลังออกจากภาพด้วย HSV4 Mask และ (f) ภาพผลลัพธ์ที่ได้จากการปรับขนาดเฉพาะส่วนผลแก้วมังกรให้มีขนาดไม่เกิน 100x100 พิกเซล

3.2.5 การแบ่งข้อมูลเพื่อใช้ในการทดลองด้วยเทคนิค 10-folds Validation

จากรูปที่ 3.12 เมื่อชุดข้อมูลผ่านกระบวนการลบพื้นหลังและปรับขนาดภาพเฉพาะส่วนผลแก้วมังกรตามสัดส่วนให้มีขนาดไม่เกิน 100x100 พิกเซลเรียบร้อยแล้ว ข้อมูลจะสุ่มตัวอย่างจากชุดข้อมูลภาพทั้งสองประเภทเฉพาะชุดข้อมูลภาพแก้วมังกรกลุ่มเปลือกสีแดง คลาสละ 1,000 ภาพ คลาสใดมีจำนวนน้อยกว่าให้ทำการเพิ่มข้อมูลภาพด้วยเทคนิคการ Augmentation ในที่นี้ผู้วิจัยเลือกใช้ Horizontal Flip Image วิธีเดียวเนื่องจากข้อมูลที่ต้องการเพิ่มให้ครบตามจำนวนที่ต้องการมีเพียงเล็กน้อย ดังนั้นจะมีข้อมูลที่ใช้ในการทดลองจากการสุ่มภาพที่ถูกบันทึกในห้องปฏิบัติการ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จำนวน 6,000 ภาพ และจากการสุ่มภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งจำนวน 6,000 ภาพ รวม 12,000 ภาพ ข้อมูลภาพที่สุ่มได้จะถูกแบ่งข้อมูลด้วยเทคนิคการแบ่งข้อมูลแบบ 10-folds Validation โดยแต่ละ Fold ประกอบไปด้วยข้อมูลภาพ 3 ชุด ได้แก่ ชุดฝึกหัด ชุดทดลองและชุดทดสอบ ในสัดส่วนร้อยละ 80 ร้อยละ 10 และร้อยละ 10 ของข้อมูลกลุ่มตัวอย่างที่สุ่มมาทั้งหมด

จากที่กล่าวไปแล้วข้างต้นว่าในการดำเนินงานวิจัยครั้งนี้ต้องการสร้างโมเดลที่สนับสนุนการจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพที่สามารถประมวลผลได้ทั้งภาพที่ถูกบันทึกในห้องปฏิบัติการและภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ดังนั้นผู้วิจัยจึงจัดรูปแบบชุดข้อมูลที่ใช้ในการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพเป็น 4 รูปแบบ ดังตารางที่ 3.5

ตารางที่ 3.5 ชุดข้อมูลที่ใช้ในการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ

ชื่อชุดข้อมูล	รายละเอียด	จำนวน (ภาพ)
Laboratory	ภาพที่ถูกบันทึกในห้องปฏิบัติการที่ผ่านการเตรียมข้อมูล Image Pre-processing ตามกระบวนการในหัวข้อที่ 3.2.1.1 และลบพื้นหลังออกจากภาพโดยใช้กระบวนการในหัวข้อ 3.2.4.1	6,000
Outdoor	ภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งที่ผ่านการเตรียมข้อมูล Outdoor Pre-processing ตามกระบวนการในหัวข้อที่ 3.2.2 และลบพื้นหลังออกจากภาพโดยใช้กระบวนการในหัวข้อ 3.2.4.2	6,000
Mixdata1	รวมชุดข้อมูล Laboratory และ Outdoor	12,000
Mixdata2	รวมชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการและภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งที่ผ่านการเตรียมข้อมูล Outdoor Pre-processing ตามกระบวนการในหัวข้อที่ 3.2.2 และลบพื้นหลังออกจากภาพโดยใช้กระบวนการในหัวข้อ 3.2.4.2	12,000

3.2.6 การจำแนกสายพันธุ์ของแก้วมังกร

หลังจากเตรียมชุดข้อมูลภาพเพื่อใช้ในการทดลองแล้ว ชุดข้อมูลทั้งหมดจะถูกนำไปทดสอบจำแนกสายพันธุ์แก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา (Content based Technique) และการเรียนรู้เชิงลึก (Deep Learning) ซึ่งจะถูกวัดประสิทธิภาพว่าเทคนิคใดมีประสิทธิภาพดีที่สุด สำหรับการทดสอบจำแนกสายพันธุ์แก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา มีกระบวนการแยกคุณลักษณะ โดยมีรายละเอียดดังนี้

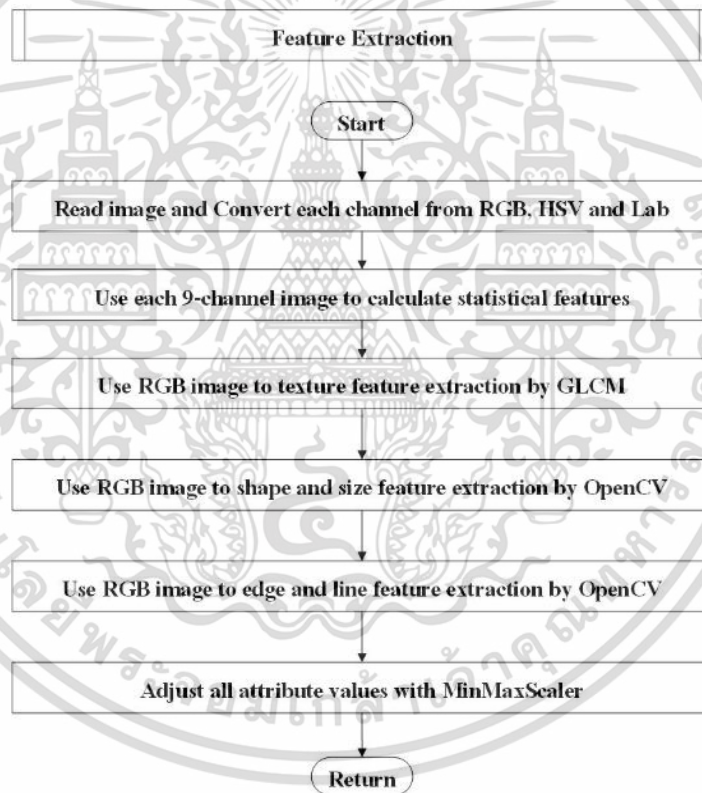
3.2.6.1 การแยกคุณลักษณะสำหรับการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ

การแยกคุณลักษณะเป็นขั้นตอนดึงลักษณะที่สำคัญของวัตถุออกมา ซึ่งคุณลักษณะเหล่านี้จะเป็นข้อมูลนำเข้าของกระบวนการจำแนกสายพันธุ์แก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหาในลำดับต่อไป ดังนั้นกระบวนการนี้ถือเป็นกระบวนการที่สำคัญอย่างยิ่ง หากนักวิจัยสามารถแยกคุณลักษณะได้อย่างมีคุณภาพจะส่งผลต่อประสิทธิภาพของการจำแนกสายพันธุ์ของแก้วมังกรไปด้วย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในงานวิจัยนี้มุ่งเน้นพัฒนาอัลกอริทึมสำหรับการจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ ซึ่งแต่ละสายพันธุ์หากมองด้วยตาเปล่าจะมีลักษณะแตกต่างกัน ตัวอย่างเช่น แก้วมังกรพันธุ์เหลืองอิสราเอลมีเปลือกสีเหลืองซึ่งแตกต่างจากแก้วมังกรสายพันธุ์อื่น นั่นหมายความว่า สามารถใช้คุณลักษณะสีเปลือกในการจำแนกกลุ่มแก้วมังกรที่มีเปลือกสีเหลืองและสีแดงได้ หากอัลกอริทึมสำหรับการจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพสามารถจำแนกกลุ่มแก้วมังกรที่มีเปลือกสีเหลืองได้ จะนำไปสู่การทำนายผลการจำแนกของแก้วมังกรพันธุ์เหลืองอิสราเอลได้ทันที เนื่องจากชุดข้อมูลที่ใช้ในการวิจัยครั้งนี้มีแก้วมังกรสายพันธุ์เดียวที่มีเปลือกสีเหลือง หรือแม้กระทั่งการเรียงชั้นของกลีบที่ส่งผลต่อพื้นผิวที่แตกต่างกันของเปลือกแก้วมังกรแต่ละสายพันธุ์ นอกจากนี้ยังมีคุณลักษณะรูปร่าง ขนาด ขอบและเส้น เป็นคุณลักษณะที่น่าสนใจนำมาใช้ในการแยกคุณลักษณะ เป็นต้น

ดังนั้นในงานวิจัยนี้จึงออกแบบให้มีการแยกคุณสมบัติทางสถิติของคุณลักษณะสี พื้นผิว รูปร่างขนาด ขอบและเส้น ดังรูปที่ 3.39 ซึ่งคาดว่าจะมีผลต่อประสิทธิภาพของการสายพันธุ์ของแก้วมังกร โดยมีรายละเอียดและขั้นตอนในการแยกคุณลักษณะในแต่ละคุณลักษณะดังนี้



รูปที่ 3.39 ผังงานการแยกคุณลักษณะสำหรับการทดลองจำแนกสายพันธุ์ของแก้วมังกรไทยจากภาพ

1. คุณลักษณะสี (Color feature)

คุณลักษณะสีที่ใช้ในงานวิจัยนี้ ประกอบไปด้วยคุณลักษณะสีของโมเดลสี RGB HSV และ Lab แต่ด้วยข้อมูลภาพที่ได้นั้นอยู่ในรูปแบบโมเดลสี RGB ซึ่งเป็นโมเดลสีที่ได้จากการบันทึกภาพผ่านกล้องของโทรศัพท์เคลื่อนที่ ดังนั้นในแยกคุณลักษณะสีจะต้องมีการแปลงระบบโมเดลสีจากโมเดลสี RGB เป็นโมเดลสี HSV และ LAB ดังสมการที่ 2.1-2.11 ในบทที่ 2 แล้วนำเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลภาพทั้ง 3 โมเดลมาแยกช่องสัญญาณจาก 3 มิติให้เหลือ 1 มิติ นั่นคือจากภาพทั้ง 3 โมเดลสี จะ ได้ข้อมูลภาพ Red (R), Green (G), Blue (B) จากโมเดลสี RGB ข้อมูลภาพ Hue (H), Saturation (S), Value (V) จากโมเดลสี HSV และข้อมูลภาพ Lightness(L), Red/Green Value (a), Blue/Yellow Value (b) จากโมเดลสี LAB รวม 9 ภาพ แล้วนำข้อมูลพิกเซลของแต่ละภาพมา คำนวณค่าเฉลี่ย (Mean), ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความเบ้ (Skewness) และความโด่ง (Kurtosis) ดังสมการที่ 3.3-3.6 (ปังกกร, 2564) รวมคุณลักษณะสีที่แยกได้ทั้งหมด เท่ากับ 36 คุณลักษณะ สามารถสรุปเป็นขั้นตอนได้ดังรูปที่ 3.40


$$\text{Mean} = \frac{1}{N} \sum_{i=0}^{N-1} P_i \quad (3.3)$$

$$\text{Standard Deviation} = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} (P_i - \text{Mean})^2} \quad (3.4)$$

$$\text{Skewness} = \frac{\frac{1}{N} \sum_{i=0}^{N-1} (P_i - \text{Mean})^3}{\left[\frac{1}{N} \sum_{i=0}^{N-1} (P_i - \text{Mean})^2 \right]^{\frac{3}{2}}} \quad (3.5)$$

$$\text{Kurtosis} = \frac{\frac{1}{N} \sum_{i=0}^{N-1} (P_i - \text{Mean})^4}{\left[\frac{1}{N} \sum_{i=0}^{N-1} (P_i - \text{Mean})^2 \right]^2} - 3 \quad (3.6)$$

โดย P_i แทน ค่าพิกเซลของภาพ
N แทน จำนวนพิกเซลของภาพ




รูปที่ 3.40 ขั้นตอนการแยกคุณลักษณะสี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. คุณลักษณะพื้นผิว (Texture feature)

คุณลักษณะพื้นผิว ที่ใช้ในงานวิจัยครั้งนี้ ใช้อัลกอริทึม gray-level co-occurrence matrix (GLCM) ในการแยกคุณลักษณะ โดยนำภาพ RGB เข้าอัลกอริทึม GLCM ด้วยไลบรารี skimage.feature โดยเลือกดึง 6 คุณสมบัติของ GLCM ได้แก่ Dissimilarity (D), Angular Second Moment (ASM), Contrast (Ct), Correlation (Cn), Energy (Ey) และ Homogeneity (Hy) โดยแต่ละคุณสมบัติใช้ข้อมูล 4 ทิศทางได้แก่ แนวนอน (0°), แนวตั้ง (90°), แนวทแยงมุมซ้าย (45°) และแนวทแยงมุมขวา (135°) รวม 24 คุณลักษณะ โดยมีขั้นตอนการแยกคุณลักษณะพื้นผิวโดยใช้ GLCM ดังรูปที่ 3.41 และสมการที่ 3.7-3.12 (Park and Guldman, 2020; Haralick. et al., 1973)



รูปที่ 3.41 ขั้นตอนการแยกคุณลักษณะพื้นผิวโดยใช้ GLCM (Park and Guldman, 2020)

$$\text{Dissimilarity} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} g(i,j) \cdot |i - j| \tag{3.7}$$

$$\text{Angular Second Moment} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (g(i,j))^2 \tag{3.8}$$

$$\text{Contrast} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - j)^2 \cdot g^2(i,j) \tag{3.9}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\text{Correlation} = \frac{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu) \cdot (j - \mu) \cdot g(i, j)}{\sigma^2} \quad (3.10)$$

$$\text{Energy} = \sqrt{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} g^2(i, j)} \quad (3.11)$$

$$\text{Homogeneity} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{1}{1+(i+j)^2} \cdot g(i, j) \quad (3.12)$$

โดย N แทน จำนวนระดับค่าสีเทา (number of gray level)

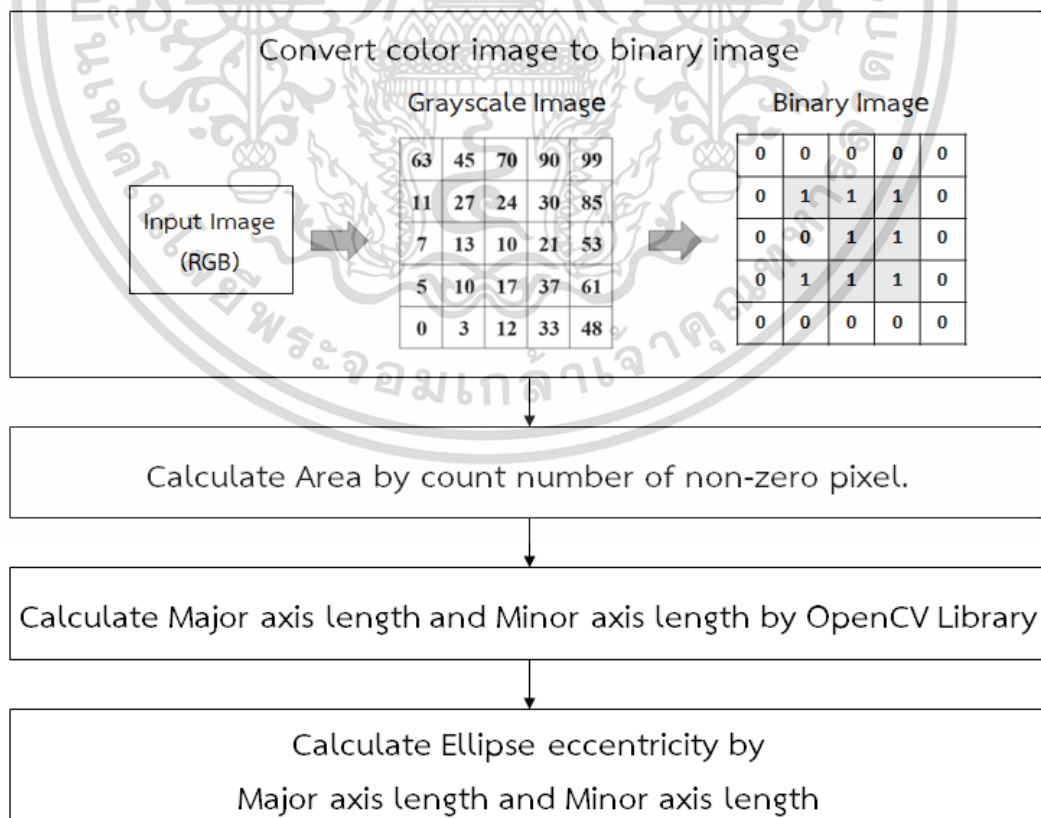
$g(i, j)$ แทน ค่าที่ได้จาก GLCM Normalized

μ แทน ค่าเฉลี่ยของ GLCM Normalized

σ^2 แทน ค่าความแปรปรวนของ GLCM Normalized

3. คุณลักษณะรูปร่างและขนาด (Shape and Size feature)

ถึงแม้ว่าลักษณะรูปร่างและขนาดของผลแก้วมังกรแต่ละสายพันธุ์มีลักษณะคล้ายคลึงกัน แต่ก็มีอาจจะที่งคุณสมบัตินี้ได้ ดังนั้นในงานวิจัยนี้จึงนำคุณลักษณะรูปร่างและขนาดมาใช้ในการดำเนินงานวิจัยด้วย คุณลักษณะรูปร่างและขนาดที่ใช้ในงานวิจัยนี้ประกอบไปด้วยคุณลักษณะพื้นที่ (Area) ความยาวแกนหลัก (Major axis length) ความยาวแกนรอง (Minor axis length) และความเยื้องศูนย์กลางของวงรี (Ellipse eccentricity) ดังสมการที่ 3.13 รวม 4 คุณลักษณะ มีขั้นตอนการแยกคุณลักษณะดังรูปที่ 3.42 (Muhammad, 2014)



รูปที่ 3.42 ขั้นตอนการแยกคุณลักษณะรูปร่างและขนาด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\text{Ellipse eccentricity} = \frac{\sqrt{(\text{Major axis length})^2 - (\text{Minor axis length})^2}}{(\text{Major axis length}/2)} \quad (3.13)$$

4. คุณสมบัติขอบและเส้น (Edge and Line Features)

คุณสมบัติขอบและเส้นที่ใช้ในการวิจัยนี้เป็นอัตราส่วนพิกเซลของขอบเฉพาะ ส่วนของผลแก้วมังกรโดยการประมวลผลด้วยอัลกอริทึม Canny Edge (Canny, 1986; Opencv Python Tutorials, 2016) และจำนวนของเส้นตรงโดยการประมวลผลอัลกอริทึม Hough Transform (Hough, 1962; Mukhopadhyay and Chaudhuri, 2015; Opencv Python Tutorials, 2016)

อัลกอริทึม Canny Edge เป็นอัลกอริทึมการตรวจจับขอบที่เป็นที่นิยมใช้ในการตรวจจับพิกเซลใดๆ ที่คาดว่าจะจะเป็นขอบของวัตถุในภาพ ประกอบด้วย 4 ขั้นตอนได้แก่ ขั้นตอนที่ 1 การลบจุดรบกวนด้วยฟิลเตอร์ Gaussian ขนาด 5x5 ขั้นตอนที่ 2 การค้นหาการไล่ระดับความเข้มของภาพและทิศทาง ขั้นตอนที่ 3 ลบพิกเซลที่ไม่ต้องการออกด้วยค่าสูงสุดในพื้นที่ใกล้เคียงในทิศทางของการไล่ระดับสี และขั้นตอนสุดท้ายคือการเลือกพิกเซลที่คาดว่าจะจะเป็นขอบหรือไม่ มีการกำหนดค่า Threshold สองค่าคือ minVal และ maxVal โดยพิกเซลใดๆ ที่มีการไล่ระดับความเข้มมากกว่า maxVal จะเป็นพิกเซลขอบและถ้าน้อยกว่า minVal จะไม่ใช่พิกเซลขอบ พิกเซลใดๆ ที่มีการไล่ระดับความเข้มระหว่างค่า minVal และ maxVal จะถูกระบุว่าเป็นขอบหรือไม่ ด้วยการตรวจสอบการเชื่อมต่อ หากเชื่อมต่อกับพิกเซลที่ขอบแน่นอน พิกเซลเหล่านั้นจะถูกตัดสินให้เป็นส่วนหนึ่งของขอบด้วย ในทางตรงกันข้ามจะถูกตัดสินว่าไม่ใช่ส่วนของขอบ การกำหนดค่า minVal และ maxVal เป็นสิ่งสำคัญมาก เพราะส่งผลต่อความถูกต้องของผลลัพธ์

ดังนั้นขั้นตอนการคำนวณอัตราส่วนพิกเซลของขอบแสดงดังรูปที่ 3.43 เริ่มจากการนำภาพผลลัพธ์จากกระบวนการลบพื้นหลังของภาพ ซึ่งเป็นภาพที่ถูกปรับขนาดตามสัดส่วนเฉพาะผลแก้วมังกรเป็น 100x100 พิกเซล ดังแสดงในรูปที่ 3.38(f) แล้วแปลงเป็นภาพระดับสีเทา จากนั้นนำภาพระดับสีเทามาแจกแจงความถี่ด้วยฮิสโตแกรม กำหนดอัตราภาคขั้นเท่ากับ 10 ใช้ขอบเขตล่างของขั้นแรกและขั้นสุดท้าย แทนค่า minVal และ maxVal ตามลำดับ แล้วประมวลผลเพื่อกำหนดพิกเซลขอบโดยใช้อัลกอริทึม Canny Edge ผ่านฟังก์ชัน cv.Canny ของไลบรารี OpenCV (Opencv Python Tutorials, 2016) ภาพที่ได้คือภาพสองระดับที่มีพิกเซลสีขาวแทนพิกเซลขอบ ดังนั้น อัตราส่วนพิกเซลขอบจะเท่ากับจำนวนพิกเซลสีขาวหารด้วยขนาดภาพและคูณด้วย 100 ดังสมการ 3.14

$$\text{Ratio of Edge} = \frac{\text{Edge pixels}}{\text{image size}} * 100 \quad (3.14)$$


สำหรับคุณสมบัติของเส้นนำมาประยุกต์ใช้เพื่อตรวจจับลักษณะของกลีบรอบเปลือกแก้วมังกร ซึ่งลักษณะของกลีบจะสามารถลากเป็นเส้นตรงได้ จากสมมติฐานแก้วมังกรที่มีกลีบรอบผลมากจะมีเส้นตรงมากด้วย ดังนั้นการแยกคุณลักษณะของเส้นจึงใช้อัลกอริทึม Hough Transform ที่สามารถตรวจจับรูปร่างในรูปภาพในรูปแบบเรขาคณิต เช่น เส้นตรง วงกลม วงรี เป็นต้น อัลกอริทึม Hough Transform สามารถตรวจจับรูปร่างได้แม้ว่าพิกเซลจะไม่ต่อเนื่องกัน อาจขาดหายไปบางพิกเซล ในงานวิจัยนี้มุ่งเน้นไปที่การตรวจจับเส้นตรง สมการเส้นในรูปแบบพาราเมตริก ดังสมการ 3.15

$$y = x \cos \theta + y \sin \theta \quad (3.15)$$

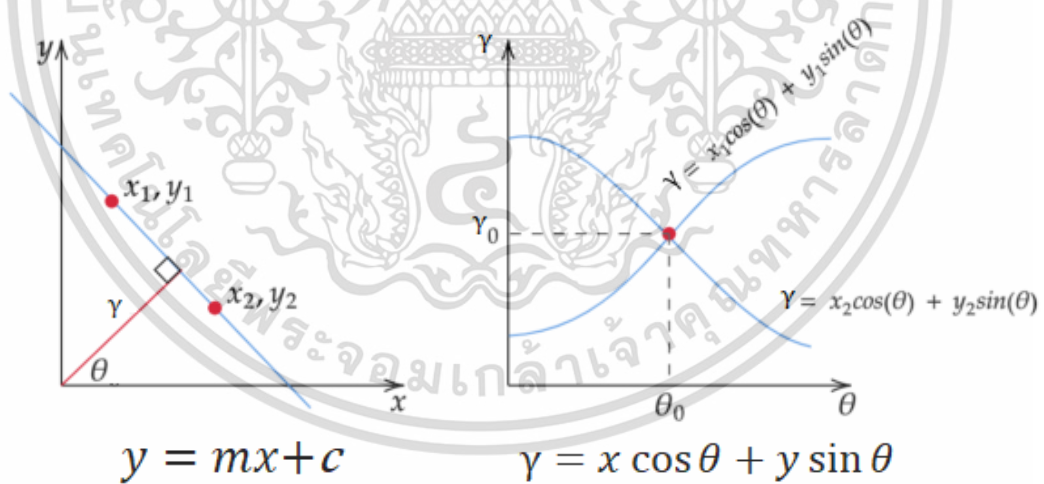
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากสมการ 3.15 กำหนดให้ x, y คือพิกัดของพิกเซล γ (ρ) คือระยะตั้งฉากจากจุดกำเนิดถึงเส้น และ θ (Theta) คือมุมของเส้นตั้งฉากกับแกนอนที่ทำมุมทิศทวนเข็มนาฬิกา ซึ่งพิกเซลใดที่อยู่ในเส้นตรงเดียวกันจะมีค่า ρ และ θ เท่ากัน ดังรูปที่ 3.44 (ดัดแปลงจาก Soret, 2020)

โดยขั้นตอนแรกของอัลกอริทึม Hough Transform คือการสร้างอาร์เรย์ 2 มิติ เรียกว่า Accumulator ใช้เก็บสะสมคะแนนที่รวบรวมจากค่าที่คำนวณได้ของ γ และ θ แต่ละคู่ สำหรับแต่ละพิกเซล Accumulator นี้จะมีค่าเริ่มต้นด้วยค่าศูนย์ ให้แถวเท่ากับ γ และคอลัมน์เท่ากับ θ ก่อนการเริ่มนับคะแนน ภาพจะต้องถูกประมวลผลเพื่อระบุพิกเซลที่คาดว่าจะจะเป็นขอบของวัตถุในภาพก่อน หลังจากนั้น คำนวณ γ ดังสมการ 3.15 โดยพิกัดพิกเซล (x, y) และแทนค่า θ ที่เป็นไปได้ จากนั้นเพิ่มค่าที่ละ 1 ใน Accumulator ที่คอลัมน์และแถวมีความสอดคล้องกับค่า γ และ θ ซึ่งเป็นผลลัพธ์ของการคำนวณ จำนวนในแต่ละเซลล์ของ Accumulator หมายถึงจำนวนพิกเซลที่สามารถอยู่ในเส้นตรงเดียวกันได้ ขั้นตอนสุดท้ายของอัลกอริทึมคือต้องกำหนดคะแนนขั้นต่ำเพื่อเป็นเกณฑ์ในการตัดสินใจเลือกกลุ่มพิกเซลที่สามารถเป็นเส้นตรงได้ อาจเป็นความยาวขั้นต่ำของเส้นที่ควรตรวจพบ ดังนั้นเพื่อให้ได้จำนวนเส้นตรง ในงานวิจัยนี้ได้นำผลลัพธ์ของอัลกอริทึม canny edge มาประมวลผล โดยใช้ฟังก์ชัน cv.HoughLines ของไลบรารี OpenCV (Opencv Python Tutorials, 2016) ตั้งค่า γ ซึ่งเป็นค่าความละเอียดของระยะทางของตัวสะสมเป็นพิกเซลเท่ากับ 1 และ θ ซึ่งเป็นความละเอียดของมุมของตัวสะสมในหน่วยเรเดียนเท่ากับ $\pi/180$ นำคะแนนสะสมของ Accumulator มาแจกแจงความถี่ด้วยฮิสโตแกรม กำหนดอัตราภาคชั้นเท่ากับ 11 นำข้อมูลจากอัตราภาคชั้นที่ 2 ถึงชั้นที่ 6 ซึ่งเป็นพื้นที่เส้นโค้งปกติมาคำนวณค่าเฉลี่ยโดยปิดเศษขึ้นเป็นจำนวนเต็ม แล้วกำหนดค่าเฉลี่ยนี้เป็นความยาวขั้นต่ำของเส้นที่ควรตรวจพบ โดยใช้ฟังก์ชัน cv.HoughLines ให้ผลลัพธ์เป็นลิสต์ของเส้นตรงที่ตรวจพบ ดังนั้นจำนวนเส้นตรงที่ได้คือความยาวของลิสต์ที่ได้จากฟังก์ชัน ดังรูปที่ 3.45


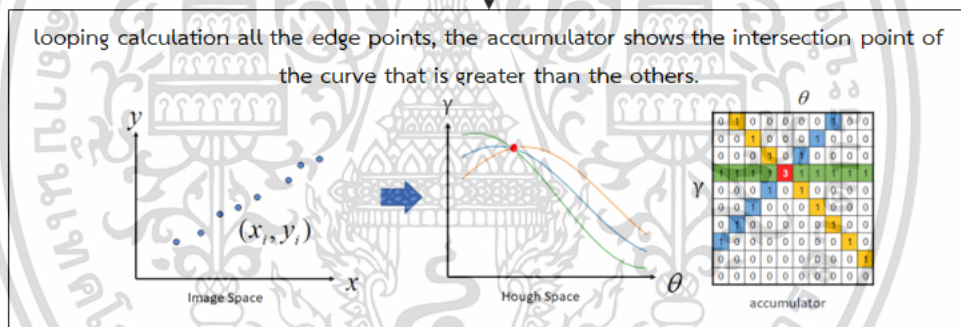

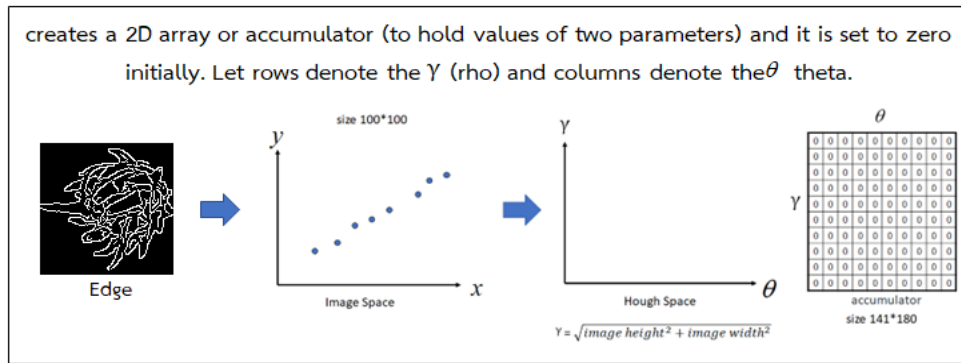


รูปที่ 3.43 ขั้นตอนการแยกคุณลักษณะขอบ



รูปที่ 3.44 ความสัมพันธ์ระหว่างค่า rho และ theta กับ สมการเส้นตรง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



minimum length of line is a mean of data in the 2nd to 6th layer.

Use edge image and minimum length of line to detect the line by cv.HoughLines function of OpenCV Library

The number of line is the length of output list from cv.HoughLines function

รูปที่ 3.45 ขั้นตอนการแยกคุณลักษณะเส้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้หน้าไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5. การปรับค่าคุณลักษณะด้วย MinMaxScaler

ผลที่ได้จากการแยกคุณลักษณะที่กล่าวมาข้างต้นจะให้ผลลัพธ์เป็นตัวเลขซึ่งมีสเกลที่แตกต่างกัน ดังรูปที่ 3.46(a) ดังนั้นเพื่อให้การเรียนรู้ของเครื่องมีประสิทธิภาพมากขึ้น จึงทำการปรับสเกลให้เป็นมาตรฐานเดียวกัน (Feature Scaling) ด้วย MinMaxScaler ซึ่งจะมีสเกลระหว่าง 0-1 โดยใช้สูตรดังสมการที่ 3.16 ซึ่งจะให้ผลลัพธ์ดังรูปที่ 3.46(b)

$$\text{MinMaxScaler Transform} = (x - \min) / (\max - \min) \quad (3.16)$$

โดย x แทน ข้อมูล

\min แทน ค่าต่ำสุดของข้อมูลในคอลัมน์

\max แทน ค่าสูงสุดของข้อมูลในคอลัมน์

	mean_r	std_r	skw_r	kurt_r
0	204.322	54.745	-0.548	-1.042
1	204.639	62.146	-0.642	-1.274
2	205.789	46.233	-0.433	-0.946
3	196.452	60.304	-0.410	-1.325
4	207.537	47.381	-0.807	-0.116
5	172.465	72.748	0.030	-1.635
6	173.830	63.752	-0.285	-1.033

(a)

	mean_r	std_r	skw_r	kurt_r
0	0.908	0.321	0.309	0.390
1	0.917	0.600	0.197	0.238
2	0.950	0.000	0.447	0.454
3	0.684	0.531	0.474	0.204
4	1.000	0.043	0.000	1.000
5	0.000	1.000	1.000	0.000
6	0.039	0.661	0.623	0.396

(b)

รูปที่ 3.46 ตัวอย่างการปรับค่าข้อมูลคุณสมบัติทางสถิติของคุณลักษณะสี่ด้วย MinMaxScaler

3.2.6.2 การจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา

สำหรับการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหานั้น ผู้วิจัยดำเนินการด้วยการแยกคุณลักษณะ ได้แก่ การแยกคุณลักษณะสี่พื้นผิว รูปร่าง ขนาด ขอบและเส้น โดยก่อนนำข้อมูลคุณลักษณะ (Features) ไปประมวลผล ได้ทำการปรับค่าสเกลของข้อมูลให้มีค่าในช่วง 0-1 ด้วย MinMaxScaler โดยใช้ข้อมูลชุดฝึกหัด (Train Set) เป็นเกณฑ์อ้างอิงในการปรับค่าของชุดทดลอง (Validate Set) และชุดทดสอบ (Test Set) ซึ่งมีแผนการทดลองใช้คุณลักษณะดังกล่าวกับวิธีการเรียนรู้ของเครื่องด้วย ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM), K-Nearest Neighbour (KNN) Standardized Variable Distances (SVD) (Elen and Avuçlu, 2021) และ Minimum Distance Criterion (MDC) (Selvaraj. et al., 2010) เพื่อหาคุณลักษณะและวิธีการเรียนรู้ที่มีประสิทธิภาพในการจำแนกมากที่สุด ซึ่งสามารถสรุปแผนการทดลองได้ดังตารางที่ 3.6

ตารางที่ 3.6 แผนการทดลองการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา

Algorithms	Distance/Kernel	Features
SVM	Linear	เลือกทดลองจากคุณลักษณะทั้งหมดหรือบางส่วนของคุณลักษณะสี่พื้นผิว รูปร่าง ขนาด ขอบและเส้น
	Polynomial	
	RBF	
	Sigmoid	
k-NN	Manhattan	
	Euclidean	
	Minkowski	
	Hellinger	

3.2.6.3 การจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยการเรียนรู้เชิงลึก

สำหรับการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยการเรียนรู้เชิงลึกนั้น ผู้วิจัยได้สร้างโมเดลการเรียนรู้เชิงลึกจากโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network : CNN) ใช้ชื่อเรียกว่า DIPDEEP ย่อมาจาก Digital Image Processing and Deep Learning โดยมีโครงสร้างดังตารางที่ 3.7 เพื่อใช้ในการทดลองและเปรียบเทียบประสิทธิภาพกับโมเดลอื่นๆ ได้แก่ ResNet50 (He. et al., 2016) VGG16 (Simonyan and Zisserman, 2015) และ MobileNetV2 (Sandler. et al., 2018)

ตารางที่ 3.7 โครงสร้างโมเดลการเรียนรู้เชิงลึกที่ใช้ในการทดลอง (DIPDEEP)

Layer	Size	Type	Output
Input	100x100x3		
Layer1	96x96x16	Convolution 2D (5x5) + ReLU	16
Layer2	48x48x16	MaxPooling (2x2)	-
Layer3	44x44x32	Convolution 2D (5x5) + ReLU	32
Layer4	22x22x32	MaxPooling (2x2)	-
Layer5	18x18x64	Convolution 2D (5x5) + ReLU	64
Layer6	9x9x64	MaxPooling (2x2)	-
Layer7	5x5x128	Convolution 2D (5x5) + ReLU	128
Layer8	2x2x128	MaxPooling (2x2)	-
Layer9	1x1x512	Flatten	512
Layer10	1x1x1024	Fully Connected + ReLU	1024
Layer11	1x1x256	Fully Connected + ReLU	256
Output	1x1x6 or 1x1x7	Fully Connected + Softmax	6

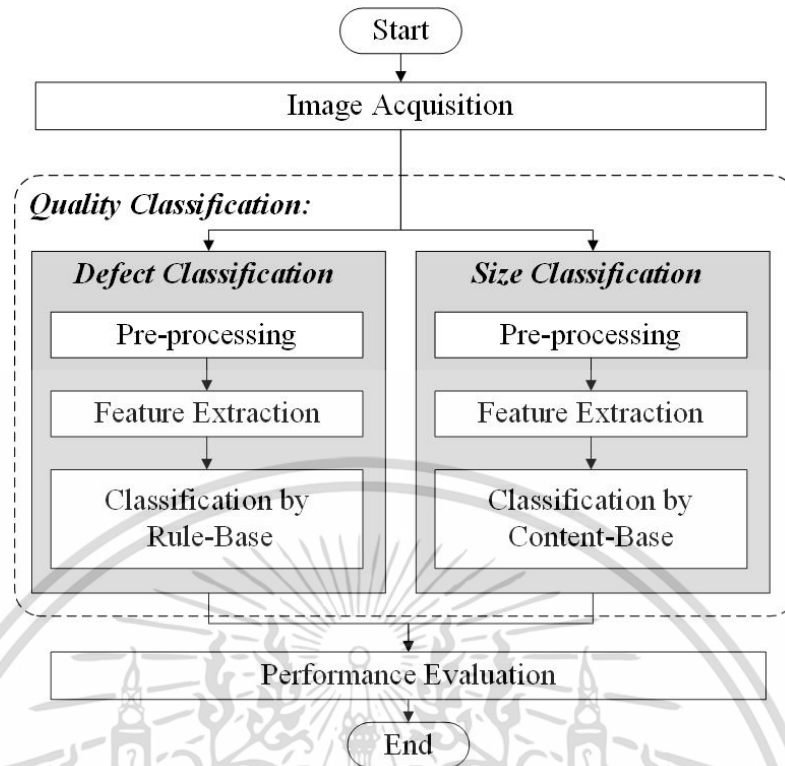
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากโครงสร้างโมเดลที่นำเสนอผู้วิจัยใช้ภาพนำเข้าขนาด 100x100 พิกเซล ประมวลผลด้วย Convolution Layer กำหนด ขนาด kernel เท่ากับ 5x5 และ activation function แบบ ReLU โดยกำหนด Output เท่ากับ 16 Node ในชั้นแรก ทำให้ขนาดภาพถูกปรับลดลงเหลือ 96x96 พิกเซล นำผลลัพธ์ที่ได้ในชั้นนี้เป็นข้อมูลนำเข้าของชั้นที่ 2 ประมวลผลต่อด้วย Pooling Layer กำหนด strides เท่ากับ 2x2 ขนาดภาพถูกปรับลดลงเหลือครึ่งหนึ่งเป็น 48x48 พิกเซล นำผลลัพธ์ที่ได้จากชั้นที่ 2 ประมวลผลต่อ ในชั้นที่ 3-8 โดยใช้ Convolution Layer ขนาด kernel เท่ากับ 5x5 ReLU activation function สลับกับ Pooling Layer กำหนด strides เท่ากับ 2x2 โดยกำหนด Output เท่ากับ 32, 64 และ 128 Node ในชั้นที่ 3, 5 และ 7 ตามลำดับ ดังนั้นขนาดของผลลัพธ์จะถูกปรับลดลงเหลือ 2x2 Output 128 Node เมื่อทำการปรับรูปแบบภาพให้เป็นมิติ 1x1 ด้วย Flatten layer ในชั้นที่ 9 จะได้ Output เท่ากับ 512 Node ชั้นที่ 10 และ 11 ใช้ Fully Connected Layer และ ReLU เป็น activation function กำหนด Output เท่ากับ 1024 และ 256 Node ตามลำดับ นำผลลัพธ์ที่ได้ประมวลผลต่อในชั้นสุดท้าย Output Layer โดยใช้ Fully Connected Layer เช่นเดิม แต่ activation function เป็นแบบ softmax กำหนด Output เท่ากับ จำนวนคลาส ซึ่งในการทดลองผู้วิจัยทดลองจำแนกสายพันธุ์แก้วมังกรไทย 6 สายพันธุ์เฉพาะกลุ่มเปลือกสีแดง ดังนั้น Output node จะเท่ากับ 6 โหนด ส่วนพารามิเตอร์ที่เหลือที่ไม่ได้ระบุผู้วิจัยใช้ค่า Default ของ keras ทั้งหมด โมเดลที่นำเสนอใช้ Optimizer แบบ Adam algorithm กำหนด Learning rate เท่ากับ 0.001 ในกระบวนการเรียนรู้ (Training) ผู้วิจัยใช้โมเดลที่นำเสนอประมวลผลกับชุดข้อมูลแก้วมังกรไทยโดยกำหนด Batch Size เท่ากับ 100 และกำหนด Epoch หลายแบบ ได้แก่ 10, 20, 30, 40, 50, 100, 300, 400 และ 500 epochs เพื่อทดสอบว่า Epoch ไດจะเหมาะสมและได้ค่าความถูกต้องสูงที่สุด

สำหรับการทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยการเรียนรู้เชิงลึก ด้วยโมเดลอื่น ได้แก่ ResNet50 (He. et al., 2016) VGG16 (Simonyan and Zisserman, 2015) และ MobileNetV2 (Sandler. et al., 2018) ซึ่งเป็นโมเดลที่มีการเรียนรู้มาแล้ว (pre-trained model) ด้วยลักษณะโครงสร้างที่แตกต่างกัน จึงมีการกำหนดให้ใช้ค่าน้ำหนัก (Weight) ของโมเดลทั้งสาม แต่ปรับขนาด Input เป็น 100x100 พิกเซล ซึ่งทั้งสามโมเดลสามารถรองรับขนาดภาพนี้ได้โดยไม่กระทบกับโครงสร้างเดิม

3.3 การพัฒนาอัลกอริทึมสำหรับจำแนกคุณภาพแก้วมังกรไทยจากภาพ

จากการศึกษาวิธีวิเคราะห์คุณภาพแก้วมังกรและงานวิจัยที่เกี่ยวข้องในบทที่ 2 พบว่าวิธีวิเคราะห์คุณภาพแก้วมังกรของไทยนั้น จะพิจารณาจากขนาดด้วยน้ำหนักของผลแก้วมังกร ความผิดปกติด้านรูปทรง ตำแหน่งที่ผิวและเปลือก ซึ่งเป็นลักษณะภายนอก มีการกำหนดคุณลักษณะของแก้วมังกรแต่ละชั้นคุณภาพไว้อย่างชัดเจน สามารถใช้การตรวจสอบด้วยสายตาและทดสอบด้วยประสาทสัมผัสของมนุษย์ในการจำแนกชั้นคุณภาพได้ แต่อาจมีความเสี่ยงสูงต่อความผิดพลาดในการจำแนกชั้นคุณภาพได้ เนื่องจากความเมื่อยล้าของสายตา ดังนั้นในการวิจัยครั้งนี้ ผู้วิจัยจึงนำเทคนิคการประมวลผลภาพ เทคนิคการสร้างกฎ และเทคนิคการแยกคุณลักษณะตามเนื้อหา ในการวางแผนการทดลองจำแนกคุณภาพของแก้วมังกรไทยจากภาพ ดังรูปที่ 3.47



รูปที่ 3.47 แผนการทดลองจำแนกคุณภาพของแก้วมังกรไทยจากภาพ

จากรูปที่ 3.47 แสดงแผนการทดลองการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ ประกอบด้วย 1) การจำแนกคุณภาพโดยการตรวจหาตำหนิโดยใช้เทคนิคการสร้างกฎ และ 2) การจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา ชุดข้อมูลภาพจะถูกประมวลผลเพื่อเตรียมข้อมูลภาพ และทำการแยกคุณลักษณะที่คาดว่าจะช่วยให้สามารถจำแนกคุณภาพโดยการตรวจหาตำหนิและจำแนกขนาดของผลแก้วมังกรจากภาพได้ ซึ่งใช้กระบวนการที่แตกต่างกัน และทำการวัดประสิทธิภาพเป็นขั้นตอนสุดท้าย

3.3.1 การเตรียมข้อมูลภาพสำหรับจำแนกคุณภาพ (Pre-processing of Quality Classification)

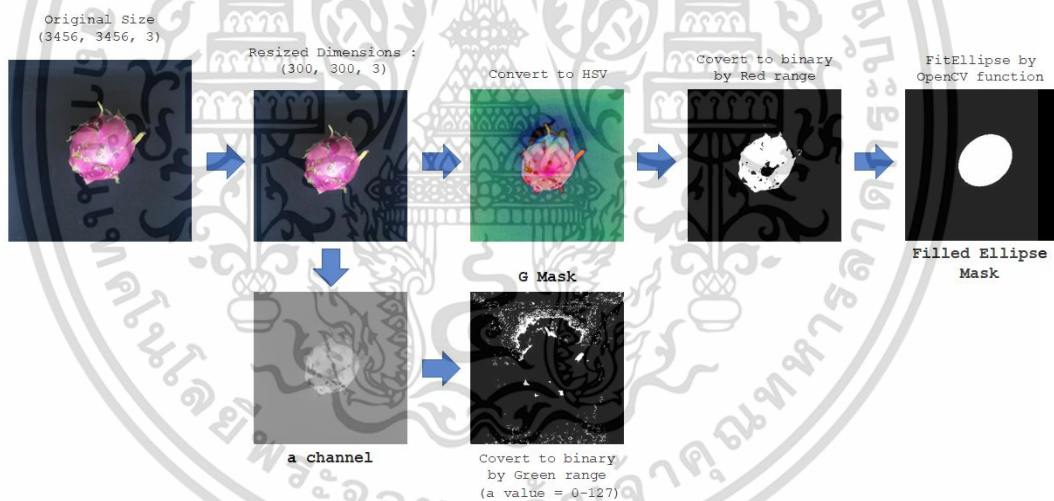
การเตรียมข้อมูลภาพสำหรับจำแนกคุณภาพมีวัตถุประสงค์เพื่อประมวลผลภาพแก้วมังกรที่ได้จากการเก็บข้อมูลตามกระบวนการเก็บข้อมูลในหัวข้อ 3.1.3 เพื่อดึงคุณลักษณะของผลแก้วมังกรที่คาดว่าจะช่วยให้สามารถจำแนกคุณภาพของแก้วมังกรได้ ประกอบไปด้วยการเตรียมข้อมูลสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิและการเตรียมข้อมูลสำหรับการจำแนกผลแก้วมังกรตามขนาด โดยมีรายละเอียดดังนี้

3.3.1.1 การเตรียมข้อมูลสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิ

จากการศึกษาการแบ่งชั้นคุณภาพแก้วมังกรตามมาตรฐานสินค้าเกษตร และตัวอย่างผลแก้วมังกรที่ถูกแบ่งกลุ่มตามชั้นคุณภาพ ดังรูปที่ 3.4 พบว่าลักษณะของผลแก้วมังกรแต่ละชั้นคุณภาพนั้น จะพิจารณาจากความผิดปกติด้านรูปร่าง ปริมาณตำหนิที่ผิวและเปลือก โดยแบ่งออกเป็น 3 ชั้นคุณภาพหลัก ได้แก่ ชั้นพิเศษ (Extra class) ชั้นหนึ่ง (Class I) และชั้นสอง (Class II) ซึ่ง 3 ชั้นเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คุณภาพดังกล่าวเป็นชั้นคุณภาพที่ยังคงสามารถนำมาซื้อขายในท้องตลาดได้ แต่จากการเก็บข้อมูลภาพพบว่ายังมีแก้วมังกรบางผลที่ไม่สามารถนำมาซื้อขายได้ แต่สามารถเก็บไว้รับประทานในครัวเรือนได้ ดังนั้นในการวิจัยครั้งนี้จึงเพิ่มชั้นคุณภาพเพิ่มเติมมาอีก 1 ชั้นคุณภาพ คือคุณภาพชั้นสาม (Class III) ซึ่งเป็นชั้นคุณภาพที่ผลแก้วมังกรมีคุณภาพต่ำกว่ามาตรฐานที่กระทรวงกำหนดไว้

โดยหลังจากเก็บชุดข้อมูลแล้วมีการนำชุดข้อมูลให้เกษตรกรเจ้าของสวน เป็นผู้กำกับป้าย (Label) เพื่อระบุชั้นคุณภาพของแก้วมังกรแต่ละภาพ พบว่าในกลุ่มตัวอย่างแก้วมังกรทุกผลไม่มีความผิดปกติด้านรูปทรง ดังนั้นการกำกับป้ายระบุชั้นคุณภาพของกลุ่มตัวอย่างจะพิจารณาจากความสด ซึ่งเป็นคุณภาพขั้นต่ำที่แก้วมังกรทุกชั้นคุณภาพต้องมี ยกเว้นในกรณีที่ผลแก้วมังกรไม่สดจะถูกจัดอยู่ในกลุ่มคุณภาพชั้นสาม (Class III) และปริมาณตำหนิที่ผิวและเปลือก หากแก้วมังกรผลใด ไม่มีตำหนิที่ผิวและเปลือก หรือมีตำหนิที่มองเห็นได้ไม่ชัดเจน แก้วมังกรผลนั้นจะถูกจัดอยู่ในกลุ่มคุณภาพชั้นพิเศษ (Extra class) หากมีตำหนิที่ผิวและเปลือกโดยรวมไม่เกินร้อยละ 5 ของพื้นที่ผิวของแก้วมังกรจะถูกจัดอยู่ในกลุ่มคุณภาพชั้นหนึ่ง (Class I) หากมีตำหนิที่ผิวและเปลือกโดยรวมไม่เกินร้อยละ 10 ของพื้นที่ผิวของแก้วมังกรจะถูกจัดอยู่ในกลุ่มคุณภาพชั้นสอง (Class II) และหากมีตำหนิที่ผิวและเปลือกโดยรวมเกินร้อยละ 10 ของพื้นที่ผิวของแก้วมังกรจะถูกจัดอยู่ในกลุ่มคุณภาพชั้นสาม (Class III) ดังนั้นผู้วิจัยจึงนำข้อมูลภาพมาประมวลผลตามขั้นตอนในรูปที่ 3.48 เพื่อเตรียมข้อมูลเพื่อใช้ในการแยกคุณลักษณะในขั้นตอนถัดไป



รูปที่ 3.48 การเตรียมข้อมูลสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิ


จากรูปที่ 3.48 ผู้วิจัยนำชุดข้อมูลภาพมาลดขนาดลงตามสัดส่วนให้มีขนาดไม่เกิน 300x300 พิกเซล แปลงภาพจากโมเดลสี RGB เป็นโมเดลสี HSV และอ่านข้อมูลช่องสัญญาณ a ของโมเดลสี Lab นำภาพสี HSV มาแปลงเป็นภาพสองระดับโดยใช้ HSV Range ของสีแดง นั่นคือค่า Hue (H) มีค่าตั้งแต่ 0-23 และ 151-179 ค่า Saturation (S) และ Value (V) กำหนดให้มีค่าตั้งแต่ 100-255 พิกเซลใดในภาพ HSV อยู่ในช่วงดังกล่าวจะถูกปรับเป็นพิกเซลสีขาวในทางตรงกันข้ามจะถูกปรับเป็นพิกเซลสีดำ นำภาพสองระดับที่ได้ไปประมวลผลต่อกันด้วย FitEllipse function ของ OpenCV Library ซึ่งจะได้ภาพวงรีที่ระบุขอบเขตของผลแก้วมังกร แทนด้วยหน้ากาก Filled Ellipse Mask เป็นการลบส่วนของกลีบที่ยื่นออกจากผลออกไป เหลือเพียงพิกเซลที่เป็นส่วนของผิวและเปลือกของผลแก้วมังกรเท่านั้น สำหรับภาพ a channel จะถูกนำมาแปลงเป็นภาพสองระดับโดยใช้

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ช่วงของสีเขียว แทนด้วยหน้ากาก G Mask นั่นคือ ค่า a ตั้งแต่ 0-127 พิกเซลใดในภาพ a channel อยู่ในช่วงดังกล่าวจะถูกปรับเป็นพิกเซลสีขาวในทางตรงกันข้ามจะถูกปรับเป็นพิกเซลสีดำ จากนั้นนำภาพผลลัพธ์ที่ได้ 3 ภาพ ได้แก่ ภาพ a channel หน้ากาก Filled Ellipse Mask และหน้ากาก G Mask มาประมวลผลต่อด้วยสมการที่ 3.17 และ 3.18 ซึ่งเป็นการครอบภาพ a channel กับหน้ากาก G Mask ด้วยหน้ากาก Ellipse Mask ซึ่งจะให้ผลลัพธ์ดังรูปที่ 3.49 ซึ่งจะเห็นว่ากลีบที่ยื่นออกมาจากเปลือกของผลแก้วมังกรจะถูกลบออกจากภาพ เป็นการลบส่วนเกินที่ไม่ต้องการออกจากภาพ ให้เหลือเพียงส่วนของผิวและเปลือกของแก้วมังกรเท่านั้น

$$\text{Dragon Fruit Cropped} = ((\text{Filled Ellipse Mask}/255) * a \text{ channel}) \quad (3.17)$$

$$\text{Green Cropped} = ((\text{Filled Ellipse Mask}/255) * G \text{ Mask}) \quad (3.18)$$



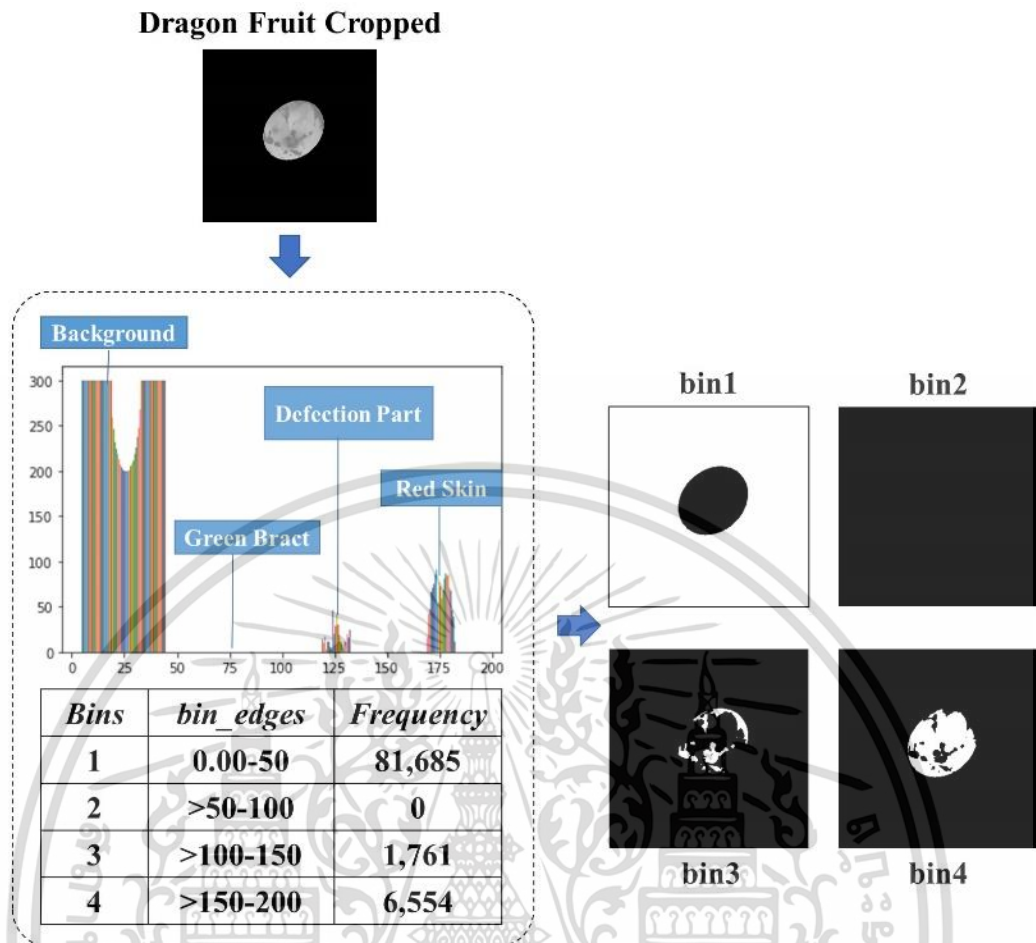
รูปที่ 3.49 การลบส่วนเกินของกลีบออกจากภาพด้วยหน้ากาก Filled Ellipse Mask

จากรูปที่ 3.49 เมื่อนำภาพ Dragon Fruit Cropped มาแจกแจงความถี่ ด้วยฮิสโตแกรม โดยกำหนดให้มีการแบ่งค่าความถี่ออกเป็น 4 อันตรภาคชั้น ซึ่งให้ผลลัพธ์ดังรูปที่ 3.50

จากรูปที่ 3.50 เมื่อพิจารณาค่าขอบบนขอบล่างและลักษณะหน้ากากของแต่ละอันตรภาคชั้น พบว่าข้อมูลที่ได้จากแต่ละอันตรภาคชั้นนั้นสามารถนำมาใช้แบ่งส่วนภาพออกเป็น 4 ส่วนได้ ได้แก่ อันตรภาคชั้นที่ 1 คือส่วนของพื้นหลัง อันตรภาคชั้นที่ 2 คือส่วนสีเขียวของกลีบที่ยังคงเหลืออยู่ในภาพ อันตรภาคชั้นที่ 3 คือส่วนของตำหนิที่ผิวและเปลือก และอันตรภาคชั้นที่ 4 คือส่วนของผิวและเปลือกที่มีสีแดง ซึ่งผลลัพธ์ที่ได้จากกระบวนการเตรียมข้อมูลสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนินี้จะถูกใช้ในการแยกคุณลักษณะในขั้นตอนถัดไป

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ สำหรับการเชิงวิชาการเพื่อการศึกษาเท่านั้น เมื่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า


ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.50 การแจกแจงความถี่และการสร้างหน้ากากด้วยฮิสโตแกรม

3.3.1.2 การเตรียมข้อมูลสำหรับการจำแนกผลแก้วมังกรตามขนาด

จากการศึกษาวิธีวิเคราะห์คุณภาพแก้วมังกร พบว่าการจำแนกผลแก้วมังกรตามขนาด ใช้วิธีการชั่งน้ำหนักผลแก้วมังกรมีหน่วยเป็นกรัมต่อผล โดยมาตรฐานสินค้าเกษตร แบ่งขนาดของผลแก้วมังกรออกเป็น 6 ขนาด พร้อมทั้งมีการระบุรหัสขนาดตั้งแต่รหัส 1 ถึง 6 โดยรหัส 1 แทนขนาดใหญ่ที่สุดและรหัส 6 แทนขนาดเล็กที่สุด แต่ละกลุ่มสายพันธุ์จะมีเกณฑ์น้ำหนักไม่เท่ากันดังที่กล่าวไปแล้วในตารางที่ 2.4 ซึ่งในงานวิจัยครั้งนี้ข้อมูลตัวอย่างแก้วมังกรที่ใช้ในการทดลองเพื่อจำแนกแก้วมังกรตามขนาด มีเพียงกลุ่มผิวสีแดงเนื้อสีขาว (*Hylocereus undatus*) ได้แก่ สายพันธุ์ขาวจัมโบ้เพียงสายพันธุ์เดียวเพราะเป็นสายพันธุ์ที่นิยมปลูกมากที่สุดและมีตัวอย่างข้อมูลครบทุกขนาด แตกต่างจากสายพันธุ์อื่น ซึ่งแก้วมังกรแต่ละผลจะถูกชั่งน้ำหนักมีหน่วยเป็นกรัมก่อนบันทึกภาพ เพื่อความถูกต้องในการระบุขนาด ในการบันทึกภาพใช้ฟังก์ชันเส้นแบ่งเก้าช่องเป็นตัวช่วยในการวางเลย์เอาต์ของภาพ ดังนั้นภาพของแก้วมังกรแต่ละขนาดจะมีความแตกต่างกัน ดังรูปที่ 3.51




รูปที่ 3.51 การแบ่งส่วนภาพด้วยเส้นแบ่งเก้าช่องของผลแก้วมังกรแต่ละขนาด

จากรูปที่ 3.51 จะสังเกตเห็นว่าเมื่อแบ่งส่วนภาพด้วยเส้นแบ่งเก้าช่อง ส่วนของผลแก้วมังกรจะอยู่ช่องศูนย์กลางและอาจมีบางส่วนปรากฏในช่องอื่นๆที่อยู่รอบข้างช่องศูนย์กลางเพียงเล็กน้อย ซึ่งถ้าแก้วมังกรมีขนาดใหญ่พิกเซลพื้นที่ปรากฏในช่องศูนย์กลางจะเหลือน้อยกว่าแก้วมังกรที่มีขนาดเล็ก ดังนั้นผู้วิจัยจึงนำภาพต้นฉบับที่ได้จากการบันทึกภาพตามกระบวนการในหัวข้อที่ 3.1.3 มาเตรียมข้อมูลภาพเพื่อนำไปแยกคุณลักษณะสำหรับการจำแนกผลแก้วมังกรตามขนาดในขั้นตอนถัดไป ดังรูปที่ 3.52

จากรูปที่ 3.52 ผู้วิจัยนำชุดข้อมูลภาพมาลดขนาดลงตามสัดส่วนให้มีขนาดไม่เกิน 300x300 พิกเซล แปลงภาพจากโมเดลสี RGB เป็นโมเดลสี HSV นำภาพสี HSV มาแปลงเป็นภาพสองระดับโดยใช้ HSV Range ของสีแดง นั่นคือค่า Hue (H) มีค่าตั้งแต่ 0-23 และ 151-179 ค่า Saturation (S) และ Value (V) กำหนดให้มีค่าตั้งแต่ 100-255 พิกเซลใดในภาพ HSV อยู่ในช่วงดังกล่าวจะถูกปรับเป็นพิกเซลสีขาวในทางตรงกันข้ามจะถูกปรับเป็นพิกเซลสีดำ นำภาพสองระดับที่ได้ไปประมวลผลต่อด้วย FitEllipse function ของ OpenCV Library ซึ่งจะได้วงรีที่ระบุนขอบเขตของผลแก้วมังกรไม่รวมกลีบ แทนวงรีนี้ด้วย Inner Ellipse Lined หลังจากนั้นนำภาพ RGB ที่ถูกลดขนาดแล้วไปลดมิติเหลือเพียงช่องสัญญาณ R นำภาพ R มาแปลงเป็นภาพสองระดับโดยใช้เทคนิค Thresholding- Based Segment กำหนดค่าขีดแบ่งเท่ากับค่าเฉลี่ยของภาพ R ซึ่งผลลัพธ์ที่ได้จะเป็นภาพสองระดับที่มีพื้นหลังเป็นพิกเซลสีดำและส่วนของผลแก้วมังกรเป็นพิกเซลสีขาว แทนด้วยภาพ DF-Mask นำภาพ DF-Mask ลด noise ด้วย Morphological Opening กำหนด kernel เท่ากับ 5x5 หลังจากนั้นหาเส้นรอบรูปของผลแก้วมังกรรวมกลีบด้วย Edge detect by 4 neighbors procedure ดัง Algorithm 3 ในรูปที่ 3.53 โดยใช้ภาพ Opening ผลลัพธ์ที่ได้จะเป็นเส้นขอบของผลแก้วมังกรทั้งหมด แทนด้วยภาพ DF-Perimeter นำ DF-Perimeter ที่ได้ไปประมวลผลต่อด้วย FitEllipse function ของ OpenCV Library ซึ่งจะได้วงรีที่ระบุนขอบเขตของผลแก้วมังกรรวมกลีบ แทนวงรีนี้ด้วย Outer Ellipse Lined และครอปภาพ Opening เฉพาะส่วนช่องศูนย์กลางของเส้นแบ่งเก้าช่อง แทนด้วยภาพ Center-Mask ดังนั้นผลลัพธ์ที่ได้ประกอบไปด้วยวงรีที่ระบุนขอบเขตของผลแก้วมังกรไม่รวมกลีบ (Inner Ellipse Lined) เส้นรอบรูปของผลแก้วมังกรรวมกลีบ (DF-Perimeter) วงรีที่ระบุนขอบเขตของผลแก้วมังกรรวมกลีบ (Outer Ellipse Lined) และส่วนช่องศูนย์กลางของเส้นแบ่งเก้าช่อง (Center-Mask) ซึ่งจะถูกใช้ในการแยกคุณลักษณะในขั้นตอนถัดไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.52 การเตรียมข้อมูลสำหรับการจำแนกผลแก้วมังกรตามขนาด

Algorithm 3: Edge detect by 4 neighbors

Data: Binary Image.

Result: Image boundary

```

1: height = A height of Binary Image.
2: width = A width of Binary Image.
3: Image boundary[] = 0
4: for each r ∈ rows of Binary Image do
5:   for each c ∈ columns of Binary Image do
6:     if input image[r,c] == 0 then
7:       north = 0
8:       south = 0
9:       east = 0
10:      west = 0
11:      if input image[r-1,c] == 0 then
12:        north = 1
13:        if input image[r+1,c] == 0 then
14:          south = 1
15:          if input image[r,c+1] == 0 then
16:            east = 1
17:            if input image[r,c-1] == 0 then
18:              west = 1
19:            sum = north + south + east + west
20:            if sum < 4 then
21:              Image boundary[r,c]=255

```

รูปที่ 3.53 อัลกอริทึมหาเส้นรอบรูปของผลแก้วมังกรรวมกลีบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.2 การแยกคุณลักษณะสำหรับจำแนกคุณภาพ (Feature Extraction of Quality Classification)

หลังจากเตรียมข้อมูลภาพสำหรับจำแนกคุณภาพเรียบร้อยแล้ว ขั้นตอนต่อไปคือการแยกคุณลักษณะ ซึ่งการแยกคุณลักษณะสำหรับจำแนกคุณภาพในงานวิจัยนี้ประกอบไปด้วย การแยกคุณลักษณะสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิและการแยกคุณลักษณะสำหรับการจำแนกผลแก้วมังกรตามขนาด โดยมีรายละเอียดดังนี้

3.3.2.1 การแยกคุณลักษณะสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิ

จากการกำกับป้ายระบุชั้นคุณภาพของกลุ่มตัวอย่างได้พิจารณาจากความสด (Freshness) และปริมาณตำหนิที่ผิวและเปลือกของแก้วมังกรเป็นร้อยละ (Defected Ratio) ซึ่งผลลัพธ์ที่ได้จากการเตรียมข้อมูลสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิในหัวข้อ 3.3.1.1 พบว่าความสดของผลแก้วมังกรสามารถใช้ปริมาณสีเขียวของกลีบที่ยังคงเหลืออยู่ในภาพได้ นั่นคือค่าความถี่ของข้อมูลในอัตราภาคชั้นที่ 2 จากการแจกแจงความถี่ด้วยฮิสโตแกรมดังแสดงในรูปที่ 3.50 จากการศึกษาพบว่าถ้าค่าความถี่เท่ากับ 0 หมายถึงแก้วมังกรไม่มีความสด ถ้าค่าความถี่มากกว่า 0 หมายถึงแก้วมังกรมีความสด นั่นหมายความว่าหากแก้วมังกรผลใดมีค่า Freshness เท่ากับ 0 นั่นคือไม่สด จะถูกระบุเป็นแก้วมังกรคุณภาพชั้นสาม (Class III) ซึ่งเป็นแก้วมังกรที่มีคุณภาพต่ำกว่ามาตรฐาน หากค่า Freshness มากกว่า 0 จะถูกพิจารณาคุณภาพด้วยปริมาณตำหนิที่ผิวและเปลือกของแก้วมังกรเป็นร้อยละ (Defected Ratio) โดยตำหนิที่ผิวและเปลือกของแก้วมังกรคือพิกเซลใดๆที่ไม่ใช่ส่วนของผิวและเปลือกที่มีสีแดง (Red skin) และไม่ใช่น้ำสีเขียวของกลีบที่ยังคงเหลืออยู่ในภาพ (Green bract) ดังนั้นปริมาณตำหนิที่ผิวและเปลือกของแก้วมังกรเป็นร้อยละสามารถคำนวณดังสมการที่ 3.19


$$\text{Defected Ratio} = \frac{\text{DF} - (\text{Red skin} + \text{Green bract})}{\text{DF}} * 100 \quad (3.19)$$

โดย DF คือจำนวนพิกเซลของผิวและเปลือกของแก้วมังกรทั้งหมด

Red skin คือส่วนผิวและเปลือกที่มีสีแดง

Green bract คือส่วนสีเขียวของกลีบที่ยังคงเหลืออยู่ในภาพ

จากสมการที่ 3.19 สามารถแทน DF ด้วยจำนวนพิกเซลสีขาวของ Filled Ellipse Mask ดังแสดงในรูปที่ 3.48 สามารถแทน Red skin ด้วยค่าความถี่ของข้อมูลในอัตราภาคชั้นที่ 4 จากการแจกแจงความถี่ด้วยฮิสโตแกรมดังแสดงในรูปที่ 3.50 และแทน Green bract ด้วยจำนวนพิกเซลสีขาวของภาพ Green Cropped ดังแสดงในรูปที่ 3.49 ประมวลผลด้วย Morphological Dilation กำหนดขนาด kernel เท่ากับ 5x5 ดังตัวอย่างในรูปที่ 3.54



รูปที่ 3.54 ตัวอย่างการแยกคุณลักษณะสำหรับการจำแนกคุณภาพโดยการตรวจหาตำหนิ

3.3.2.2 การแยกคุณลักษณะสำหรับการจำแนกคุณภาพตามขนาด

จากผลลัพธ์ที่ได้จากการเตรียมข้อมูลภาพสำหรับการจำแนกผลแก้วมังกรตามขนาดสามารถนำมาระบุพื้นที่ของผลแก้วมังกร (Object Area) ด้วยการนับจำนวนพิกเซลสีขาวของภาพ Opening ซึ่งหมายถึงพิกเซลผลแก้วมังกร นับจำนวนพิกเซลสีขาวของภาพ DF-Perimeter แทนค่าความยาวรอบรูปของผลแก้วมังกร (Object Perimeter) เรียกใช้ FitEllipse function ของ OpenCV Library เพื่อระบุความยาวแกนหลัก (Major axis length) ความยาวแกนรอง (Minor axis length) ของวงรีที่ระบุขอบเขตของผลแก้วมังกรไม่รวมกลีบ (Inner Ellipse Lined) และวงรีที่ระบุขอบเขตของผลแก้วมังกรรวมกลีบ (Outer Ellipse Lined) นับจำนวนพิกเซลสีขาวของภาพ Center-Mask แทนพื้นที่ของผลแก้วมังกรที่ปรากฏในช่องศูนย์กลางของเส้นแบ่งแก้วช่อง และคำนวณค่าปริมาตรของผลแก้วมังกร

ด้วยรูปทรงของผลแก้วมังกรที่มีกลีบอยู่รอบผลทำให้ไม่สามารถระบุรูปทรงทางเรขาคณิตได้อย่างชัดเจนว่าเป็นรูปทรงใด การคำนวณปริมาตรของผลแก้วมังกรจึงคำนวณโดยการหาผลรวมของปริมาตรเฉพาะส่วนของผลแก้วมังกรซึ่งมีรูปทรงคล้ายทรงรีกับปริมาตรเฉพาะส่วนของกลีบที่ไม่สามารถระบุรูปทรงทางเรขาคณิตได้อย่างแน่ชัด ดังสมการที่ 3.20

$$\text{Dragon fruit Volume} = \text{Inner Ellipse Volume} + \text{Bract Volume} \quad (3.20)$$

จากสมการทั่วไปของปริมาตรทรงรีดังสมการที่ 3.21

$$\text{Ellipse Volume} = 4/3\pi * abc \quad (3.21)$$

โดย abc คือผลคูณของรัศมีทั้งสามแกนของทรงรี ซึ่งข้อมูลภาพที่ใช้ในการทดลองเป็นภาพ 2 มิติ ไม่สามารถระบุความยาวรัศมีครบทั้งสามแกนได้ แต่ด้วยผลแก้วมังกรที่ใช้ในการทดลองมีเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปทรงปกติ จึงอนุมานว่ารัศมีแกน a มีค่าเท่ากับความยาวแกนหลักของวงรี Inner Ellipse Lined ทหาร 2 และ รัศมีแกน b กับ c มีค่าเท่ากับความยาวแกนรองของวงรี Inner Ellipse Lined ทหาร 2 ดังนั้นปริมาตรเฉพาะส่วนของผลแก้วมังกร แทนด้วยปริมาตรของวงรี Inner Ellipse Lined สามารถคำนวณได้ดังสมการที่ 3.22

$$\text{Inner Ellipse Volume} = 4/3\pi * (MA_{\text{innerE}} / 2) * [(ma_{\text{innerE}}/2)]^2 \quad (3.22)$$

โดย MA_{innerE} คือความยาวแกนหลักของวงรี Inner Ellipse Lined, ma_{innerE} คือความยาวแกนรองของวงรี Inner Ellipse Lined

สำหรับการคำนวณปริมาตรเฉพาะส่วนของกลีบนั้นค่อนข้างเป็นเรื่องยากเพราะไม่สามารถระบุรูปทรงของกลีบได้อย่างชัดเจน อีกทั้งความยาวของกลีบแต่ละกลีบก็ไม่เท่ากัน ทิศทางของปลายกลีบก็แตกต่างกัน ดังนั้นหากหั่น (slice) ผลแก้วมังกรเป็นชั้นบางๆคล้ายกับกระดาษแผ่นบางๆที่วางซ้อนกันหลายชั้น ปริมาตรของกองกระดาษ (stack of papers) จะเท่ากับพื้นที่ของกระดาษแต่ละชั้นคูณความหนาของกองกระดาษ ดังนั้นปริมาตรเฉพาะส่วนของกลีบจะเท่ากับพื้นที่เฉพาะส่วนกลีบแก้วมังกรคูณความหนาของผลแก้วมังกร โดยพื้นที่เฉพาะส่วนกลีบแก้วมังกรมีค่าเท่ากับผลต่างของพื้นที่ผลแก้วมังกรทั้งหมด (Object Area) กับพื้นที่เฉพาะส่วนของผลแก้วมังกรไม่รวมกลีบ (Inner Ellipse Lined) ความหนาของผลแก้วมังกรมีค่าเท่ากับความยาวแกนรองของวงรี Outer Ellipse Lined รูปทรงของกลีบแก้วมังกรคล้ายทรงกรวย ทำให้พื้นที่ของกลีบแก้วมังกรแต่ละชั้นมีค่าไม่เท่ากัน ดังนั้นจึงกำหนดค่าสัมประสิทธิ์เท่ากับ 0.75 เพื่อลดทอนพื้นที่กลีบที่ขาดหายไปในช่วงปลายกลีบ ดังสมการที่ 3.23

$$\text{Bract Volume} = [(Area_{\text{object}} - Area_{\text{innerE}}) * ma_{\text{outerE}}] * 0.75 \quad (3.23)$$

โดย $Area_{\text{object}}$ คือพื้นที่ของผลแก้วมังกรทั้งหมด, $Area_{\text{innerE}}$ คือพื้นที่เฉพาะส่วนของผลแก้วมังกรไม่รวมกลีบมีค่าเท่ากับพื้นที่ของวงรี Inner Ellipse Lined และ ma_{outerE} คือความหนาของผลแก้วมังกรมีค่าเท่ากับความยาวแกนรองของวงรี Outer Ellipse Lined

3.3.3 การจำแนกคุณภาพแก้วมังกรไทยจากภาพ


จากรูปที่ 3.47 หลังจากกระบวนการแยกคุณลักษณะเรียบร้อยแล้ว กระบวนการต่อไปคือการจำแนกคุณภาพ (Quality Classification) ประกอบไปด้วยการจำแนกคุณภาพโดยการตรวจหาตำหนิ และการจำแนกขนาดของผลแก้วมังกรจากภาพ โดยใช้เทคนิคการสร้างกฎและเทคนิคการแยกคุณลักษณะตามเนื้อหาตามลำดับ ซึ่งมีรายละเอียดดังนี้

3.3.3.1 การจำแนกคุณภาพโดยการตรวจหาตำหนิโดยใช้เทคนิคการสร้างกฎ

จากมาตรฐานสินค้าการเกษตรที่ระบุไว้ว่าผลแก้วมังกรกลุ่มคุณภาพชั้นพิเศษ (Extra class) ต้องเป็นผลแก้วมังกรที่ไม่มีตำหนิที่ผิวและเปลือก หรือมีตำหนิที่มองเห็นได้ไม่ชัดเจน ผลแก้วมังกรกลุ่มคุณภาพชั้นหนึ่ง (Class I) และชั้นสอง (Class II) ต้องเป็นผลแก้วมังกรที่มีตำหนิที่ผิวและเปลือกโดยรวมไม่เกินร้อยละ 5 และร้อยละ 10 ของพื้นที่ผิวของแก้วมังกรตามลำดับ โดยทั้งสามกลุ่มนี้ต้องเป็นแก้วมังกรที่ยังคงมีความสดอยู่ถึงจะถูกจัดกลุ่มในสามชั้นเหล่านี้ได้ หากเป็นผลแก้วมังกรมีเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คุณภาพต่ำกว่าสามกลุ่มนี้ นั่นคือไม่มีความสดหรือมีตำหนิที่ผิวและเปลือกโดยรวมเกินร้อยละ 10 ของพื้นที่ผิวของแก้วมังกร ในงานวิจัยนี้จะถือว่าแก้วมังกรลักษณะนี้เป็นกลุ่มแก้วมังกรชั้นสาม (Class III) ซึ่งมีคุณภาพต่ำกว่ามาตรฐานที่กำหนดไว้

ดังนั้นการสร้างกฎเพื่อใช้จำแนกคุณภาพโดยการตรวจหาตำหนินั้น ผู้วิจัยใช้คุณลักษณะความสด (Freshness) และปริมาณตำหนิที่ผิวและเปลือกของแก้วมังกรเป็นร้อยละ (Defected Ratio) ในการสร้างกฎ ดังรูปที่ 3.55



รูปที่ 3.55 กฎการจำแนกคุณภาพโดยการตรวจหาตำหนิ

โดยในการทดลองจำแนกคุณภาพโดยการตรวจหาตำหนิโดยใช้กฎดังรูปที่ 3.55 ได้ทำทดลองกับชุดข้อมูลภาพทั้งหมดรวม 3,556 ภาพ และชุดข้อมูลจากการสุ่มตัวอย่างจากภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละชั้นคุณภาพดังแสดงในรูปที่ 3.9 และตารางที่ 3.4 คลาสละ 1,000 ภาพ คลาสใดมีจำนวนน้อยกว่าให้ทำการเพิ่มข้อมูลภาพด้วยเทคนิคการ Augmentation ในที่นี้ผู้วิจัยเลือกใช้ Rotation และ Flip ในการเพิ่มข้อมูลภาพ รวม 4,000 ภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.3.2 การจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา

สำหรับการจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหานี้ ผู้วิจัยดำเนินการแยกคุณลักษณะดังที่กล่าวไปแล้วในหัวข้อ 3.3.2.2 รวม 8 คุณลักษณะ ได้แก่ พื้นที่ของผลแก้วมังกร (Object Area) ความยาวรอบรูปของผลแก้วมังกร (Object Perimeter) ความยาวแกนหลัก (Major axis length) ความยาวแกนรอง (Minor axis length) ของวงรี Inner Ellipse Lined และวงรี Outer Ellipse Lined พื้นที่ของผลแก้วมังกรที่ปรากฏในช่องศูนย์กลางของเส้นแบ่งเก้าช่อง และปริมาตรของผลแก้วมังกร (Dragon fruit Volume)

โดยในการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหานี้ ได้ทำการสุ่มตัวอย่างจากชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละรหัสขนาดดังแสดงในรูปที่ 3.11 และตารางที่ 3.3 คลาสละ 1,000 ภาพ คลาสใดมีจำนวนน้อยกว่าให้ทำการเพิ่มข้อมูลภาพด้วยเทคนิคการ Augmentation ในที่นี้ผู้วิจัยเลือกใช้ Rotation และ Flip ในการเพิ่มข้อมูลภาพ ดังนั้นจะมีข้อมูลที่ใช้ในการทดลองจำนวน 6,000 ภาพ ซึ่งจะถูกนำมาแบ่งข้อมูลด้วยเทคนิคการแบ่งข้อมูลแบบ 10-folds Validation โดยแต่ละ Fold ประกอบไปด้วยข้อมูลภาพ 3 ชุด ได้แก่ ชุดฝึกหัด ชุดทดลองและชุดทดสอบ ในสัดส่วนร้อยละ 80 ร้อยละ 10 และร้อยละ 10 ของข้อมูลกลุ่มตัวอย่างที่สุ่มมาทั้งหมดตามลำดับ แล้วดำเนินการแยกคุณลักษณะดังที่กล่าวไว้ข้างต้น

ก่อนนำข้อมูลคุณลักษณะ (Features) ไปประมวลผล ได้ทำการปรับค่าสเกลของข้อมูลให้มีค่าในช่วง 0-1 ด้วย MinMaxScaler โดยใช้ข้อมูลชุดฝึกหัด (Train Set) เป็นเกณฑ์อ้างอิงในการปรับค่าของชุดทดลอง (Validate Set) และชุดทดสอบ (Test Set) ซึ่งมีแผนการทดลองใช้คุณลักษณะดังกล่าวกับวิธีการเรียนรู้ของเครื่องด้วย ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM), K-Nearest Neighbour (KNN) ต้นไม้ตัดสินใจ (Decision Tree : DT) Naïve Bayes (NB) และ Backpropagation เพื่อหาคุณลักษณะและวิธีการเรียนรู้ที่มีประสิทธิภาพในการจำแนกขนาดมากที่สุด ซึ่งสามารถสรุปแผนการทดลองได้ดังตารางที่ 3.8

ตารางที่ 3.8 แผนการทดลองการจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา

Algorithms	Detail
SVM	ทดลองโดยกำหนด kernel ที่แตกต่างกัน ได้แก่ linear, polynomial, RBF และ sigmoid
KNN	ทดลองโดยกำหนด distance ที่แตกต่างกัน ได้แก่ manhattan, euclidean, minkowski และ hellinger
NB	ใช้ค่าเริ่มต้นของ scikit-learn library
Backpropagation	กำหนดโครงสร้างของเครือข่ายให้ hidden layer เท่ากับ 8, learning_rate เท่ากับ 0.3 และจำนวนรอบของการฝึกหัดเท่ากับ 5000 รอบ
DT	ใช้ค่าเริ่มต้นของ scikit-learn library

3.4 การวัดประสิทธิภาพอัลกอริทึม (Performance Evaluation)

สำหรับการวัดประสิทธิภาพอัลกอริทึม พิจารณาจากตารางคอนฟิวชันเมทริกต์ (Confusion Matrix) ค่าความถูกต้อง (Accuracy) ค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) และนำเทคนิคการแบ่งข้อมูล k-fold Cross Validation (k=10) เพื่อช่วยแบ่งข้อมูลสำหรับการวัดประสิทธิภาพ โดยในแต่ละ Fold จะประกอบไปด้วยข้อมูลสำหรับการฝึกหัด (Train) ร้อยละ 80 ข้อมูลชุดทดลอง (Valid) ร้อยละ 10 และข้อมูลชุดทดสอบ (Test) ร้อยละ 10 มาใช้ในการวัดประสิทธิภาพอัลกอริทึม โดยแบ่งการวัดประสิทธิภาพออกเป็น 2 ส่วน ได้แก่ การวัดประสิทธิภาพอัลกอริทึมสำหรับจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ และการวัดประสิทธิภาพอัลกอริทึมสำหรับจำแนกคุณภาพของแก้วมังกรไทยจากภาพ ซึ่งแต่ละส่วนจะมีการวัดประสิทธิภาพย่อยตามกระบวนการทำงานของแต่ละอัลกอริทึมตามแผนการทดลองที่ออกแบบไว้ดังรูปที่ 3.12 และรูปที่ 3.47 ตามลำดับ โดยมีรายละเอียดดังตารางที่ 3.9

ตารางที่ 3.9 แผนการการวัดประสิทธิภาพอัลกอริทึม

รายการวัดประสิทธิภาพ	รายละเอียด
1. อัลกอริทึมสำหรับจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ	1) การวัดประสิทธิภาพของการการระบุประเภทของภาพ 2) การวัดประสิทธิภาพของการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก 3) การวัดประสิทธิภาพของการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา 4) การวัดประสิทธิภาพของการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการเรียนรู้เชิงลึก 5) สรุปผลการวัดประสิทธิภาพของการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ
2. อัลกอริทึมสำหรับจำแนกคุณภาพของแก้วมังกรไทยจากภาพ	1) การวัดประสิทธิภาพของการจำแนกคุณภาพโดยการตรวจหาตำหนิ 2) การวัดประสิทธิภาพของการจำแนกขนาดของผลแก้วมังกรจากภาพ 3) สรุปผลการวัดประสิทธิภาพของการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

ผลการวิจัยและการอภิปรายผล

จากวิธีการดำเนินงานวิจัยและแผนการทดลองที่นำเสนอในบทที่ 3 ผลการวิจัยของงานวิจัยนี้ จะถูกแบ่งเป็น 2 ส่วน ตามวัตถุประสงค์ของงานวิจัย ได้แก่ ผลการทดลองการจำแนกสายพันธุ์แก้ว มังกรไทยจากภาพ และผลการทดลองจำแนกคุณภาพของแก้วมังกรไทยจากภาพ โดยแต่ละส่วนจะมี ผลการทดลองย่อยตามกระบวนการของแผนการทดลองที่นำเสนอไว้ โดยมีรายละเอียดดังนี้

4.1 ผลการทดลองการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ

จากแผนการทดลองการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ ได้แบ่งการทดลองเพื่อประวัต ประสิทธิภาพอัลกอริทึมเป็น 4 การทดลอง ได้แก่ 1) การระบุประเภทของภาพ 2) การจำแนกกลุ่ม แก้วมังกรด้วยสีเปลือก 3) การจำแนกภาพแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะ ตามเนื้อหา และ 4) การจำแนกภาพแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการเรียนรู้เชิงลึก

4.1.1 ผลการทดลองการระบุประเภทของภาพ

เป็นการทดลองเพื่อระบุประเภทของภาพ โดยชุดข้อมูลภาพที่ใช้ในการทดลองมี 2 ประเภท ได้แก่ ภาพที่ถูกบันทึกในห้องปฏิบัติการ (Laboratory Image) และภาพที่ถูกบันทึกในสภาวะ แวดล้อมกลางแจ้ง (Outdoor Image) ในการทดลองได้ทดลองกับชุดข้อมูลที่ถูกสุ่มตัวอย่างจากภาพ แก้วมังกรประเภทละ 700 ภาพ (สายพันธุ์ละ 100 ภาพ) รวม 2 ประเภทเป็น 1,400 ภาพ เพื่อใช้ในการ ศึกษาคุณสมบัติทางสถิติของภาพแต่ละประเภท ได้แก่ ค่าเฉลี่ย (Mean) ค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) และความโด่ง (Kurtosis) ของฟังก์ชันพื้นหลังของภาพระดับเทา พร้อมทั้งทำ การทดลองกับข้อมูลทั้งหมด ผลการทดลองแสดงดังตารางที่ 4.1 พบว่ากระบวนการระบุประเภทของ ภาพที่นำเสนอในงานวิจัยนี้สามารถระบุประเภทของภาพได้ถูกต้อง 100.00%

ตารางที่ 4.1 ผลการทดลองการระบุประเภทของภาพ

ประเภทภาพ	จำนวนภาพ	ค่าความถูกต้อง (%)	จำนวนภาพ	ค่าความถูกต้อง (%)
Laboratory Image	700	100.00	9,754	100.00
Outdoor Image	700	100.00	9,067	100.00
Laboratory Image และ Outdoor Image	1,400	100.00	18,821	100.00

4.1.2 ผลการทดลองการจำแนกภาพแก้วมังกรด้วยสีเปลือก

เป็นการทดลองเพื่อจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก ชุดข้อมูลที่ใช้ในการทดลองแบ่งออกเป็น 2 กลุ่ม ได้แก่ กลุ่มเปลือกสีเหลืองและกลุ่มเปลือกสีแดง โดยใช้ชุดข้อมูลภาพทั้งภาพที่ถูกบันทึกในห้องปฏิบัติการและภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ด้วยวิธีการเตรียมข้อมูลที่แตกต่างกัน 3 รูปแบบ ได้แก่ การใช้ภาพต้นฉบับในการประมวลผล การใช้วิธีการตรวจจับตำแหน่งของผลแก้ว มังกรในภาพด้วยวิธีของ Fu, et al. (2019) ร่วมกับอัลกอริทึม Graph Cut และการเตรียมข้อมูลภาพ

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตามกระบวนการ Outdoor Pre-processing ที่นำเสนอไปแล้วในหัวข้อที่ 3.2.2 ผลการทดลองแสดงดังตารางที่ 4.2 และ 4.3

ตารางที่ 4.2 ผลการทดลองการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกของภาพที่ถูกบันทึกในห้องปฏิบัติการ

สายพันธุ์	จำนวนข้อมูล	ค่าความถูกต้อง(%)		
		Non-pre-processing	Fu. et al. (2019) and Graph Cut	Outdoor Pre-processing
พันธุ์ขาวจัมโบ้ (Jumbo White)	1,172	100.00	100.00	100.00
พันธุ์ขาวเวียดนาม (Vietnamese White)	1,190	100.00	100.00	100.00
พันธุ์ชมพูจินดา (Pink)	1,309	100.00	100.00	100.00
พันธุ์แดงสยาม (Siam Red)	1,869	100.00	100.00	100.00
พันธุ์แดงไต้หวัน (Taiwan Red)	1,184	100.00	100.00	100.00
พันธุ์แดงทับทิม (Ruby Red)	1,110	100.00	100.00	100.00
พันธุ์เหลืองอิสราเอล (Israel Yellow)	1,920	100.00	100.00	100.00
Total/Mean	9,754	100.00	100.00	100.00

ตารางที่ 4.3 ผลการทดลองการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกของภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง

สายพันธุ์	จำนวนข้อมูล	ค่าความถูกต้อง(%)		
		Non-pre-processing	Fu. et al. (2019) and Graph Cut	Outdoor Pre-processing
พันธุ์ขาวจัมโบ้ (Jumbo White)	1,241	94.44	100.00	100.00
พันธุ์ขาวเวียดนาม (Vietnamese White)	2,478	98.63	99.76	100.00
พันธุ์ชมพูจินดา (Pink)	1,013	100.00	100.00	100.00
พันธุ์แดงสยาม (Siam Red)	950	99.47	100.00	100.00
พันธุ์แดงไต้หวัน (Taiwan Red)	1,021	87.86	100.00	100.00

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.3 ผลการทดลองการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกของภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง (ต่อ)

สายพันธุ์	จำนวนข้อมูล	ค่าความถูกต้อง(%)		
		Non-pre-processing	Fu. et al. (2019) and Graph Cut	Outdoor Pre-processing
พันธุ์แดงทับทิม (Ruby Red)	871	99.20	100.00	100.00
พันธุ์เหลืองอิสราเอล (Israel Yellow)	1,493	99.80	100.00	100.00
Total/Mean	9,067	97.06	99.96	100.00

จากผลการทดลองดังตารางที่ 4.2 และ 4.3 พบว่ากระบวนการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกที่นำเสนอในงานวิจัยนี้ สามารถใช้จำแนกแก้วมังกรด้วยสีเปลือกได้ โดยภาพที่ถูกบันทึกในห้องปฏิบัติการทั้ง 3 รูปแบบ ให้ค่าความถูกต้อง 100.00% เท่ากันทั้งหมด แต่ต่างจากภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งที่อยู่ในรูปแบบของภาพต้นฉบับและภาพที่ได้จากวิธีการของ Fu. et al. (2019) ร่วมกับอัลกอริทึม Graph Cut มีค่าความถูกต้องน้อยกว่าภาพที่ถูกเตรียมข้อมูลด้วยกระบวนการ Outdoor Pre-processing ซึ่งให้ค่าความถูกต้อง 100.00%

ดังนั้นสรุปได้ว่ากระบวนการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกจะให้ผลลัพธ์สูงที่สุดก็ต่อเมื่อใช้ข้อมูลภาพที่มีรูปแบบแตกต่างกันขึ้นอยู่กับประเภทของภาพ หากเป็นภาพที่ถูกบันทึกในห้องปฏิบัติการสามารถใช้ภาพต้นฉบับในการจำแนกกลุ่มด้วยสีเปลือกได้โดยไม่ต้องผ่านการเตรียมข้อมูล หากเป็นภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งต้องใช้วิธีการเตรียมข้อมูลภาพด้วยกระบวนการ Outdoor Pre-processing ก่อนนำไปจำแนกกลุ่มด้วยสีเปลือก ซึ่งให้ค่าความถูกต้อง 100.00%

4.1.3 ผลการทดลองการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา

ในการทดลองการจำแนกสายพันธุ์ของแก้วมังกรจะเหลือเพียงกลุ่มข้อมูลภาพแก้วมังกรเปลือกสีแดงเท่านั้น เนื่องจากกระบวนการจำแนกกลุ่มแก้วมังกรด้วยสีเปลือกให้ค่าความถูกต้อง 100.00% ทำให้แก้วมังกรกลุ่มเปลือกสีเหลืองถูกจำแนกออกไปแล้ว ซึ่งในหัวข้อนี้จะนำเสนอผลการทดลองการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหา ชุดข้อมูลที่ใช้ในการทดลองมี 4 รูปแบบ ได้แก่ ชุดข้อมูล Laboratory ชุดข้อมูล Outdoor ชุดข้อมูล Mixdata1 และชุดข้อมูล Mixdata2 รายละเอียดระบุในตารางที่ 3.5 มีการแยกคุณลักษณะสี พื้นผิว รูปร่าง ขนาด ขอบและเส้น เพื่อใช้ในการทดลองหาคุณลักษณะและวิธีการเรียนรู้ที่มีประสิทธิภาพในการจำแนกมากที่สุด โดยการทดลองนี้เริ่มจากการทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Laboratory ซึ่งเรียกการทดลองนี้ว่า CBML Method ย่อมาจาก Content-Base and Machine Learning Method มีการเลือกใช้คุณลักษณะ 34 คุณลักษณะ ดังแสดงในตารางที่ 4.4 แบ่งชุดข้อมูลด้วย 10-folds Validation พร้อมทั้งมีการทดลองกับคุณลักษณะอื่นจากงานวิจัยของ Jana. et al. (2017) และ Muhammad (2014) เพื่อเปรียบเทียบประสิทธิภาพ แสดงผลการทดลอง

ได้ดังตารางที่ 4.5

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.4 คุณลักษณะที่ใช้ในการทดลองของ CBML Method

คุณลักษณะ	รายละเอียด	จำนวนคุณลักษณะ
สี (Colors)	ค่าเฉลี่ย (Mean), ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความเบ้ (Skewness) และความโด่ง (Kurtosis) ของช่องสัญญาณ R,G,B ของโมเดลสี RGB ช่องสัญญาณ H,S,V ของโมเดลสี HSV และช่องสัญญาณ a, b ของโมเดลสี Lab	32
พื้นผิว (Texture)	คุณสมบัติ Dissimilarity และ ASM จากอัลกอริทึม GLCM ของภาพ RGB เฉพาะทิศทาง 0°	2

ตารางที่ 4.5 ผลการทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Laboratory และคุณลักษณะของ CBML Method

อัลกอริทึม	ระยะทาง/เคอร์เนล	ค่าความถูกต้องเฉลี่ย (ร้อยละ) (SD.)								
		CBML 34 คุณลักษณะ สีและพื้นผิว			Jana. et al. (2017) 28 คุณลักษณะ สีและพื้นผิว			Muhammad (2014) 14 คุณลักษณะ พื้นผิวและรูปร่าง		
		Train	Valid	Test	Train	Valid	Test	Train	Valid	Test
SVM	Linear	91.22 (0.14)	90.90 (1.20)	90.75 (1.21)	83.12 (0.31)	82.65 (1.53)	82.55 (1.60)	57.36 (0.41)	56.12 (1.88)	56.65 (1.54)
	Polynomial	100.00 (0.00)	98.28 (0.42)	98.47 (0.62)	100.00 (0.00)	94.10 (1.14)	94.20 (1.06)	94.83 (0.69)	52.82 (2.23)	52.88 (2.22)
	RBF	92.86 (0.13)	92.33 (1.22)	92.50 (0.92)	87.25 (0.27)	86.17 (1.71)	86.22 (1.73)	62.87 (0.46)	58.98 (1.05)	59.23 (1.13)
	Sigmoid	38.97 (0.61)	38.85 (1.66)	38.75 (1.80)	21.59 (2.35)	21.62 (2.72)	21.87 (2.48)	11.32 (1.55)	11.12 (1.84)	11.30 (1.88)
k-NN	Manhattan	96.51 (0.15)	92.18 (0.89)	92.35 (1.09)	93.72 (0.32)	86.12 (1.32)	85.92 (1.36)	70.80 (0.66)	45.58 (0.94)	46.75 (1.51)
	Euclidean	96.89 (0.12)	92.87 (1.00)	93.23 (1.10)	94.01 (0.36)	87.00 (1.13)	86.87 (1.30)	69.64 (0.31)	45.67 (1.49)	45.13 (1.56)
	Minkowski	97.04 (0.14)	93.12 (0.96)	93.20 (1.01)	94.21 (0.38)	86.70 (1.24)	87.13 (0.99)	69.10 (0.63)	44.62 (1.10)	44.35 (1.61)
	Hellinger	97.05 (0.09)	93.02 (0.99)	92.82 (0.85)	94.25 (0.19)	86.68 (1.03)	86.62 (1.32)	67.19 (0.68)	39.73 (1.41)	40.63 (1.82)
	Chebyshev	93.46 (0.13)	92.18 (0.81)	91.90 (1.28)	93.90 (0.31)	85.93 (1.28)	86.00 (1.15)	67.94 (0.96)	42.27 (1.47)	41.17 (1.22)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.5 ผลการทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Laboratory และคุณลักษณะของ CBML Method (ต่อ)

อัลกอริทึม	ระยะทาง/ เคอร์เนล	ค่าความถูกต้องเฉลี่ย(ร้อยละ) (SD.)								
		CBML 34 คุณลักษณะ สีและพื้นผิว			Jana. et al. (2017) 28 คุณลักษณะ สีและพื้นผิว			Muhammad (2014) 14 คุณลักษณะ พื้นผิวและรูปร่าง		
		Train	Valid	Test	Train	Valid	Test	Train	Valid	Test
MDC (Selvaraj. et al., 2010)	Manhattan	61.95 (0.31)	61.63 (1.77)	62.08 (1.78)	54.99 (0.52)	54.88 (2.23)	55.10 (2.33)	42.95 (0.63)	43.00 (2.17)	43.27 (1.71)
	Euclidean	64.96 (0.26)	64.58 (1.65)	64.52 (1.50)	59.29 (1.10)	59.43 (2.77)	59.13 (2.42)	44.64 (0.72)	44.43 (1.53)	44.27 (1.76)
	Minkowski	65.77 (0.32)	65.60 (1.39)	65.57 (1.35)	61.16 (1.18)	60.80 (2.77)	60.70 (1.89)	43.80 (0.81)	43.02 (1.75)	43.98 (2.42)
	Hellinger	67.15 (8.74)	63.87 (1.84)	64.22 (1.68)	56.86 (2.05)	56.90 (3.46)	57.17 (2.51)	43.98 (0.52)	43.52 (2.29)	43.50 (3.21)
	Chebyshev	64.46 (0.45)	64.17 (1.54)	63.68 (2.27)	58.56 (2.46)	58.45 (3.27)	58.30 (2.67)	37.63 (0.67)	36.93 (1.97)	37.18 (1.89)
SVD (Elen and Avuçlu, 2021)	Manhattan	62.42 (0.41)	62.28 (2.03)	62.50 (1.97)	56.65 (0.45)	56.32 (2.56)	56.22 (2.58)	44.05 (0.74)	43.70 (2.06)	44.17 (2.05)
	Euclidean	63.88 (0.31)	63.72 (1.71)	63.88 (1.92)	58.89 (1.03)	59.07 (2.65)	58.70 (2.28)	44.60 (0.80)	44.38 (1.87)	44.50 (2.02)
	Minkowski	64.68 (0.26)	64.33 (1.79)	64.48 (1.64)	59.97 (0.96)	59.93 (2.65)	59.73 (1.87)	44.34 (0.66)	44.10 (2.28)	43.97 (2.16)
	Hellinger	63.90 (0.43)	63.60 (2.09)	64.08 (1.74)	57.73 (1.44)	57.80 (3.01)	57.70 (2.34)	45.06 (0.61)	45.43 (1.91)	45.00 (2.21)
	Chebyshev	69.62 (0.26)	66.43 (1.58)	66.43 (1.54)	60.86 (1.31)	60.87 (2.77)	60.58 (1.63)	43.09 (0.69)	42.48 (1.63)	42.47 (2.16)

จากผลการทดลองพบว่าการใช้ 34 คุณลักษณะสีและพื้นผิวของ CBML Method กับวิธีเรียนรู้ด้วยซัพพอร์ตเวกเตอร์แมชชีน Polynomial Kernel กำหนด degree เท่ากับ 8 ให้ประสิทธิภาพดีกว่าวิธีอื่น ให้ค่าความถูกต้องเฉลี่ยสำหรับชุดฝึกหัดเท่ากับร้อยละ 100.00 ± 0.00 ชุดทดสอบเท่ากับร้อยละ 98.28 ± 0.42 และชุดทดสอบเท่ากับร้อยละ 98.47 ± 0.62

หลังจากนั้น เพื่อพัฒนาโมเดลให้สามารถรองรับการประมวลผลกับภาพที่ถูกบันทึกในสถานะแวดล้อมกลางแจ้งด้วย จึงทำการทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูลที่เหลือ ได้แก่ ชุดข้อมูล Outdoor ชุดข้อมูล Mixdata1 และชุดข้อมูล Mixdata2 ซึ่งเรียกรวมการทดลองนี้ว่า DIP-CBML Method ย่อมาจาก Digital Image Processing and Content-Base and Machine Learning Method การมีการเลือกใช้คุณลักษณะ 29 คุณลักษณะ ดังแสดงในตารางที่ 4.6 แบ่งชุดข้อมูลด้วย 10-folds Validation กำหนดวิธีเรียนรู้ด้วยซัพพอร์ตเวกเตอร์แมชชีน Polynomial Kernel กำหนด degree เท่ากับ 11 เพื่อเปรียบเทียบประสิทธิภาพว่าคุณลักษณะแบบใดให้ประสิทธิภาพสูงกว่า แสดงผลการทดลองได้ ดังตารางที่ 4.7

ตารางที่ 4.6 คุณลักษณะที่ใช้ในการทดลองของ DIP-CBML Method

คุณลักษณะ	รายละเอียด	จำนวนคุณลักษณะ
สี (Colors)	ค่าเฉลี่ย (Mean), ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation), ความเบ้ (Skewness) และความโด่ง (Kurtosis) ของช่องสัญญาณ R,G,B ของโมเดลสี RGB ช่องสัญญาณ H ของโมเดลสี HSV และช่องสัญญาณ a, b ของโมเดลสี Lab	24
พื้นผิว (Texture)	คุณสมบัติ Dissimilarity Contrast และ ASM จากอัลกอริทึม GLCM ของภาพ RGB เฉพาะทิศทาง 0°	3
ขอบและเส้น (Edge and Line)	อัตราส่วนพิกเซลของขอบเฉพาะส่วนของผลแก้วมิงกรโดยการประมวลผลด้วยอัลกอริทึม Canny Edge และจำนวนของเส้นตรงโดยการประมวลผลอัลกอริทึม Hough Transform	2

ตารางที่ 4.7 ผลการทดลองจำแนกสายพันธุ์ของแก้วมิงกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Outdoor Mixdata1 และ Mixdata2

Method	ค่าความถูกต้องเฉลี่ย (ร้อยละ) (SD.)											
	Laboratory			Outdoor			Mixdata1			Mixdata2		
	Train	Valid	Test	Train	Valid	Test	Train	Valid	Test	Train	Valid	Test
CBML	100.00 (0.00)	98.28 (0.42)	98.47 (0.62)	99.83 (0.03)	95.17 (1.09)	94.82 (1.24)	99.90 (0.01)	96.54 (0.45)	96.38 (0.68)	99.91 (0.01)	95.98 (0.91)	95.88 (0.56)
DIP-CBML	100.00 (0.00)	97.58 (0.79)	97.85 (0.92)	100.00 (0.00)	94.27 (0.67)	94.00 (0.97)	100.00 (0.00)	95.32 (0.56)	95.53 (0.50)	100.00 (0.00)	95.00 (0.72)	95.05 (0.72)

จากผลการทดลองพบว่าเมื่อเปลี่ยนรูปแบบของชุดข้อมูลเป็นชุดข้อมูล Outdoor ชุดข้อมูล Mixdata1 และชุดข้อมูล Mixdata2 พบว่าประสิทธิภาพของ CBML Method ลดลง สังเกตได้จากค่าความถูกต้องของชุดฝึกหัดน้อยกว่าร้อยละ 100.00 แต่เมื่อนำคุณลักษณะของ DIP-CBML Method มาทดลองใช้กับข้อมูลทั้งสามรูปแบบ ผลที่ได้คือประสิทธิภาพในการจำแนกสูงขึ้น ค่าความถูกต้องของชุดฝึกหัดเท่ากับร้อยละ 100.00 ± 0.00 ทั้งสามชุดข้อมูล โดยค่าความถูกต้องของชุดทดสอบของชุดข้อมูล Outdoor เท่ากับร้อยละ 94.00 ± 0.97 ชุดข้อมูล Mixdata1 เท่ากับร้อยละ 95.53 ± 0.05 และชุดข้อมูล Mixdata2 เท่ากับร้อยละ 95.05 ± 0.72

นอกจาก DIP-CBML Method จะให้ผลลัพธ์ที่ดีกว่า CBML Method แล้ว จากผลการทดลองยังสรุปได้ว่าหากต้องการสร้างโมเดลสำหรับจำแนกสายพันธุ์ของแก้วมิงกรกลุ่มเปลือกสีแดงด้วยเทคนิคการแยกคุณลักษณะตามเนื้อหาที่สามารถรองรับการประมวลผลกับภาพทั้งสองประเภท การเตรียมข้อมูลภาพของภาพแต่ละประเภทเป็นสิ่งสำคัญ ส่งผลต่อประสิทธิภาพของโมเดลได้ ดังเช่นผลการทดลองในตารางที่ 4.7 พบว่าค่าความถูกต้องของชุดข้อมูล Mixdata1 ให้ค่าสูงกว่าชุดข้อมูล Mixdata2 นั้นหมายความว่าภาพที่ถูกบันทึกในห้องปฏิบัติการและภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งควรผ่านกระบวนการเตรียมข้อมูลภาพที่แตกต่างกัน จึงจะให้ผลลัพธ์ที่ดีกว่า

4.1.4 ผลการทดลองการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการเรียนรู้เชิงลึก

การทดลองจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยเทคนิคการเรียนรู้เชิงลึก ใช้โมเดล DIPDEEP ซึ่งเป็นโมเดลการเรียนรู้เชิงลึกที่พัฒนาขึ้นสำหรับใช้ในการทดลองนี้ พร้อมทั้งเปรียบเทียบประสิทธิภาพกับโมเดลอื่น โดยการทดลองถูกแบ่งเป็นการทดลองย่อย 2 การทดลอง เพื่อกำหนดค่าพารามิเตอร์ที่เหมาะสมให้กับโมเดล โดยมีผลการทดลองดังนี้

4.1.4.1 การทดลองย่อยที่ 1

เป็นการทดลองเพื่อเปรียบเทียบประสิทธิภาพของการเตรียมข้อมูลและโครงสร้างโมเดลการเรียนรู้เชิงลึกที่แตกต่างกันด้วยชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการทั้ง 7 สายพันธุ์ โดยการสุ่มตัวอย่างข้อมูลสายพันธุ์ละ 1,000 ภาพ แบ่งชุดข้อมูลด้วย 10-folds Validation ภาพทั้งหมดถูกเตรียมข้อมูลด้วยวิธีการที่แตกต่างกัน ได้แก่ วิธีการเตรียมข้อมูลที่น่าเสนอในหัวข้อที่ 3.2.1.1 และวิธีการเตรียมข้อมูลของ Muresan and Oltean (2018) พร้อมทั้งใช้ข้อมูลดังกล่าวทดลองกับโมเดลการเรียนรู้เชิงลึก DIPDEEP และโมเดลการเรียนรู้เชิงลึกของ Muresan and Oltean (2018) โดยกำหนด Epoch หลายแบบ ได้แก่ 10, 20, 30, 40, 50, 100, 300, 400 และ 500 epochs เพื่อทดลองว่า Epoch ใดจะเหมาะสมและได้ค่าความถูกต้องสูงสุด แสดงผลการทดลองได้ดังตารางที่ 4.8

ตารางที่ 4.8 การทดลองย่อยที่ 1

epochs	ค่าความถูกต้องเฉลี่ย (ร้อยละ) (SD.)					
	Muresan and Oltean (2018) method			DIPDEEP Method		
	Train	Valid	Test	Train	Valid	Test
10	97.41(1.00)	95.09(1.37)	94.49(1.03)	97.60(0.72)	95.59(0.83)	94.06(1.21)
20	99.64(0.59)	97.11(1.10)	96.46(1.05)	99.83(0.50)	97.81(0.75)	96.99(0.88)
30	100(0.00)	98.20(0.55)	97.70(0.47)	100(0.00)	98.74(0.52)	98.00(0.39)
40	100(0.00)	98.50(0.38)	97.66(0.36)	100(0.00)	98.71(0.46)	97.96(0.38)
50	100(0.00)	98.13(0.44)	97.49(0.60)	100(0.00)	98.61(0.55)	98.11(0.32)
100	100(0.00)	98.36(0.46)	97.56(0.89)	100(0.00)	98.74(0.27)	98.20(0.44)
300	100(0.00)	98.37(0.43)	97.60(0.84)	100(0.00)	98.71(0.56)	97.99(0.72)
400	100(0.00)	98.13(0.79)	97.39(0.60)	100(0.00)	98.67(0.53)	97.67(0.88)
500	97.65(5.65)	93.09(6.35)	77.33(21.49)	100(0.00)	96.21(2.27)	88.61(9.63)

จากผลการทดลองย่อยที่ 1 พบว่าวิธีการเตรียมข้อมูลและโมเดล DIPDEEP ให้ค่าความถูกต้องสูงสุดที่ Epoch เท่ากับ 100 ค่าความถูกต้องเท่ากับ 98.20 ± 0.44 ส่วนวิธีการเตรียมข้อมูลและโมเดลของ Muresan and Oltean (2018) ให้ค่าความถูกต้องสูงสุดที่ Epoch เท่ากับ 30 ค่าความถูกต้องเท่ากับ 97.70 ± 0.47 ซึ่งมีค่าความถูกต้องน้อยกว่าวิธีการของ DIPDEEP ดังนั้นในการทดลองอื่นๆ ควรใช้วิธีการเตรียมข้อมูลและโมเดล DIPDEEP และกำหนด Epoch เท่ากับ 100


4.1.4.2 การทดลองย่อยที่ 2

เป็นการทดลองเพื่อเปรียบเทียบประสิทธิภาพโครงสร้างโมเดลการเรียนรู้เชิงลึกของ DIPDEEP กับโมเดลอื่น ได้แก่ ResNet50 (He. et al., 2016) VGG16 (Simonyan and Zisserman, 2015) และ MobileNetV2 (Sandler. et al., 2018) โดยข้อมูลที่ใช้ในการทดลองเป็นชุดข้อมูลภาพแก้วม้งกรกลุ่มเปลือกสีแดง 6 สายพันธุ์ ที่ถูกจัดอยู่ในรูปแบบ 4 รูปแบบ รายละเอียดดังตารางที่ 3.5 แสดงผลการทดลองได้ดังตารางที่ 4.9 พบว่าชุดข้อมูล Laboratory ให้ผลการทดลองที่ชัดเจนกว่าชุดข้อมูลอื่น จากผลการทดลองระบุว่าโมเดล DIPDEEP มีประสิทธิภาพมากกว่าโมเดลอื่น ให้ค่าความถูกต้องเท่ากับร้อยละ 98.80±0.48 ในขณะที่การทดลองของชุดข้อมูลอื่นกับทุกโมเดลให้ค่าความถูกต้องสำหรับชุดฝึกหัดน้อยกว่าร้อยละ 100.00 ดังนั้นจากการทดลองทั้งหมด หากต้องการโมเดลสำหรับจำแนกสายพันธุ์ของแก้วม้งกรกลุ่มเปลือกสีแดงที่สามารถรองรับการประมวลกับภาพทั้งสองประเภทได้ เทคนิคการเรียนรู้เชิงลึกอาจจะไม่เหมาะสม

ตารางที่ 4.9 การทดลองย่อยที่ 2

ชุดข้อมูล		ค่าความถูกต้องเฉลี่ย(ร้อยละ) (SD.)			
		ResNet50	VGG16	MoBiLeNetV2	DIPDEEP
Laboratory	Train	99.73 (0.85)	100.00 (0.00)	86.56 (11.86)	100.00 (0.00)
	Valid	99.13 (1.64)	98.80 (0.32)	85.43 (12.36)	98.45 (0.62)
	Test	99.13 (1.65)	98.70 (0.41)	86.05 (11.85)	98.80 (0.48)
Outdoor	Train	93.27 (18.60)	99.81 (0.14)	73.56 (16.65)	99.80 (0.05)
	Valid	89.18 (18.15)	93.55 (1.46)	71.35 (16.75)	94.42 (0.72)
	Test	89.70 (18.00)	93.33 (1.70)	71.27 (15.63)	94.18 (1.25)
Mixdata1	Train	98.37 (3.20)	99.78 (0.32)	90.95 (5.30)	99.68 (0.31)
	Valid	95.58 (3.55)	95.32 (0.81)	88.53 (5.51)	95.02 (0.95)
	Test	95.98 (3.74)	95.35 (0.94)	88.98 (5.58)	94.96 (1.08)
Mixdata2	Train	95.26 (9.80)	99.69 (0.57)	70.44 (22.63)	99.66 (0.39)
	Valid	92.44 (9.97)	94.16 (1.40)	68.88 (21.86)	94.18 (1.40)
	Test	92.42 (10.58)	94.47 (1.23)	68.63 (21.94)	94.34 (0.93)

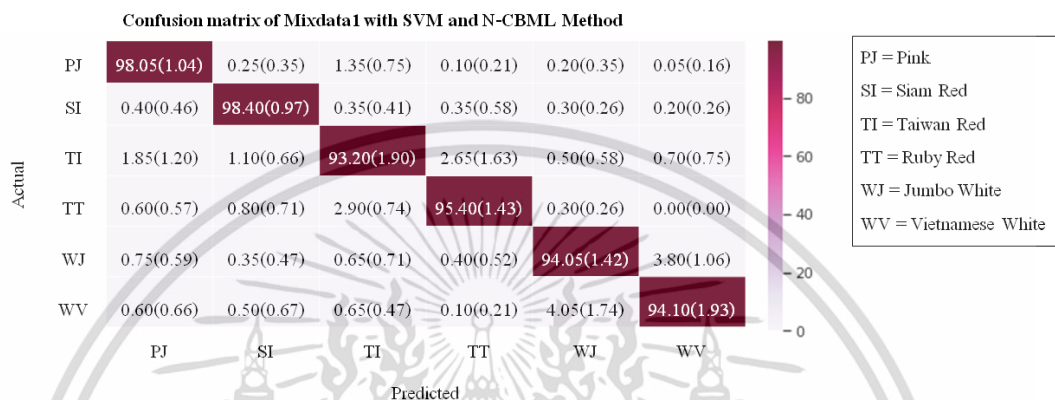
จากวัตถุประสงค์ของงานวิจัยนี้คือการพัฒนาอัลกอริทึมสำหรับจำแนกสายพันธุ์แก้วม้งกรไทย จากภาพ โดยสามารถรองรับการทำงานกับภาพ 2 ประเภท ได้แก่ ภาพที่ถูกบันทึกในห้องปฏิบัติการ และภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง ซึ่งจากผลการทดลองทั้งหมดสรุปได้ดังรูปที่ 4.1




รูปที่ 4.1 โมเดลการจำแนกสายพันธุ์แก้มังกรไทยจากภาพ

จากรูปที่ 4.1 จะเห็นว่าโมเดลที่ได้จะประกอบไปด้วย 1) การเก็บข้อมูลภาพ (Image Acquisition) 2) ระบุประเภทของภาพ (Image Type Identification) มีค่าความถูกต้อง 100.00% 3) การจำแนกกลุ่มแก้มังกรด้วยสีเปลือก (Red and Yellow Classification) มีค่าความถูกต้อง 100.00% 4) การลบพื้นหลังออกจากภาพ (Image Background Removal) 5) การแยกคุณลักษณะเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Feature Extraction) ด้วย N-CBML Method และ 6) การจำแนกสายพันธุ์โดยใช้เทคนิคแยกคุณลักษณะตามเนื้อหาและการเรียนรู้ด้วยซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) กำหนด kernel เป็นแบบ Polynomial และ degree เท่ากับ 11 ซึ่งให้ค่าความถูกต้องในการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพสูงกว่าวิธีอื่น มีค่าความถูกต้องเท่ากับร้อยละ 95.53 ± 0.50 สามารถแสดงประสิทธิภาพของโมเดลด้วยตารางคอนฟิวชันเมทริกซ์ได้ดังรูปที่ 4.2 มีค่าความแม่นยำเท่ากับ 0.955 ± 0.010 ค่าความระลึเท่ากับ 0.955 ± 0.020 และค่าความถ่วงดุลเท่ากับ 0.955 ซึ่งตัวอย่างการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพที่ให้ผลลัพธ์ไม่ถูกต้อง แสดงตัวอย่างได้ดังรูปที่ 4.3



รูปที่ 4.2 ตารางคอนฟิวชันเมทริกซ์ของการจำแนกสายพันธุ์ของแก้วมังกรกลุ่มเปลือกสีแดงด้วยชุดข้อมูล Mixdata1 และคุณลักษณะของ DIP-CBML Method



รูปที่ 4.3 ตัวอย่างการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพไม่ถูกต้อง

4.2 ผลการทดลองจำแนกคุณภาพของแก้วมังกรไทยจากภาพ

จากแผนการทดลองการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ ได้แบ่งการทดลองเพื่อประวัตประสิทธิภาพอัลกอริทึมเป็น 2 การทดลอง ได้แก่ 1) การจำแนกคุณภาพโดยการตรวจหาดำหนิ และ 2) การจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา

4.2.1 ผลการทดลองจำแนกคุณภาพโดยการตรวจหาดำหนิ

ในการทดลองใช้ข้อมูลภาพทั้งหมด จำนวน 3,556 ภาพ และภาพที่ได้จากการสุ่มตัวอย่างจากชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละชั้นคุณภาพ คลาสละ 1,000 ภาพ คลาสใดมีจำนวนน้อยกว่าให้ทำการ Rotation และ Flip เพื่อเพิ่มข้อมูลภาพ ดังนั้นจะมีข้อมูลที่ใช้ในการทดลองจำนวน 4,000 ภาพ ถูกนำไปทดลองกับกฎการจำแนกคุณภาพ ดังกล่าวไปแล้วในรูปที่ 3.55 โดยข้อมูลภาพถูกทดลองด้วยวิธีการที่น่าเสนอและวิธีการของ Trieu and Thinh (2021) แสดงผลการทดลองได้ดังตารางที่ 4.10 และ 4.11 พบว่ากฎที่น่าเสนอสำหรับจำแนกคุณภาพโดยการตรวจหาดำหนิที่ผิวและเปลือกของผลแก้วมังกรสามารถจำแนกคุณภาพได้ถูกต้อง 100.00%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.10 ผลการทดลองจำแนกคุณภาพโดยการตรวจหาตำหนิ

Quality code	Quality Class	ชุดข้อมูลภาพทั้งหมด		ชุดข้อมูลภาพจากการสุ่ม	
		จำนวนภาพ	ค่าความถูกต้อง (%)	จำนวนภาพ	ค่าความถูกต้อง (%)
C0	Extra Class	387	100.00	1,000	100.00
C1	Class I	513	100.00	1,000	100.00
C2	Class II	643	100.00	1,000	100.00
C3	No Quality	2,013	100.00	1,000	100.00

ตารางที่ 4.11 เปรียบเทียบผลการทดลองจำแนกคุณภาพโดยการตรวจหาตำหนิด้วยวิธีของ Trieu and Think (2021) และวิธีที่นำเสนอ

วิธีการ	ค่าความถูกต้อง(%)	
	ชุดข้อมูลภาพทั้งหมด	ชุดข้อมูลภาพจากการสุ่ม
Trieu and Think [12]	27.20	26.65
This approach	100.00	100.00

4.2.2 ผลการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา

ในการทดลองใช้ภาพที่ได้จากการสุ่มตัวอย่างจากชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการของแต่ละรหัสขนาด 6 ขนาด ขนาดละ 1,000 ภาพ คลาสใดมีจำนวนน้อยกว่าให้ทำการ Rotation และ Flip เพื่อเพิ่มข้อมูลภาพ ดังนั้นจะมีข้อมูลที่ใช้ในการทดลองจำนวน 6,000 ภาพ ถูกนำไปแยกคุณลักษณะขนาดและรูปร่าง 8 คุณลักษณะดังที่กล่าวไปแล้วในบทที่ 3 และทำการแยกคุณลักษณะด้วยวิธีการของ Fitri. et al. (2021) และ Fitri. et al. (2022) เพื่อเปรียบเทียบประสิทธิภาพ สามารถสรุปได้ดังตารางที่ 4.12 พร้อมทั้งทำการปรับค่าสเกลของข้อมูลให้มีค่าในช่วง 0-1 ด้วย MinMaxScaler แบ่งชุดข้อมูลด้วย 10-folds Validation ทดลองใช้คุณลักษณะดังกล่าวกับวิธีการเรียนรู้ของเครื่องด้วย ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM), K-Nearest Neighbour (KNN) ต้นไม้ตัดสินใจ (Decision Tree : DT) Naïve Bayes (NB) และ Backpropagation เพื่อหาคุณลักษณะและวิธีการเรียนรู้ที่มีประสิทธิภาพในการจำแนกขนาดมากที่สุด ซึ่งสามารถแสดงผลการทดลองได้ดังตารางที่ 4.13

ตารางที่ 4.12 คุณลักษณะที่ใช้ในการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพ

วิธีการ	คุณลักษณะ	โมเดลการจำแนก
Fitri. et al. (2021)	5 คุณลักษณะ ได้แก่ พื้นที่ (area) เส้นรอบรูป (perimeter) ความยาว (length) เส้นผ่านศูนย์กลาง (diameter) และ ค่าเมทริกซ์ (metric)	Backpropagation กำหนด โครงสร้างแบบ 5,8,5,3 learning rate เท่ากับ 0.05 และ learning 5000 รอบ
Fitri. et al. (2022)	4 คุณลักษณะ ได้แก่ พื้นที่ (area) เส้นรอบรูป (perimeter) ความยาว (length) และเส้นผ่านศูนย์กลาง (diameter)	Backpropagation กำหนด โครงสร้างแบบ 4,8,3 learning rate เท่ากับ 0.3 และ learning 5000 รอบ
This approach	8 คุณลักษณะ ได้แก่ พื้นที่ของผลแก้วมังกร (Object Area) ความยาวรอบรูปของผลแก้วมังกร (Object Perimeter) ความยาวแกนหลัก (Major axis length) ความยาวแกนรอง (Minor axis length) ของวงรี Inner Ellipse Lined และวงรี Outer Ellipse Lined พื้นที่ของผลแก้วมังกรที่ปรากฏในช่องศูนย์กลางของเส้นแบ่งเก้าช่อง และปริมาตรของผลแก้วมังกร (Dragon fruit Volume)	Decision tree with the default value of the scikit-learn library

ตารางที่ 4.13 ผลการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา

อัลกอริทึม	Distance/Kernel	Mean (SD.)								
		Fitri. et al. (2021)			Fitri. et al. (2022)			This approach		
		Train	Valid	Test	Train	Valid	Test	Train	Valid	Test
SVM	Linear	38.43 (0.27)	38.22 (1.87)	38.00 (1.99)	37.99 (0.40)	37.68 (1.33)	37.85 (1.42)	82.89 (0.39)	82.65 (1.54)	82.62 (1.45)
	Polynomial	39.53 (0.22)	34.82 (1.31)	35.23 (1.48)	38.57 (0.27)	34.05 (1.40)	33.98 (1.66)	91.84 (0.32)	88.03 (0.75)	88.20 (1.09)
	RBF	45.35 (0.36)	44.07 (1.60)	44.18 (1.62)	45.35 (0.43)	44.13 (1.22)	44.00 (1.30)	89.03 (0.30)	88.42 (0.94)	88.28 (0.89)
	Sigmoid	11.16 (0.83)	11.08 (1.24)	11.15 (1.15)	10.59 (0.64)	10.60 (1.60)	10.55 (1.46)	3.48 (0.17)	3.48 (0.65)	3.48 (0.70)

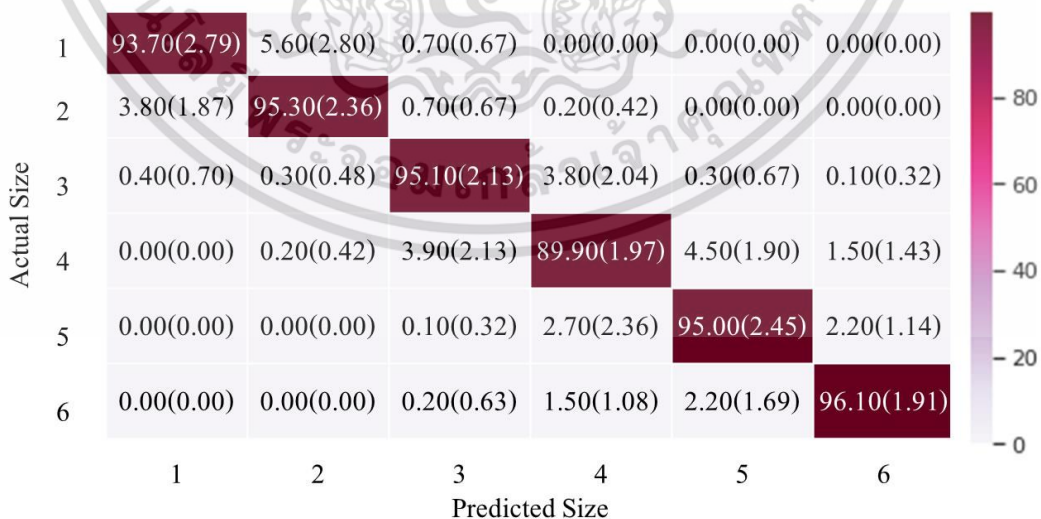
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.13 ผลการทดลองจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหา (ต่อ)

อัลกอริทึม	Distance/ Kernel	Mean (SD.)								
		Fitri. et al. (2021)			Fitri. et al. (2022)			This approach		
		Train	Valid	Test	Train	Valid	Test	Train	Valid	Test
KNN	Manhattan	66.40 (0.46)	40.63 (1.09)	41.33 (1.75)	66.30 (0.75)	40.82 (1.06)	41.52 (1.49)	98.16 (0.19)	95.15 (0.68)	95.18 (0.93)
	Euclidean	65.17 (0.44)	39.70 (1.70)	40.33 (1.39)	65.16 (0.44)	40.13 (1.74)	40.75 (1.48)	97.79 (0.21)	94.52 (0.36)	94.43 (0.68)
	Minkowski	65.10 (.38)	39.07 (1.71)	39.20 (1.27)	64.79 (0.37)	39.52 (1.50)	39.45 (1.16)	97.67 (0.18)	94.42 (0.46)	94.15 (0.61)
	Hellinger	65.47 (0.38)	40.10 (2.31)	40.18 (1.83)	65.67 (0.38)	40.47 (1.54)	40.47 (1.62)	98.13 (0.16)	95.07 (0.67)	95.18 (0.78)
	Chebyshev	65.08 (0.37)	38.65 (1.52)	38.88 (1.74)	64.63 (0.37)	38.80 (1.56)	39.37 (1.25)	97.17 (0.24)	93.52 (0.56)	93.35 (0.59)
NB	-	46.11 (0.35)	40.98 (1.34)	41.55 (0.98)	39.62 (0.25)	39.52 (1.65)	39.42 (1.63)	77.06 (0.35)	76.93 (1.25)	76.97 (1.24)
Backpropagation (Fitri. et al., 2022)	-	23.18 (0.00)	23.28 (0.02)	23.32 (0.02)	26.51 (0.00)	26.63 (0.01)	26.55 (0.01)	33.33 (0.00)	33.33 (0.00)	33.33 (0.00)
DT	-	91.12 (0.00)	49.75 (2.06)	49.10 (2.47)	100.00 (0.00)	53.97 (1.96)	54.02 (2.15)	100.00 (0.00)	93.63 (1.05)	94.18 (0.88)

จากผลการทดลองพบว่าการใช้ 8 คุณลักษณะขนาดและรูปร่างที่นำเสนอ ดังตารางที่ 4.12 กับวิธีเรียนรู้ด้วยต้นไม้ตัดสินใจ (Decision Tree : DT) กำหนดพารามิเตอร์ด้วยค่าเริ่มต้นของ Scikit-Learn Library ซึ่งให้ประสิทธิภาพดีกว่าวิธีการเรียนรู้อื่น ให้ค่าความถูกต้องเฉลี่ยสำหรับชุดฝึกหัดเท่ากับร้อยละ 100.00 ± 0.00 ชุดทดสอบเท่ากับ ร้อยละ 93.63 ± 1.05 และชุดทดสอบเท่ากับร้อยละ 94.18 ± 0.88 สามารถแสดงตารางคอนฟิวชันเมทริกซ์ได้ดังรูปที่ 4.4

Confusion matrix of Size Classification with Decision Tree



รูปที่ 4.4 ตารางคอนฟิวชันเมทริกซ์ของการจำแนกขนาดของผลแก้วมังกรจากภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยต้นไม้ตัดสินใจที่ได้มีความลึก (depth) 19 ชั้น มี Leaf Node จำนวน 276 โหนด ดังแสดงในรูปที่ 4.5


```

|--- Center_mask <= 0.67
|   |--- Object_Area <= 0.44
|   |   |--- Center_mask <= 0.33
|   |   |   |--- Inner_ma <= 0.24
|   |   |   |   |--- Center_mask <= 0.23
|   |   |   |   |   |--- Object_Perimeter <= 0.51
|   |   |   |   |   |   |--- Inner_MA <= 0.18
|   |   |   |   |   |   |   |--- Center_mask <= 0.15
|   |   |   |   |   |   |   |   |--- class: 0
|   |   |   |   |   |   |   |   |--- Center_mask > 0.15
|   |   |   |   |   |   |   |   |   |--- Outer_ma <= 0.02
|   |   |   |   |   |   |   |   |   |   |--- Inner_MA <= 0.09
|   |   |   |   |   |   |   |   |   |   |   |--- class: 1
|   |   |   |   |   |   |   |   |   |   |   |--- Inner_MA > 0.09
|   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_MA <= 0.16
|   |   |   |   |   |   |   |   |   |   |   |   |   |--- truncated branch of depth 3
|   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_MA > 0.16
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- truncated branch of depth 2
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Outer_ma > 0.02
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Object_Area <= 0.18
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_ma <= 0.22
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 1
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_ma > 0.22
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 0
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Object_Area > 0.18
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_ma <= 0.21
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 0
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_ma > 0.21
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 1
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_MA > 0.18
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Center_mask <= 0.22
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Object_Perimeter <= 0.07
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 2
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_ma <= 0.56
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Outer_MA <= 0.01
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 5
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Outer_MA > 0.01
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 4
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_ma > 0.56
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 5
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Object_Perimeter > 0.20
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 4
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_MA > 0.60
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 5
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- DF_VOLUME > 0.02
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 5
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Center_mask > 0.78
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 4
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Inner_ma > 0.64
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Object Area <= 0.26
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- DF_VOLUME <= 0.01
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 5
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- DF_VOLUME > 0.01
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 4
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Object Area > 0.26
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 5
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Center_mask > 0.78
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Center_mask <= 1.00
|   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 5
|   |   |   |   |   |   |   |   |   |   |   |--- Center_mask > 1.00
|   |   |   |   |   |   |   |--- class: 4

```

รูปที่ 4.5 ตัวอย่างต้นไม้ตัดสินใจที่ได้จากการทดลอง
 เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้เผยแพร่ไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางคอนฟิวชันเมทริกต์ในรูปที่ 4.4 พบว่าในกรณีที่การจำแนกขนาดของผลแก้วมังกร จากภาพที่ให้ผลลัพธ์ไม่ถูกต้องนั้น ส่วนใหญ่จะจำแนกขนาดเป็นขนาดใกล้เคียง เช่น แก้วมังกรขนาด รหัส 1 ซึ่งเป็นขนาดใหญ่ที่สุด โมเดลจำแนกผิดเป็นแก้วมังกรขนาดรหัส 2 หรือขนาดรหัส 2 จำแนกผิดเป็นขนาดรหัส 1 อาจเป็นเพราะแก้วมังกรบางผลมีกลีบหนาใหญ่ น้ำหนักที่ชั่งได้บางส่วนอาจมาจากกลีบที่อยู่รอบเปลือกของผลแก้วมังกรด้วย ทำให้โมเดลทำนายขนาดเล็กกว่าหรือใหญ่กว่าขนาดจริง โดยตามมาตรฐานสินค้าเกษตรเพื่อการส่งออกแก้วมังกรของไทยระบุว่า อนุญาตให้มีความคลาดเคลื่อนเรื่องขนาดได้ โดยแก้วมังกรทุกรหัสขนาดอาจมีแก้วมังกรที่ขนาดใหญ่หรือเล็กกว่าชั้นถัดไปหนึ่งชั้นปนมาได้ไม่เกิน 10% ของจำนวนหรือน้ำหนักของแก้วมังกร ดังนั้นจากผลการทดลองนี้สามารถแสดงตัวอย่างการจำแนกขนาดผิดได้ดังรูปที่ 4.6



รูปที่ 4.6 ตัวอย่างการจำแนกขนาดของผลแก้วมังกรจากภาพไม่ถูกต้อง

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

จากการดำเนินงานวิจัยเรื่องการจำแนกสายพันธุ์และคุณภาพของแก้วมังกรไทยจากภาพ โดยมีวัตถุประสงค์เพื่อสร้างชุดข้อมูลภาพแก้วมังกรไทย เพื่อพัฒนาอัลกอริทึมสำหรับการจำแนกสายพันธุ์และจำแนกคุณภาพของแก้วมังกรไทยจากภาพ ให้สอดคล้องกับมาตรฐานสินค้าเกษตรเพื่อการส่งออกแก้วมังกรของไทย พบว่าชุดข้อมูลภาพแก้วมังกรไทยที่ได้มานี้ สามารถนำมาใช้กับกระบวนการประมวลผลภาพดิจิทัลได้ และสามารถนำมาใช้ในการเรียนรู้เพื่อพัฒนาอัลกอริทึมสำหรับการจำแนกสายพันธุ์และอัลกอริทึมสำหรับการจำแนกคุณภาพของแก้วมังกรไทยจากภาพได้ โดยการจำแนกด้วยกฎ (Rule Based Classifiers) และจำแนกด้วยการแยกคุณลักษณะตามเนื้อหา (Content-based)

ผลการทดลองระบุว่าโมเดลของการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ ดังแสดงในตารางที่ 5.1 ประกอบไปด้วย 1) การเก็บข้อมูลภาพ (Image Acquisition) ที่มีทั้งการบันทึกภาพในห้องปฏิบัติการ (Laboratory Image) และการบันทึกภาพในสภาวะแวดล้อมกลางแจ้ง (Outdoor Image) 2) ระบุประเภทของภาพ (Image Type Identification) ด้วยการสร้างกฎจากคุณสมบัติทางสถิติของภาพแต่ละประเภท ให้ค่าความถูกต้อง 100.00% 3) การจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก (Red and Yellow Classification) ด้วยการสร้างกฎจากค่าร้อยละของสีเหลือง (Yellow Ratio) และสีแดง (Red Ratio) ซึ่งสามารถจำแนกได้ถูกต้อง 100.00% 4) การลบพื้นหลังออกจากภาพ (Image Background Removal) ซึ่งข้อมูลภาพที่บันทึกในห้องปฏิบัติการ และภาพในสภาวะแวดล้อมกลางแจ้ง มีกระบวนการลบพื้นหลังออกจากภาพที่แตกต่างกัน 5) การแยกคุณลักษณะ (Feature Extraction) ด้วย DIP-CBML Method ซึ่งประกอบไปด้วยคุณลักษณะสี พื้นผิว ขอบและเส้น จำนวน 29 คุณลักษณะ และ 6) การจำแนกสายพันธุ์ (Species Classification) โดยใช้เทคนิคแยกคุณลักษณะตามเนื้อหาด้วยซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) ซึ่งสามารถจำแนกเฉพาะชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการมีความถูกต้อง 98.80% ชุดข้อมูลภาพเฉพาะที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้งมีความถูกต้อง 94.00% และชุดข้อมูลภาพที่รวมทั้งภาพที่ถูกบันทึกในห้องปฏิบัติการและสภาวะแวดล้อมกลางแจ้งมีถูกต้อง 95.53%

สำหรับโมเดลการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ ดังแสดงในตารางที่ 5.1 ประกอบไปด้วย 1) การเก็บข้อมูลภาพ (Image Acquisition) โดยการบันทึกภาพในห้องปฏิบัติการ (Laboratory Image) ซึ่งถูกนำไปกำกับป้าย (Label) เพื่อใช้จำแนกคุณภาพโดยการตรวจหาตำหนิและการจำแนกผลแก้วมังกรตามขนาด 2) การเตรียมข้อมูลภาพ (Pre-processing) เพื่อใช้จำแนกคุณภาพโดยการตรวจหาตำหนิและการจำแนกผลแก้วมังกรตามขนาด ซึ่งมีกระบวนการที่ต่างกัน 3) การแยกคุณลักษณะ (Feature Extraction) จากคุณลักษณะสี ขนาดและรูปร่าง และ 4) จำแนกคุณภาพของแก้วมังกรไทยจากภาพ (Quality Classification) ด้วยการจำแนกคุณภาพโดยการตรวจหาตำหนิ ซึ่งสามารถจำแนกได้ถูกต้อง 100.00% และการจำแนกขนาดของผลแก้วมังกรจากภาพโดยใช้เทคนิคการแยกคุณลักษณะตามเนื้อหาด้วยต้นไม้ตัดสินใจ (Decision Tree : DT) กำหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พารามิเตอร์ด้วยค่าเริ่มต้นของ Scikit-Learn Library โดยต้นไม้ตัดสินใจที่ได้มีความลึก (depth) 19 ชั้น มี Leaf Node จำนวน 276 โหนด สามารถจำแนกได้ถูกต้อง 94.18%

ตารางที่ 5.1 โมเดลของการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ

โมเดลของการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพ			
โมเดลของการจำแนกสายพันธุ์		โมเดลการจำแนกคุณภาพ	
ส่วนประกอบโมเดล	ข้อมูลและวิธีการ	ส่วนประกอบโมเดล	ข้อมูลและวิธีการ
1) การเก็บข้อมูลภาพ (Image Acquisition)	Laboratory Image	1) การเก็บข้อมูลภาพ (Image Acquisition)	Laboratory Image
	Outdoor Image		
2) ระบุประเภทของภาพ (Image Type Identification)	Rule Based Classifiers	2) การเตรียมข้อมูลภาพ (Pre-processing)	Pre-processing of Defect Detection
			Pre-processing of Size Classification
3) การจำแนกกลุ่มแก้วมังกรด้วยสีเปลือก (Red and Yellow Classification)	Rule Based Classifiers	3) การแยกคุณลักษณะ (Feature Extraction)	สี และรูปร่าง
4) การลบพื้นหลังออกจากภาพ (Image Background Removal)	Laboratory Image และ Outdoor Image ใช้วิธีการที่แตกต่างกัน	4) จำแนกคุณภาพ (Quality Classification)	Rule Based Classifiers
5) การแยกคุณลักษณะ (Feature Extraction)	สี พื้นผิว ขอบและเส้น (DIP-CBML Method)		
6) การจำแนกสายพันธุ์ (Species Classification)	SVM (Polynomial Kernel กำหนด degree=11)	4.2) การจำแนกขนาด	Decision Tree

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2 ข้อจำกัดและข้อเสนอแนะ

ด้วยคุณค่าของแก้วมังกรที่เป็นผลไม้ที่มีประโยชน์ มีคุณค่าทางโภชนาการสูง และเป็นพืชเศรษฐกิจชนิดหนึ่งที่สามารถสร้างรายได้ให้กับเกษตรกรไทยได้ แต่ด้วยผลผลิตที่ได้ของแต่ละพื้นที่ในประเทศไทยมีจำนวนมากน้อยไม่เท่ากัน ส่งผลต่อราคาขาย พื้นที่ที่มีผลผลิตน้อยจะมีราคาสูงกว่าพื้นที่ที่มีผลผลิตมาก ในขณะที่มีต้นทุนในการเพาะปลูกเท่ากัน ดังนั้นงานวิจัยนี้จึงถูกพัฒนาขึ้น ด้วยความคาดหวังว่าจะช่วยเพิ่มมูลค่าให้ผลผลิตแก้วมังกรสด มีราคาเท่าเทียมกันทุกพื้นที่ ด้วยการนำเสนออัลกอริทึมสำหรับการจำแนกสายพันธุ์และการจำแนกคุณภาพของแก้วมังกรไทยจากภาพ ที่สอดคล้องกับมาตรฐานสินค้าเกษตรเพื่อการส่งออกแก้วมังกรของไทย

หากเกษตรกรสามารถจำแนกสายพันธุ์แก้วมังกรและจำแนกคุณภาพของผลผลิตได้อย่างถูกต้อง จะช่วยส่งเสริมการบริหารจัดการผลผลิตแก้วมังกรได้ ไม่ว่าจะเป็นการดูแลรักษาผลผลิตหลังเก็บเกี่ยว การจัดการลักษณะการขนส่ง การรักษาคุณภาพผลผลิตให้เป็นไปตามข้อกำหนดของการนำเข้าและส่งออก ซึ่งส่งผลต่อต้นทุนและราคาขายได้ อีกทั้งในภาคอุตสาหกรรม หากมีเครื่องมือช่วยตรวจสอบคุณภาพผลแก้วมังกรแทนการตรวจพินิจและประสาทสัมผัสของมนุษย์ ช่วยลดแรงงานและความเสี่ยงต่อความผิดพลาดในการจำแนกคุณภาพของผลผลิตได้ นอกจากนี้อาจนำไปสู่การพัฒนานวัตกรรมเพื่อเป็นเครื่องมือให้บุคคลที่เลือกบริโภคแก้วมังกรแค่บางสายพันธุ์ เนื่องจากมีอาการแพ้หรือเลือกซื้อแก้วมังกรตามความชื่นชอบส่วนตัวของแต่ละบุคคลได้ และที่สำคัญอาจช่วยลดความเสี่ยงจากกลุ่มมิจฉาชีพ เช่น การหลอกลวงขายแก้วมังกรผิดสายพันธุ์ด้วยราคาที่ไม่เหมาะสม

จากตารางที่ 5.1 โมเดลที่ได้จากผลการวิจัยนี้ ใช้เทคนิคการจำแนกด้วยกฎ (Rule Based Classifiers) และเทคนิคการจำแนกด้วยการแยกคุณลักษณะตามเนื้อหา (Content-based) ซึ่งให้ผลลัพธ์ที่ดีกว่าการใช้เทคนิคการจำแนกด้วยโมเดลการเรียนรู้เชิงลึก (Deep learning) อาจเนื่องจากโมเดลการเรียนรู้เชิงลึกที่ใช้ในการทดลอง มีโครงสร้างที่ยังไม่สามารถดึงคุณลักษณะของชุดข้อมูลภาพได้เพียงพอต่อการจำแนก ซึ่งอาจมีการพัฒนาโครงสร้างใหม่เพื่อเพิ่มประสิทธิภาพได้ในอนาคต

สำหรับโมเดลของการจำแนกสายพันธุ์แก้วมังกรไทยจากภาพที่ได้จากการวิจัยนี้ สามารถรองรับการประมวลผลได้ทั้งชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการและชุดข้อมูลภาพที่ถูกบันทึกในสภาวะแวดล้อมกลางแจ้ง แตกต่างจากโมเดลของการจำแนกคุณภาพของแก้วมังกรไทยจากภาพสามารถประมวลผลได้กับชุดข้อมูลภาพที่ถูกบันทึกในห้องปฏิบัติการเท่านั้น หากโมเดลสามารถประมวลผลกับภาพในสภาวะแวดล้อมกลางแจ้งได้ อาจเป็นผลดีกับเกษตรกรในการดูแลรักษาผลผลิตก่อนเก็บเกี่ยวให้ได้คุณภาพตามมาตรฐานก่อนส่งต่อไปยังภาคอุตสาหกรรม

ในกระบวนการแยกคุณลักษณะของการจำแนกคุณภาพของผลแก้วมังกรด้วยการคำนวณค่าปริมาตรของผลแก้วมังกรเพื่อระบุขนาดตามมาตรฐานของไทย ซึ่งการคำนวณนี้ใช้หลักการเปรียบเทียบกับรูปทรงวงรี โดยผลการคำนวณเป็นการประมาณการ ดังนั้นหากนำไปใช้ในการคำนวณปริมาตรของผลไม้ชนิดอื่นที่ไม่สามารถระบุรูปร่างทางเรขาคณิตได้อย่างชัดเจน อาจได้ผลลัพธ์คลาดเคลื่อนได้

นอกจากนี้ชุดข้อมูลภาพที่ใช้ศึกษาในงานวิจัยนี้ใช้ชุดข้อมูลเพียงแค่ภาพของผลแก้วมังกรเท่านั้น หากนำไปใช้กับผลไม้ชนิดอื่น หรือชุดข้อมูลภาพอื่น อาจส่งผลต่อประสิทธิภาพของโมเดลได้ ดังนั้นอาจมีการพัฒนาโมเดลเพื่อรองรับการประมวลผลกับผลไม้ชนิดอื่นได้ในอนาคต

บรรณานุกรม

- กานต์ อู่ยวิรัช. 2552. การวัดประสิทธิภาพของโมเดล (Two-class prediction). [Online]. Available : <https://www.kanouivirach.com/2009/11/ประสิทธิภาพของโมเดล>.
- กฤติยา ไชยนอก. 2559. “จุดสารข้อมูลสมุนไพรมานาน 33 ปีที่ 4.” กรุงเทพฯ : สำนักงานข้อมูลสมุนไพรคณะเภสัชศาสตร์ มหาวิทยาลัยมหิดล.
- โกเมศ อัมพวัน. 2561. Data mining—การทำเหมืองข้อมูล บทที่ 6 การจำแนกประเภทและการทำนาย (Classification and Prediction). [Online]. Available : <https://staff.informatics.buu.ac.th/~komate/886464/%5B6%5D-Classification.pdf>.
- ไกรศักดิ์ เกษร. 2565. จากเหมืองข้อมูลแบบเดิมสู่เหมืองข้อมูลเชิงความหมาย บทที่ 6 โครงข่ายประสาทเทียมอัจฉริยะ. [Online]. Available : <https://csit.nu.ac.th/kraisak/sdm/contents/Chapter06.pdf>.
- กอบเกียรติ สระอุบล. 2563. เรียนรู้ data science และ AI : machine learning ด้วย python. กรุงเทพฯ : มีเดีย เนทเวิร์ค.
- จักรกฤษ อ่อนชื่นจิตร และ จักรี ศรีนนท์ฉัตร. 2562. “การเปรียบเทียบเทคนิคการแบ่งส่วนภาพสำหรับตรวจคุณภาพแผ่นวงจรพิมพ์.” วารสารวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่. 26(3) : 224-235.
- ชิตพงษ์ กิตตินราดร. 2563. Neural Network Algorithm. [Online]. Available : <https://guopai.github.io/ml-blog14.html>.
- นพรุจ พัฒนสาร และ ณีรัฐฉวี ศรีวิบูลย์. 2563. “การประมวลผลภาพสำหรับการจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์โดยการจำลองการมองเห็นของมนุษย์ด้วยวิธีการเรียนรู้เชิงลึก.” *Journal of Information Science and Technology*. 10(1) : 24-29.
- นฤมล มานีพพาน. 2537. แก้วมังกร DRAGON FRUIT. กรุงเทพฯ : เพชรกระรัต.
- ปภังกร อินแก้ว. 2564. เอกสารประกอบการสอนกระบวนวิชา 204123 วิทยาการข้อมูลเบื้องต้น (Introduction to Data Science). เชียงใหม่ : หน่วยพิมพ์เอกสาร งานบริการการศึกษา และพัฒนาคณาจารย์นักศึกษา คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่.
- วิภาวรรณ บัวทอง. 2557. Chapter 8 Clustering K-Means. [Online]. Available : <https://wipawanblog.files.wordpress.com/2014/06/chapter-8-clustering-k-means.pdf>.
- สุทธิสินี หักกะยานนท์. 2543. ไม้ผลเศรษฐกิจ. กรุงเทพฯ : นานาสาส์.
- สนั่น ศรีสุข. 2556. การประมวลผลภาพขั้นสูง. กรุงเทพฯ : มหาวิทยาลัยเทคโนโลยีมหานคร.
- สุภาสพงษ์ รุ่งทำนอง. 2555. หลักการจำแนกข้อมูลภาพเชิงวัตถุ (object base image analysis). [Online]. Available : <https://www.gotoknow.org/posts/492648>.
- สุรพงษ์ โกสิยะจินดา. 2556. “แก้วมังกร.” สารานุกรมไทยสำหรับเยาวชน. เล่มที่ 38 : 106-139.
- อมรเดช ศิริพัฒนานนท์. 2563. สร้าง AI ด้วย rule-based หรือ Machine Learning ต่างกันยังไง. [Online]. Available : <https://makeitonline.in.th/2020/ai-rule-based-or-machine-learning>.

เอกสารนี้เป็นเอกสารเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บรรณานุกรม (ต่อ)

- Abdulateef, S. K. and Salman, M. D. 2021. "A Comprehensive Review of Image Segmentation Techniques." *Iraqi Journal for Electrical and Electronic Engineering*. 17(2) : 166-175.
- Awasthi, S. 2020. **Seven Most Popular SVM Kernels**. [Online]. Available : <https://dataaspirant.com/svm-kernels/>.
- Bani, N. T. and Ershad, F. S. 2019. "Content-based image retrieval based on combination of texture and colour information extracted in spatial and frequency domains." *The Electronic Library*. 37(4) : 650-66.
- Beetsma, J. 2020. **The CIELAB L*a*b* System – the Method to Quantify Colors of Coatings**. [Online]. Available : <https://knowledge.ulprospector.com/10780/pc-the-cielab-lab-system-the-method-to-quantify-colors-of-coatings/>.
- Burger, W. and Burge M. J. 2009. **Principles of Digital Image Processing Fundamental Techniques**. New York : Springer Undergraduate Topics in Computer Science – UTiCS.
- Canny, J. 1986. "A Computational Approach to Edge Detection." *IEEE Transactions on Pattern Analysis and Machine Intelligence*. PAMI-8(6) : 679-698.
- Cecotti, H. Rivera, A. Farhadloo, M. and Pedroza, M. A. 2020. "Grape detection with convolutional neural networks." *Expert Systems with Applications*. 159 : 113588.
- Chen, J. Shan, S. He, C. Zhao, G. Pietikainen, M. Chen, X. and Gao, W. 2010. "WLD: A robust local image descriptor." *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 32(9) : 1705-1720.
- Dalpiaz, D. 2020. **Basics of Statistical Learning Chapter 9 Binary Classification**. [Online]. Available : <https://statisticallearning.org/binary-classification.html>.
- De Luna, R. G. Dadios, E. P. Bandala, A. A. and Vicerra, R. R. P. 2019. "Size Classification of Tomato Fruit Using Thresholding, Machine Learning and Deep Learning Techniques." *AGRIVITA Journal of Agricultural Science*. 41(3) : 586-596.
- Department of agricultural extension, Ministry of Agriculture and Cooperatives. 2020. **Agricultural production information service system**. [Online]. Available : <https://production.doae.go.th/service/site/login>.
- Dubey, S. R. Dixit, P. Singh, N. and Gupta, J. P. 2013. "Infected fruit part detection using k-means clustering segmentation technique." *International Journal of Artificial Intelligence and Interactive Multimedia*. 2(2) : 65-72.
- Elen, A. and Avuçlu, E. 2021. "Standardized Variable Distances: A distance-based machine learning method." *Applied Soft Computing*. 98 : 106855.

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ภายใต้การสงวนลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี โดยสงวนสิทธิ์ในชื่อและเครื่องหมายการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บรรณานุกรม (ต่อ)

- Elgendy, M. 2020. **Deep Learning for Vision Systems**. 1st Edition. New York : Manning.
- Fitri, Z. E. Baskara, A. Madjid, A. and Imron, A. M. N. 2022. “Comparison of Classification for Grading Red Dragon Fruit (*Hylocereus costaricensis*).” *Jurnal Nasional Teknik Elektro*. 11(1) : 43-49.
- Fitri, Z. E. Baskara, A. Silvia, M. Madjid, A. and Imron, A. M. N. 2021. “Application of backpropagation method for quality sorting classification system on white dragon fruit (*Hylocereus undatus*).” in **Proceedings of the 3rd International Conference on Food and Agriculture, IOP Conference Series: Earth and Environmental Science**. East Java : IOP Publishing.
- Fu, L. Duan, J. Zou, X. Lin, G. Song, S. Ji, B. and Yang, Z. 2019. “Banana detection based on color and texture features in the natural environment.” *Computers and Electronics in Agriculture*. 167 : 105057.
- Fu, Y. Nguyen, M. Zou, and Yan, W. Q. 2022. “Grading Methods for Fruit Freshness Based on Deep Learning.” *SN Computer Science*. 3 : 264.
- Goenaga, R. Marrero, A. and Perez, D. 2020. “Yield and Fruit Quality Traits of Dragon Fruit Cultivars Grown in Puerto Rico.” *Horttechnology*. 30(6) : 803-808.
- Gonzalez, R. C. and Woods, R. E. 1992. **Digital image processing**. , Boston : Addison-Wesley.
- Gonzalez, R. C. Woods, R. E. and Eddins, S. L. 2004. **Digital image processing using Matlab**. New Jersey : Pearson Prentice Hall.
- Hameed, K., Chai, D., and Rassau, A., 2018. “A comprehensive review of fruit and vegetable classification techniques.” *Image and Vision Computing*. 80 : 24-44.
- Hamza, R. and Chtourou, M. 2020. “Design of fuzzy inference system for apple ripeness estimation using gradient method.” *IET Image Processing*. 14(3) : 561-569.
- Harikant, S. 2021. **K Fold Cross Validation Technique**. [Online]. Available : <https://blog.ineuron.ai/K-Fold-Cross-Validation-Technique-NCaSO8Kmfh>.
- Haralick, R. M., Shanmugam, K. and Dinstein, I. 1973. “Textural Features for Image Classification.” *IEEE Transactions on Systems, Man, and Cybernetics*. SMC-3(6) : 610-621.
- He, K. Zhang, X. Ren, S. and Sun, J. 2016. “Deep Residual Learning for Image Recognition.” 770-778. in **Proceedings of the IEEE conference on computer vision and pattern Recognition (CVPR)**. Las Vegas : IEEE.
- Hough, P.V.C. 1962. “A Method and Means for Recognizing Complex Patterns.” *U.S. Patent 3,069,654*. Dec.18.

บรรณานุกรม (ต่อ)

- Jana, S. Basak, S. and Parekh, R. 2017. "Automatic fruit recognition from natural images using color and texture features." 620–624. in **Proceedings of 2nd International Conference on 2017 Devices for Integrated Circuit, DevIC 2017**. Kalyani: IEEE.
- Joseph, L. 2012. **How to convert RGB to HSV using OpenCV**. [Online]. Available : <http://www.technolabsz.com/2012/08/how-to-convert-rgb-to-hsv-using-opencv.html>.
- Krishna, M. M., Neelima, M., Harshali, M., and Rao, M. V. G. 2018. "Image classification using Deep learning." *International Journal of Engineering & Technology*. 7(2.7) : 614-617.
- Li, X. Jiang, G. Zhang, A. and Chen, J. Y. 2017. "A photograph-based approach for visual simulation of wrapped Jacquardtronic lace." *Textile Research Journal*. 88(23) : 1-11.
- Magalhães, D. S. Silva, D. M. Ramos, J. D. Pio, L. A. S. Pasqual, M. Boas, E. V. B. V. Galvão, E. C. and Melo, E. T. 2019. "Changes in the physical and physico chemical characteristics of red pulp dragon fruit during its development." *Scientia Horticulturae*. 253 : 180-186.
- Marques, O. 2011. **Practical image and video processing using MATLAB**. New Jersey : Wiley-IEEE Press.
- Masithoh, R. E. Tampani, H. and Sutiarsa, L. 2013. "Detection of White Dragon Fruits (*Hylocereus Undatus*) in Outdoor Environment Using Image Processing Technique." *Australian Journal of Basic and Applied Sciences*. 7(9) : 254-260.
- Momeny, M. Jahanbakhshi, A. Jafarnejhad, K. and Zhangd, Y. 2020. "Accurate classification of cherry fruit using deep CNN based on hybrid pooling approach." *Postharvest Biology and Technology*. 166 : 111204.
- Muhammad, G. 2014. "Automatic date fruit classification by using local texture descriptors and shape-size features." 174–179. in **Proceedings - UKSim-AMSS 8th European Modelling Symposium on Computer Modelling and Simulation, EMS 2014**. Pisa: IEEE.
- Mukhopadhyay, P. and Chaudhuri, B. B. 2015. "A survey of Hough Transform." *Pattern Recognition*. 48(3) : 993-1010.
- Muresan, H. and Oltean, M. 2018. "Fruit recognition from images using deep learning." *Acta Aniversitatis Sapientiae Informatica*. 10(1) : 26-42.

บรรณานุกรม (ต่อ)

- Narendra, V. G. and Pinto, A. J. 2020. “Defects detection in fruits and vegetables using image processing and soft computing techniques.” 325-337. in **Proceedings of 6th International Conference on Harmony Search, Soft Computing and Applications**. Istanbul: Springer.
- National Bureau of Agricultural Commodity and Food Standards, Ministry of Agriculture and Cooperatives. 2015. **Thai agricultural standard : Dragon fruit**. [Online]. Available : <https://www.acfs.go.th/standard/download/eng/DRAGON-FRUIT-ENG.pdf>.
- Nidhi, B. 2022. **Rule Based Data Mining Classifier: A Comprehensive Guide 101**. [Online]. Available : <https://hevodata.com/learn/rule-based-data-mining/>.
- Opencv Python Tutorials. 2016. **Canny Edge Detection**. [Online]. Available : https://opencv24-python-tutorials.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_canny/py_canny.html.
- Opencv Python Tutorials. 2016. **Changing Colorspaces**. [Online]. Available : https://opencv24-python-tutorials.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_colorspaces/py_colorspaces.html.
- Opencv Python Tutorials. 2016. **Hough Line Transform**. [Online]. Available : https://opencv24-python-tutorials.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_houghlines/py_houghlines.html.
- Osako, Y. Yamane, H. Lin, S. Y. Chen, P. A. and Tao, R. 2020. “Cultivar discrimination of litchi fruit images using deep learning.” *Scientia Horticulturae*. 269 : 109360.
- Parekh, R. 2021. **Fundamentals of image, audio, and video processing using Matlab®: with applications to pattern recognition**. First Edition. Florida : CRC Press (Taylor and Francis group).
- Park, Y. and Guldmann, J. M. 2020. “Measuring continuous landscape patterns with Gray-Level Co-Occurrence Matrix (GLCM) indices: An alternative to patch metrics?.” *Ecological Indicators*. 109 : 105802.
- Perween, T. Mandal, K. and Hasan, M. 2018. “Dragon fruit: An exotic super future fruit of India.” *Journal of Pharmacognosy and Phytochemistry*. 7(2) : 1022-1026.
- Phuangsaikai, N. Jakmune, J. and Kittiwachana, S. 2021. “Investigation into the predictive performance of colorimetric sensor strips using RGB, CMYK, HSV, and CIELAB coupled with various data preprocessing methods: a case study on an analysis of water quality parameters.” *Journal of Analytical Science and Technology*. 12(19) : 1-16.

บรรณานุกรม (ต่อ)

- Przybyłek, S. and Cena, C. 2021. **What is a Color Model? - Uses & Definition.** [Online]. Available : <https://study.com/academy/lesson/what-is-a-color-model-uses-definition.html>.
- Ramella, G. and Baja, G. S. D. 2013. “A new technique for color quantization based on histogram analysis and clustering.” *International Journal of Pattern Recognition and Artificial Intelligence.* 27(3) : 1360006-1-17.
- Reyes, J. F. Contreras, E. Correa, C. and Melin, P. 2021. “Image analysis of real-time classification of cherry fruit from colour features.” *Journal of Agricultural Engineering.* 52(4) : 1-6.
- Rosebrock, A. 2021. **OpenCV Color Spaces (cv2.cvtColor).** [Online]. Available : <https://pyimagesearch.com/2021/04/28/opencv-color-spaces-cv2-cvtColor/>.
- Samek, W. Montavon, G. Lapuschkin, S. Anders, C. J. Müller, K. R. 2021. “Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications.” *Proceedings of the IEEE.* 109(3) : 247-278.
- Sandler, M. Howard, A. Zhu, M. Zhmoginov, A. and Chen, L. C. 2019. “MobileNetV2: Inverted Residuals and Linear Bottlenecks.” 4510-4520. in **2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition.** Salt Lake City : IEEE.
- Schmidhuber, J. 2015. “Deep Learning in Neural Networks: An Overview.” *Neural Networks.* 61 : 85-117.
- Selvaraj, A. Shebiah, N. Nidhyanthan, S. and Ganesan, L. 2010. “Fruit Recognition using Color and Texture Features.” *Journal of Emerging Trends in Computing and Information Sciences.* 1(2) : 90-94.
- Shwartz, S. S. and David, S. B. 2014. **Understanding Machine Learning - From Theory to Algorithms.** First Edition. New York : Cambridge University Press.
- Simonyan, K. and Zisserman, A. 2015. “Very deep convolutional networks for large-scale image recognition.” 398-406. in Bengio, Y. and Lecun, Y. **3rd International Conference on Learning Representations ICLR 2015 - Conference Track Proceedings.** 75. 6. San Diego : n.p..
- Socret, L. 2020. **Lines Detection with Hough Transform.** [Online]. Available : <https://towardsdatascience.com/lines-detection-with-hough-transform-84020b3b1549>.

บรรณานุกรม (ต่อ)

- Tait, K. A., Khan, J. S., Alqahtani, F., Shah, A. A., Khan, F. A., Rehman, R. U., Boulila, W., and Ahmad, J. 2021. "Intrusion Detection using Machine Learning Techniques: An Experimental Comparison." 1-10. in **2021 International Congress of Advanced Technology and Engineering (ICOTEN)**. Taiz : Yemeni Scientists Research Group (YSRG) and Hadramout University.
- Trieu, N. M., and Thinh, N. T. 2021. "Quality Classification of Dragon Fruits Based on External Performance Using a Convolutional Neural Network." *Applied sciences*. 11(22) : 10558.
- Trivellini, A. Lucchesini, M. Ferrante, A. Massa, D. Orlando, M. Incrocci, L. and Mensuali-Sodi, A. 2020. "Pitaya, an Attractive Alternative Crop for Mediterranean Region." *Agronomy*. 10(8) : 1065.
- Wichienchot, S. Jatupornpipat, M. and Rastall, R. A. 2010. "Oligosaccharides of pitaya (dragon fruit) flesh and their prebiotic properties." *Food Chemistry*. 120(3) : 850-857.



ภาคผนวก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก
ผลงานที่ได้รับการตีพิมพ์



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

DIPDEEP: Classification for Thai dragon fruit

Naruwan Yusamran and Nualsawat Hiransakolwong*

Department of Computer Science, Faculty of Science, King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand

Received 5 December 2021

Revised 5 February 2022

Accepted 25 February 2022

Abstract

Thai dragon fruit is an interesting fruit with beautiful colors and high nutritional value, which can be used for food and pharmaceutical. In Thailand, there are 7 species of dragon fruits. Its skin can be divided into red or yellow groups, but inside can be divided into white, red or pink groups. If farmers know the species of dragon fruits, they can export fruits at a good price. Most people are unable to distinguish species of the dragon fruits. This paper is focus on classifying species of dragon fruits from images using digital image processing and deep learning called DIPDEEP. The DIPDEEP method has three steps; color space transformation, calculation ratio of the yellow and red color, classification using the deep learning method. First, the Thai dragon fruit images were classified into yellow (1 species) out from red (6 species). The Thai red dragon fruit was resized into 100x100 pixel resolutions in the pre-processing step only 6 species. Then, the red class was sent to classify again using the deep learning method. The experiments were processed in a dataset with 9,754 dragon fruit images on a black background (laboratory), and 10,072 images of dragon fruits at outdoor environment (outdoor). The results showed that accuracy of classification between the red and yellow dragon fruit for laboratory and outdoor datasets was 100% and 95.26%, respectively. The red dragon fruit is classified its species with accuracy 98.80%. The DIPDEEP has the smallest file size, and can save workload time because of separating yellow skin out at first step.

Keywords: Dragon fruit, Classification, Digital image processing, Deep learning

1. Introduction

A dragon fruit is a fruit of the cactus family, having high nutritional value utilized [1]. In Thailand, dragon fruits are traded in both domestic and international markets. During the epidemic situation of COVID-19, trading of dragon fruits and its branches continues unaffected. They can trade through social media.

National Bureau of Agricultural Commodity and Food Standards, the Ministry of Agriculture and Cooperatives of Thailand, has classified the dragon fruits into 3 main groups, which have differences in its peel color and the fruit pulp inner color; namely Group 1 for red skin with white flesh (*Hylocereus undatus*), Group 2 for red skin with red flesh (*Hylocereus polyrhizus*) or red skin with pink flesh (*Hylocereus* spp.), and group 3 for yellow or gold skin with white flesh (*Hylocereus* sp. and *Selenicereus* sp.). For export packaging sold with good price, the species of dragon fruit must be identified on the label attached to the front of the package [2]. There are 7 species of Thai dragon fruits, Loei province located at the top of the northeastern region of Thailand can harvest the most dragon fruits [3]. Group 1, there are two species; Jumbo White and Vietnamese White. Group 2, there are four species; Pink, Siam Red, Taiwan Red, and Ruby Red. Group 3, there is only one species called Israel Yellow. Most farmers know only the color of the skin and the pulp. They will sell their harvest to middlemen separated dragon fruits into 3 main groups, but they could not identify its species.

For this reason, the domestic trading price of each type of dragon fruit was determined only according to three main groups. If farmers can classify species of dragon fruits, they will learn how to manage dragon fruits, and how to take care for transportation according to the characteristics of each species that affect the cost and selling price. An academic or an expert farmer required a lot of knowledge and expertise will be able to distinguish species from morphological characteristics. Normally, people are unable to distinguish the species of dragon fruits correctly. Especially the Groups 1 and 2 all of which have the same red skin. This may make a mistake in separating the groups because at the time of purchase cannot see the inside. They may be classified fruit pulp in wrong color, affected the reliability and sale price to consumers or factories. Someone who allergy with specific species could not avoid.

This paper is focus on classifying species of dragon fruits from images using digital image processing and deep learning called DIPDEEP, which is a difference from the classification with specific characteristics such as branches, flowers and fruits [1]. The remainder of this paper presents the relevant researches in section 2, the DIPDEEP algorithm in section 3, the dataset and experimental results in section 4, and the remarkable conclusions in section 5.

เอกสารนี้เป็นเอกสารสิทธิ์สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

*Corresponding author. Tel.: +668 1405 7819

Email address: nualsawat.hi@kmitl.ac.th

doi: 10.14456/easr.2022.51

2. Theory and literature review

2.1 Color theory

Color in RGB model is a color system formed by mixing three color channels, red, green, and blue. Each channel has a color scale from 0-255. For example, RGB (245, 102, 36) represent an orange color [4]. Color in HSV model approximates the human perception of color. They include Hue (H), Saturation (S), and Value (V). H is a color tone indicated by the angle of the color wheel, which ranges from 0° to 360°. S is the color saturation value. V is the color brightness value. In OpenCV image processing, the H ranges is used in half values. The S and V values range from 0-255. If both values are set to 255, the color tones are clearly displayed. For example, Red Pure has HSV (0, 255, 255), et [5]. Color in LAB model consists of three components: L is the lightness value from black to white, A is the green gradation to red and B is the blue gradation to yellow. In image processing with OpenCV, LAB values are adjusted in the range 0-255 [4].

2.2 Digital image processing

A digital image can be represented by a function of two variables: $F(x, y)$ where x and y are spatial coordinates, each of which is called a pixel. The F value is in range 0-255. Grayscale image consists of one channel and for color images consists of RGB, HSV, or LAB as described in color theory. Digital Image Processing is the process of taking the color value of each pixel for the intended purposes; image resizing, color converting, data augmentation, or other techniques such as removing the background from an image to reduce noise, etc. [6]

2.3 Feature extraction

Feature extraction selects image features that help identify specific characteristics of all images. There are color, shape, texture, or others expected to be used as criteria for characterizing [6] or searching or sorting images similarly [7, 8]. Of course, the image data may not be the only characteristic that can be characterized. The feature vector, a 1-dimensional array, was used to replace the processing of every pixel of the image data [6]. Characterization generally consists of two parts: feature extraction and similarity measurement [8], both of which must be analyzed and tested to verify validity. The end result may use one or more attributes based on experimental results.

2.4 Deep learning

Deep learning is one of the most popular automated machine learning methods. Provides high predictive performance work as a black box [9] to mimic the work of human neurons by building a neural network with a layer of nonlinear processing overlaid multiple layers [6, 10]. Each layer takes the result of the previous layer as input. The model helps distinguish features automatically. The researcher prepare only information for learning. This makes a lot of convenience for the researchers. There are many researches using Deep learning.

2.5 Literature review

Many previous researches in classification from images have 4 steps: data acquisition, data pre-processing, feature extraction, and then classification [11]. Color, shape, texture, or other features are expected to be used as criteria for finding or sorting similar images [7, 8]. Of course, image data may not contain just one feature that is different. For examples, there are using texture and color properties for image retrieval [12], using apple skin color to assess ripening of apples according to their maturity stage [13], as well as using color features in the classification of cherries by [14].

Deep learning is one of the most popular automated machine learning methods. The highlight of this technique is that it supports classification with fuzzy attributes. The model helps distinguish features automatically. [15] The effectiveness of the deep learning model was tested in detecting white and red grapes by training with 11 architectures, such as Alexnet, Densenet201, Googlenet, InceptionResNetV2, InceptionV3, ResNet18, ResNet50, ResNet101, SqueezeNet, VGG16 and VGG19. It was found that the suitable deep learning model for the detection of white grapes was ResNet50 and red grapes was ResNet101. Therefore, a deep learning model to classify these two grapes should use modified ResNet. In addition, ResNet50 is the winner of ILSVRC 2015 in classification task [16], compared to the performance of VGG16 models that won first and second place in ILSVRC 2014 in localization and classification task respectively [17]. The VGG16 gets less accurate in detecting grapes [15], but it's an interesting model with an 8 times reduction in the number of layers.

The VGG16 model is used in [18] to identify 4 varieties of Taiwan lychee. The results showed that VGG16 was able to identify lychees with an average accuracy of 98.33%. Although the performance of the VGG16 model [18] did not compare with other models, all experimental results confirmed the performance of the deep learning model very well.

With the evolving technology MobileNetV2 [19], a smaller model, was developed to support the smaller mobile applications, limited computing resources but the performance is still satisfactory. Fruit recognition from images using deep learning presented experimental results for training a CNN to classify many kinds of fruits using Fruits-360 dataset [20]. Food image can be classified by user interactive identify segmentation input boundary and classify using support vector machine [21]. The paper run experiments on Food 101 dataset.

A binary image is used as a criterion to segment cherry fruit from background and then used CNN to classify regular or irregular shaped cherries. The efficiency was compared with the use of KNN, ANN, Fuzzy, and Ensemble Decision Trees (EDT) to classify regular and irregular cherries from the histogram of gradient (HOG) and Local binary pattern (LBP) surface characteristics. The experiment found that CNN was able to correctly identify 99.4% of regular and irregular cherries [22].

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. The DIPDEEP algorithm

This paper presents algorithms to classify species of dragon fruits automatically called DIPDEEP, consisting of a main program, sub-programs. The program reads a dragon fruit image, and then the result is its species. The DIPDEEP stands for implementation with digital image processing and deep learning. The main program of DIPDEEP (old version) is shown as Figure 1(a). Since the dragon fruit can be distinguished the yellow skin color of the Israel yellow species from the other 6 species with red skin. This paper use the main program of DIPDEEP (new version) as shown in Figure 1(b). This version can reduce classification time.

A subprogram, Calculate Ratio of Yellow and Red color, calculates the ratio of yellow color and the ratio of red color in an image, shown as Figure 2. Then, if the ratio of yellow is greater than the ratio of red, it will be the Israel yellow species and exit. Otherwise, the program will continue a subprogram, Preprocessing, made clear image shown as Figure 3. Then crop the image to a size of 100x100 pixels and come through a subprogram, Classify only 6 Classes of red, using a deep learning model set parameters as shown in Table 1 to distinguish 6 species of red-peel dragon fruit.

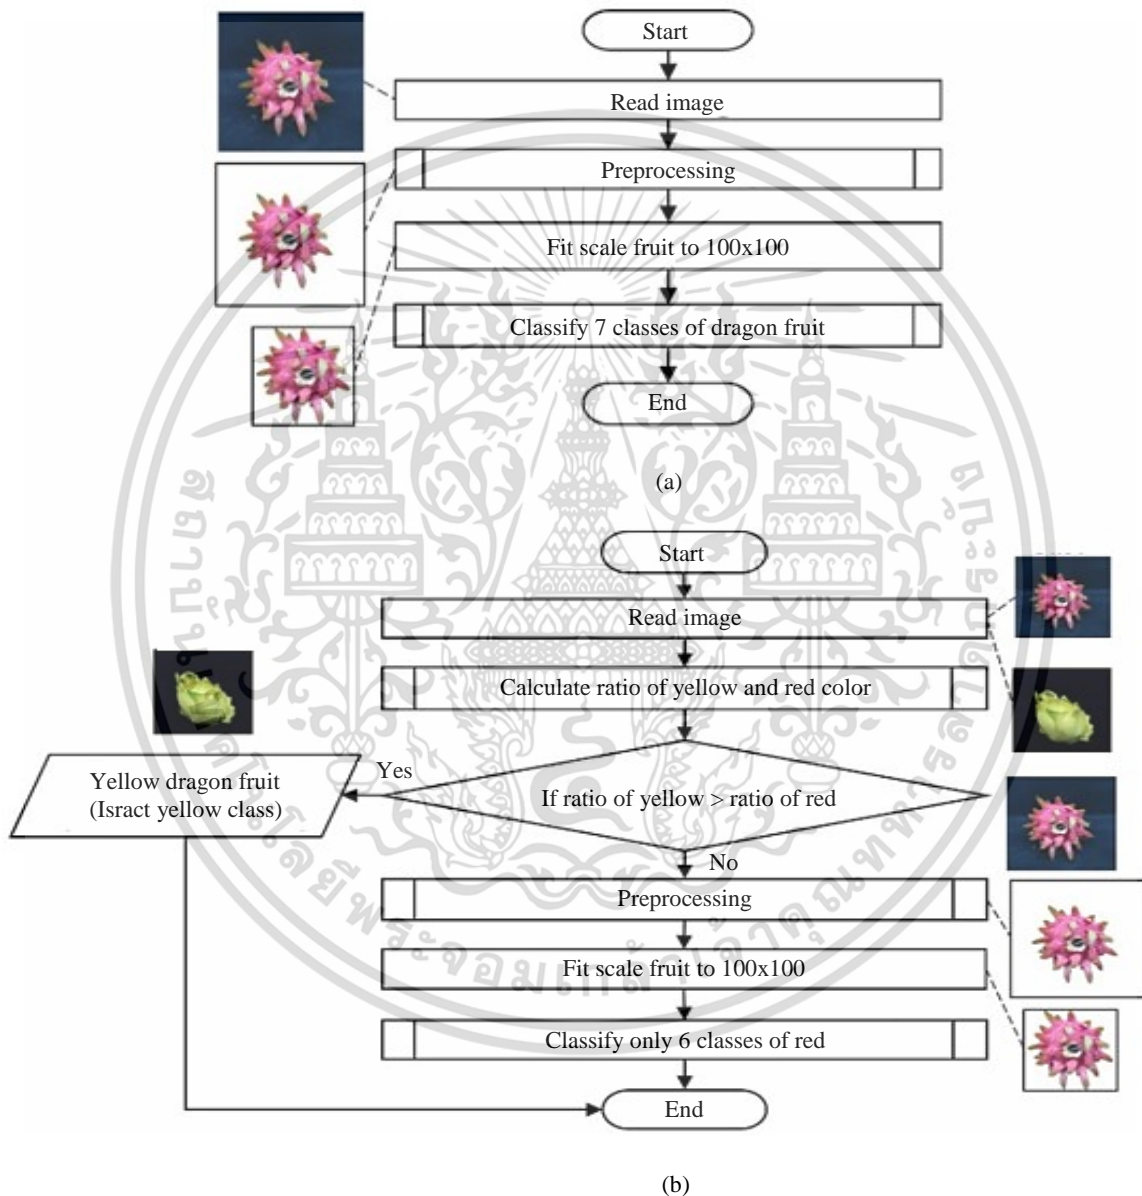


Figure 1 The main program of DIPDEEP method (a) old version (b) new version.

DIPDEEP method used the HSV color model to separate groups of dragon fruit from its peel color between yellow and red. The peel color morphology of dragon fruit compared to the HSV color wheel revealed that the yellow-peel fruit had H value close to 23°-37°, the entire yellow tone of the color wheel. Red-peel dragon fruit has H value close to 0°-23° and 151°-179°, the red and magenta tones of the color wheel respectively. Therefore, the DIPDEEP method used H values to classify dragon fruit groups from it peel color as shown in Figure 2 with OpenCV processing. The yellow ratio and the red ratio were returned to the main program.

In digital image processing, the RGB channel can be spited from 3 channels into a single channel. This is easier to process than three-channel simultaneous processing. From Figure 3, DIPDEEP method uses only R channel to calculate the mean threshold value, used Equation (1), as a criterion for conversion color image into binary image, preprocessing to reduce noise in an image and can extract object from background pixels.

$$mean\ threshold = \frac{\sum R}{N} \tag{1}$$

Where R is the R value of RGB model in each pixel, and N is the total number of pixels. When the value of mean threshold is returned, each pixel is compare its R value with the value of mean threshold. If the R value is greater than, this pixel will be set to white color as an object. Otherwise, this pixel will be set to black color as a background. There is used morphology function opening to modify the object boundary smoother and used the Fill Hole from the OpenCV program to fill any hole in the object. Then background is switched to white color, and the object area is switched to the same area of the origin image. The image obtained in this step is cropped to a specific proportion of the dragon fruit to 100x100 pixels and returned to the main program used as input to the next step, the deep learning model. After the main program get clear object from its background, then call a subprogram, Classify only 6 Classes of red. The deep learning model to distinguish 6 species of red-peel dragon fruit was set parameters as shown in Table 1, giving the optimized efficiency model.




Figure 2 Calculate ratio of yellow and red color subprogram.

Table 1 The structure of the convolution neural network used in the DIPDEEP method.

Layer	Size	Type	Output
Input	100x100x3		
Layer1	96x96x16	Convolution 2D (5x5) + ReLU	16
Layer2	48x48x16	MaxPooling (2x2)	-
Layer3	44x44x32	Convolution 2D (5x5) + ReLU	32
Layer4	22x22x32	MaxPooling (2x2)	-
Layer5	18x18x64	Convolution 2D (5x5) + ReLU	64
Layer6	9x9x64	MaxPooling (2x2)	-
Layer7	5x5x128	Convolution 2D (5x5) + ReLU	128
Layer8	2x2x128	MaxPooling (2x2)	-
Layer9	1x1x512	Flatten	512
Layer10	1x1x1024	Fully Connected + ReLU	1024
Layer11	1x1x256	Fully Connected + ReLU	256
Output	1x1x6	Fully Connected + Softmax	6

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Figure 3 Preprocessing subprogram.

4. Dataset and experiments

Dataset is very important for beginning researches. There are images of dragon fruits from a large image source in Kaggle named Fruit-360 [20] but it does not cover all 7 species of Thai dragon fruits. This research have to create a new dataset, 7 species of Thai dragon fruits are collected between August-October 2020 from 7 plantations in Mueang Loei District, Phu Ruea District and Dan Sai District, Loei Province, where gets the highest harvest of dragon fruits [3]. These samples of dragon fruits are less than one week after harvesting.

4.1 Dataset

The data set consisted of 9,754 images which were divided into Jumbo White 1,172 images, Vietnamese White 1,190 images, Pink 1,309 images, Siam Red 1,869 images, Taiwan Red 1,184 images, Ruby Red 1,110 images, and Israel Yellow 1,920 images. The dataset used only the mobile phone camera to take images with 1:1 aspect ratio, disables all filters, and the dragon fruit is placed in a portable studio box with size 40x40 cm, floor with black velvet fabric, installed one row of LED lights on the top edge of the box, as shown in Figure 4(a). From Figure 4(b) the object is kept as centered as possible, by using the nine dividing lines of image layout, and try to take images with the object rotated as 0-360 degrees as possible, similar to the images of Fruit-360 [20]. An example image looks like Figure 4(c). Each image contains only one species of a dragon fruit with black background. Each species used samples more than one dragon fruit. After collecting the dataset, botanists and gardeners identify the label again for the accuracy of the species name identification used to validation as a ground truth data.

There are total 10,072 images of dragon fruits in an outdoor environment using a mobile phone camera, with free aspect ratios, such as 3:4, 9:16 in natural sun light as well. The results of images have a more complex background, with different image sizes as shown in Figure 5. If innovations are developed in the future that farmers or tourists can use the camera of a mobile phone to easily detect the species of dragon fruit without using a ruler or a proficient tool. It will be great challenge for future researches.

4.2 Experiments for the preprocessing subprogram

The DIPDEEP ever testing RGB, HSV, and LAB to determine the channel of the image converted to binary image can be used to separate the background image from the dragon fruit effectively. From the experimental results, the R Channel of the RGB model gave the best results as shown on Figure 6.

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

From Figure 7, an example image is presented results for each process step to extract an object from its background following a subprogram in Figure 3, beginning with an original image, follow with the binary result after segmenting with the mean threshold, the result after processed with function Opening, the result after Fill Hole, the result after running function Erosion, and then the result of an image after remove background. Then crop the result image, with the centered object, to fit with 100x100 pixels similar to [20] as shown on Figure 8. From Figure 9, example images represent results after done with the Preprocessing subprogram. There are 7 species of dragon fruits, which is ordered from left to right are Pink, Siam Red, Taiwan Red, Ruby Red, Jumbo White, Vietnamese White and Israel Yellow species, respectively. From Figure 10, each column displays, ordered from top to bottom, a dragon fruit image, an image showing pixels of yellow color position and its yellow ratio value, an image showing pixels of red position and its red ratio value of H channel in the HSV model. For each column in Figure 10, any dragon fruits with red skin have their red ratio value more than their yellow ratio. The Israel Yellow, the last two columns on the right hand side, has its yellow ratio value more than its red ratio value. Therefore the yellow ratio value and the red ratio value can be used to identify skin color of dragon fruits.





Figure 4 (a) Show the device to collect the data (b) imaging techniques (c) a sample of data.



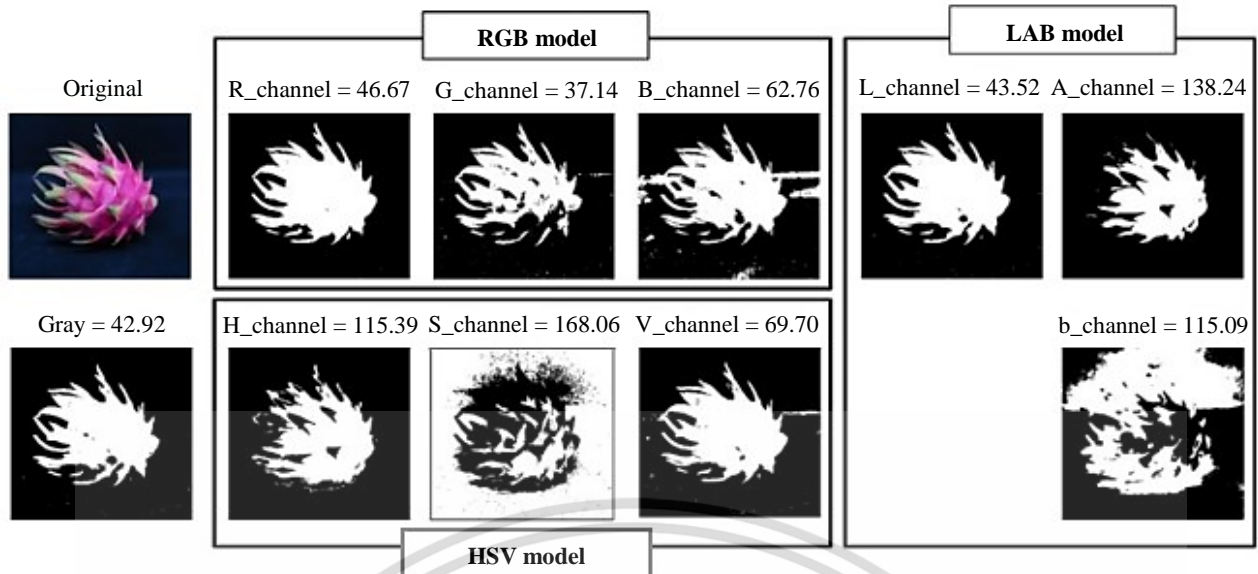
Figure 5 Samples of a dragon fruit image in an outdoor environment.



(a) Show result of converting 3 channels to 1 channel for either RGB, HSV, or LAB model.

Figure 6 (a) An image in either original, gray, RGB, HSV, or LAB model, (b) binary image.

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(b) The results respectively in (a) after convert all channel to binary by using mean threshold.

Figure 6 (continued) (a) An image in either original, gray, RGB, HSV, or LAB model, (b) binary image.




Figure 7 Illustration of each step to extract object from its background.

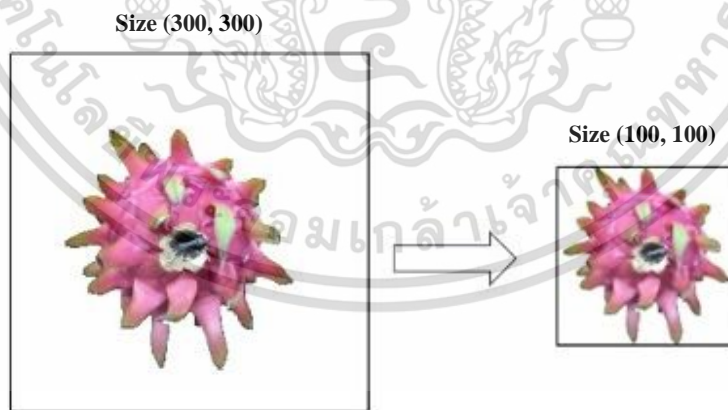


Figure 8 An example of cropped the object to fit scale 100x100 pixels



Figure 9 Results after done with the preprocessing subprogram.

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Figure 10 Results for each column, original image, its yellow ratio value, and red ratio value.

4.3 Experimental results

Before doing the experiments, images of 7 species of dragon fruit were randomly selected 1,000 images per species, divided into 800, 100, and 100 images for the Training Set, the Validate Set, and the Test Set, respectively. Using the 10-Folds Validation technique. All of the selected images were processed with main program. Experimental results after finished the Preprocessing subprogram as shown in section 4.2 are used as input data for running the deep learning in the subprogram named Classify only 6 Classes of red, in the main program (new version), and Classify 7 Classes, in the main program (old version). A 100x100 pixel image is used to process with a deep learning model Structured as Table 1.

From Table 1, Output Layer was set the output equal to the number of classes. Therefore, the output node is equal to 6 nodes for DIPDEEP new version, and 7 nodes for DIPDEEP old version. The rest of the parameters that are not specified using all Keras default values. The model uses the Adam algorithm optimizer, the learning rate is 0.001 in the Training process, by assigning Batch Size equal to 100 and assigning multiple Epochs namely 10, 20, 30, 40, 50, 100, 300, 400 and 500 epochs to test which Epoch will be the best and get the highest accuracy. The results of classifying of 7 Classes are comparing between the Fruit recognition method [20] and The DIPDEEP (old version) shown on Table 2. From the results, it was found that Epoch equal to 100 was the most suitable because it could provide the highest accuracy of 98.20%.

From Table 3, results showed that DIPDEEP method can classify between Yellow and Red skin species correctly with accuracy 100%. All of experiments were explained only using Laboratory Dataset. From Table 4, results showed any numbers of samples in from both Laboratory Dataset and Outdoor Dataset using DIPDEEP method. In this experiment, Red skin and Yellow skin can be classified correctly with accuracy 100 % in Laboratory Dataset. But Outdoor Dataset can be classified correctly with accuracy 95.26%, lesser than results of Laboratory Dataset. Because it has more complex background. The accuracy to separate species of the Outdoor dataset is not stable because of its accuracy was less than 100%. Therefore, the Outdoor dataset did not process other steps yet.

Table 2 Percentage accuracy of results between the fruit recognition method and DIPDEEP

epochs	Mean (SD.)					
	Fruit recognition method [20]			DIPDEEP Method		
	Train	Valid	Test	Train	Valid	Test
10	97.41(1.00)	95.09(1.37)	94.49(1.03)	97.60(0.72)	95.59(0.83)	94.06(1.21)
20	99.64(0.59)	97.11(1.10)	96.46(1.05)	99.83(0.50)	97.81(0.75)	96.99(0.88)
30	100(0.00)	98.20(0.55)	97.70(0.47)	100(0.00)	98.74(0.52)	98.00(0.39)
40	100(0.00)	98.50(0.38)	97.66(0.36)	100(0.00)	98.71(0.46)	97.96(0.38)
50	100(0.00)	98.13(0.44)	97.49(0.60)	100(0.00)	98.61(0.55)	98.11(0.32)
100	100(0.00)	98.36(0.46)	97.56(0.89)	100(0.00)	98.74(0.27)	98.20(0.44)
300	100(0.00)	98.37(0.43)	97.60(0.84)	100(0.00)	98.71(0.56)	97.99(0.72)
400	100(0.00)	98.13(0.79)	97.39(0.60)	100(0.00)	98.67(0.53)	97.67(0.88)
500	97.65(5.65)	93.09(6.35)	77.33(21.49)	100(0.00)	96.21(2.27)	88.61(9.63)

Table 3 Percentage accuracy of classification results between yellow and red

	Train		Valid		Test	
	Samples	Hue range	Samples	Accuracy	Samples	Accuracy
Yellow (1 species)	800	23-37	100	100%	100	100%
Red (6 species)	800	0-23 and 151-179	100	100%	100	100%

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

From Figure 1(b) and Table 3, the results showed that the H channel of HSV color model can classify the Israel Yellow species from the other 6 species with 100% accuracy. And the deep learning in DIPDEEP new version can classify 6 species of red-skin dragon fruits with accuracy 98.80% as showed on Table 5. Table 5 reported the comparison for accuracy of classification methods, such as ResNet50 [16], VGG16 [17], MoBileNetV2 [19], and DIPDEEP. The results showed that ResNet50 and MoBileNetV2 for training set cannot get accuracy 100%, and cannot use to compare results. The VGG16 get accuracy 98.70 % and DIPDEEP get accuracy 98.80%. Therefore the DIPDEEP model is more suitable for classifying the 6 species of Thai dragon fruits. The DIPDEEP is fine-tune the CNN architecture, which is similar to the VGG16 in that the number of layers is reduced from 16 to 13, and the filter size is reduced to 16, 32, 64, and 128, but the kernel size of the convolution layer is increased from 3x3 to 5x5. Importantly, the file sizes of DIPDEEP, ResNet50, VGG16 and MobileNetV2 are 12.2 MB, 270.7 MB, 542 MB and 26.5 MB, respectively. The DIPDEEP method is the smallest size. The confusion matrix with 100 epochs for 6 classes shows as shown on Figure 11. Examples of the misclassified images were shown on Figure 12. Taiwan Red is very similar with Ruby Red. Therefore these species have the less average of accuracy rate than other.

Table 4 Classification results between red and yellow with 2 different datasets

Species	Laboratory dataset		Outdoor dataset	
	Samples	Accuracy	Samples	Accuracy
Pink	1,309	100.00%	1,058	100.00%
Siam Red	1,869	100.00%	974	97.84%
Taiwan Red	1,184	100.00%	1,111	86.41%
Ruby Red	1,110	100.00%	903	98.00%
Jumbo White	1,172	100.00%	1,603	92.33%
Vietnamese White	1,190	100.00%	2,925	92.44%
Israel Yellow	1,920	100.00%	1,498	99.80%
	Mean	100.00%	Mean	95.26%

Table 5 Comparison for accuracy of classification methods (for 6 species of red skin).

	Mean (SD.)			
	ResNet50[16]	VGG16[17]	MoBileNetV2[19]	DIPDEEP
Train	99.73 (0.85)	100.00 (0.00)	86.56 (11.86)	100.00 (0.00)
Valid	99.13 (1.64)	98.80 (0.32)	85.43 (12.36)	98.45 (0.62)
Test	99.13 (1.65)	98.70 (0.41)	86.05 (11.85)	98.80 (0.48)




Figure 11 A confusion matrix with 100 epochs for classification 6 species.




Figure 12 Examples of the misclassified images.

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5. Remarkable conclusions

In DIPDEEP method, the color characteristics H of the HSV color model were used to distinguish dragon fruit from its peel color between yellow and red. When a yellow-peel dragon fruit is detected, the results of the cultivar classification can be concluded immediately because of only one species in yellow color. This reduces the work of the computer as well. In the pre-processing step of DIPDEEP, used the color characteristics R of the RGB color model to reduce noise in the image and can help to detect dragon fruit from the background. The DIPDEEP method modified deep learning to classify 6 species of Thai red dragon fruit. This DIPDEEP method is an automatic method with smallest file size, compared with ResNet50, VGG16 and MobileNetV2, and save time because it can classify the Israel Yellow species out with accuracy 100% before doing classify the other 6 species, with the accuracy value 98.80%. This method can help farmers, consumers, and factories to classify species of Thai dragon fruit, and help famers selling their products in higher price or help someone who is allergy with specific species can avoid it correctly. All experiment results used only the Laboratory dataset. Since from Table 4, the Outdoor dataset was used to classify between the Israel Yellow with the other 6 different species which accuracy was less than 100%, and did not process other steps in DIPDEEP yet. Therefore, the Outdoor dataset needs to be studied more for the future work.

6. References

- [1] Abirami K, Swain S, Baskaran V, Venkatesan K, Sakthivel K, Bommayasamy N. Distinguishing three Dragon fruit (*Hylocereus* spp.) species grown in Andaman and Nicobar Islands of India using morphological, biochemical and molecular traits. *Sci Rep.* 2021;11:2894.
- [2] National Bureau of Agricultural Commodity and Food Standards, Ministry of Agriculture and Cooperatives. Thai agricultural standard: Dragon fruit [Internet]. 2015 [cited 2021 Sep 11]. Available from: <https://www.acfs.go.th/standard/download/eng/DRAGON-FRUIT-ENG.pdf>.
- [3] Department of agricultural extension, ministry of agriculture and cooperatives. Agricultural production information service system [Internet]. 2020 [cited 2021 Sep 1]. Available from: <https://production.doae.go.th/service/site/login>.
- [4] Parekh R. Fundamentals of image, audio, and video processing using Matlab®: with applications to pattern recognition. Florida: CRC Press; 2021.
- [5] Burger W, Burge MJ. Principles of digital image processing fundamental techniques. New York: Springer; 2009.
- [6] Elgendy M. Deep learning for vision systems. New York: Manning; 2019.
- [7] Latif A, Rasheed A, Sajid U, Ahmed J, Ali N, Ratyal NI, et al. Content-based image retrieval and feature extraction: a comprehensive review. *Math Probl Eng.* 2019;2019:9658350.
- [8] Wang S, Han K, Jin J. Review of image low-level feature extraction methods for content-based image retrieval. *Sens Rev.* 2019;39(6):783-809.
- [9] Samek W, Montavon G, Lapuschkin S, Anders CJ, Müller KR. Explaining deep neural networks and beyond: a review of methods and applications. *Proc IEEE.* 2021;109(3):247-78.
- [10] Schmidhuber J. Deep learning in neural networks: an overview. *Neural Netw.* 2015;61:85-117.
- [11] Hameed K, Chai D, Rassau A. A comprehensive review of fruit and vegetable classification techniques. *Image Vis Comput.* 2018;80:24-44.
- [12] Bani N. T, Fekri-Ershad S. Content-based image retrieval based on combination of texture and colour information extracted in spatial and frequency domains. *Electron Libr.* 2019;37(4):650-66.
- [13] Hamza R, Chtourou M. Design of fuzzy inference system for apple ripeness estimation using gradient method. *IET Image Process.* 2020;14(3):561-9.
- [14] Reyes JF, Contreras E, Correa C, Melin P. Image analysis of real-time classification of cherry fruit from colour features. *J Agric Eng.* 2021;52(4):1-6.
- [15] Cecotti H, Rivera A, Farhadloo M, Pedroza MA. Grape detection with convolutional neural networks. *Expert Syst Appl.* 2020;159:113588.
- [16] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016 Jun 27-30; Las Vegas, USA.* New York: IEEE; 2016. p. 770-8.
- [17] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations ICLR; 2015 May 7-9; San Diego, USA.* New York: DBLP; 2015. p. 398-406.
- [18] Osako Y, Yamane H, Lin SY, Chen PA, Tao R. Cultivar discrimination of litchi fruit images using deep learning. *Sci Hortic.* 2020;269:109360.
- [19] Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC. MobileNetV2: inverted residuals and linear bottlenecks mark. *IEEE/CVF Conference on Computer Vision and Pattern Recognition; 2018 Jun 18-23; Salt Lake City, USA.* New York: IEEE; 2018. p. 4510-20.
- [20] Mureşan H, Oltean M. Fruit recognition from images using deep learning. *Acta Univ Sapientiae Inform.* 2018;10(1):26-42.
- [21] Inunganbi S, Seal A, Khanna P. Classification of food images through interactive image segmentation. In: Nguyen N, Hoang D, Hong TP, Pham H, Trawiński B, editors. *Intelligent information and database systems.* Cham: Springer; 2018. p. 519-28.
- [22] Momeny M, Jahanbakhshi A, Jafarnezhad K, Zhangd Y. Accurate classification of cherry fruit using deep CNN based on hybrid pooling approach. *Postharvest Biol Technol.* 2020;166:111204.

CBML: CLASSIFICATION – THAI RED DRAGON FRUIT

NARUWAN YUSAMRAN AND NUALSAWAT HIRANSAKOLWONG*

Department of Computer Science
School of Science
King Mongkut's Institute of Technology Ladkrabang
Chalongkrung Road, Ladkrabang, Bangkok 10520, Thailand
62605118@kmitl.ac.th; *Corresponding author: nualsawat.hi@kmitl.ac.th

Received March 2022; accepted May 2022

ABSTRACT. A dragon fruit is nutritious having low sugar levels suitable for diabetics. Its shape is spherical with petals surrounding the bark. In Thailand, 7 species of dragon fruit are grown. Its appearance can be divided into red bark (6 species) or yellow bark (1 species). People can separate between yellow and red bark. Since the red-skinned dragon fruit may have its fruit pulp in one of three possible colors: white, red or pink, it is difficult to guess from the outside what color of the fruit pulp will be. The big problem is that people cannot classify its species of red bark. Some people may be allergic or dislike dragon fruit in some species. Therefore, this research is trying to find the best way to automatically classify the species of Thai red dragon fruit from its image. The CBML stands for content base and Machine Learning. This method uses content base to extract key features (34 attributes), and uses Machine Learning for giving optimization results with the Support Vector Machine (SVM), setting kernel for polynomial in 8 degree. The results showed that the CBML method was able to identify any species of dragon fruits in the red bark group with an accuracy of 98.47%.

Keywords: Dragon fruit, Classification, Content base, Machine Learning

1. Introduction. A dragon fruit is a species of Cactaceae, genus *Hylocereus* spp. and *Selenicereus* sp. [1]. Its bark is yellow or red with petals around the fruit, and at the end of the petals is green. The dragon fruits are divided into 3 groups, which have differences in the shell color (Peel/Skin) and the inner color (fruit pulp), namely Group 1 white pulp with red skin (*Hylocereus undatus*), Group 2 red-pulp-red-skin (*Hylocereus polyrhizus*) or pink-pulp-red-skin (*Hylocereus* spp.), and Group 3 yellow or gold skin-white-pulp (*Hylocereus* sp. and *Selenicereus* sp.) [2].

From visiting the area to explore the cultivation of dragon fruits in the Loei province located at the top of the northeastern region of Thailand, Loei is the area that can harvest the most products in the country [3] with total 7 species of dragon fruits. There are 2 species in Group 1, namely Jumbo White and Vietnamese White, 4 species in Group 2 namely Pink, Siam Red, Taiwan Red, Ruby Red, and 1 species in Group 3 namely Israel Yellow as shown in Figure 1. Dragon fruits in both Group 1 and Group 2 have red bark, with 6 different species. Its morphological features [4] are difficult to collect information because it requires expertise in botany. Therefore, this paper is interested in classifying the species of Thai red dragon fruit using content base and Machine Learning techniques to the specific 6 species of red shell, namely Jumbo White, Vietnamese White, Pink, Siam Red, Taiwan Red and Ruby Red. The correct classification of red dragon fruit species can be very beneficial, for example, making farmers sell them for a better price. A factory can have an automated system for separating and labeling the species. Consumers who are allergic with certain species will be able to avoid it correctly or to choose their favorite.




FIGURE 1. Dragon fruits that show its bark color and its fruit pulp in any group and any species

From previous research, it was found popular techniques used in fruit classification, mostly in two prominent methods: Deep Learning and Machine Learning [5,6]. Of course, Deep Learning is probably the simpler method as the features are automatically extracted. However, with Deep Learning processing as a black box [7], it is more difficult for researchers to understand the features used in the classification. For Machine Learning, researchers have to select the attributes that are used in their classification, which can be difficult to know which attributes are the most appropriate. However, with the advantage of selecting this feature itself, researchers are able to understand how the algorithm works. The researchers were able to define the characteristics used for classifying themselves. All parts of the algorithm can be edited. The number of parameters can be set depending on the used algorithm. They can be classified of feature one by one, without confusion. In the past, there had been many successful methods, with mostly an accuracy less than 90% [5,8].

Therefore, in conducting this research, the objectives are to study and search for characteristics finding classification methods suitable for separating 6 species of red bark dragon fruits by using content base and Machine Learning techniques. The results show that our method gave better accuracy. The remainder of this paper will present the relevant research in Section 2, the CBML algorithm in Section 3, the experiment results in Section 4, and remarkable summary discussions in Section 5.

2. Literature Review. Popular techniques used in fruit classification are not only Deep Learning, but Machine Learning techniques [5,6]. In the characterization process, the suitable attributes have to be defined to be used for the classification in Machine Learning. However, Deep Learning is automatic feature extraction [7]. If the researchers select the suitable attributes that are well used to classify, the output of the classification will also have good results [6]. Feature extraction is to extract data of an image such as color, shape, size, and texture that can describe all image attributes. It can be all or part of

an image that can represent the entire image [9]. Feature extraction can use a manual selection feature based on the classification problem or use a computer to select a feature automatically [10] to achieve the appropriate feature. These features can be used for recognition, identification, classification, grading, and retrieval [5,6]. The efficiency of these works depends on the appropriate feature extraction. There may be only one or more attributes. The main characteristics that are commonly used to distinguish attributes are color feature, shape feature, and texture feature [6], which can be used to specify statistical features and geometric properties. Most researchers try to select the attributes for the best matching methods used to classify in order to achieve the highest efficiency in their work. Machine Learning is a technique, commonly used to classify. Well-known algorithms have been applied, including Decision Tree (DT), Random Forest (RF), k-Nearest Neighbor (k-NN), Naïve Bayes (NB), and Support Vector Machine (SVM), where these algorithms produce different results [5,6]. The most prominent resultant algorithm is Support Vector Machine (SVM). For example, [11] used color and texture attributes to recognize fruits from photographs of 8 natural fruits. The 16 surface characteristics from the Gray-Level Co-occurrence Matrix (GLCM) and 12 color attributes derived from the RGB color model were used. Using all 28 color and texture attributes can perform better than using just one color or texture feature. The accuracy was 83.33%.

Similarly in [12], the authors used color and texture attributes to recognize 15 super-market fruits. The fruit images in the RGB color model were converted to the HSV color model. The H Channel and the S Channel were analyzed with 4 statistical properties. There are total 8 attributes. The V Channel are also analyzed to extract surface attributes. The co-occurrence matrices of 5 attributes are contrast, energy, local homogeneity, cluster shade, cluster prominence. Therefore, the combination 13 attributes were used. Fruit image recognition (MDC method) with 13 common color and texture attributes gave an accuracy of 86%. Therefore, color and texture characteristics are considered suitable for species identification of the fruits using datasets of different fruits, with the efficient operation of SVM and MDC.

Color, texture, shape and size attributes [8] were used to distinguish 4 types of date palms. The 3 channels from RGB color model were used to generate histograms using Local Binary Pattern (LBP) and Weber Local Descriptor (WLD) algorithms. There are clearly different patterns, with the features that have a high volume. Therefore, the Fisher Discrimination Ratio (FDR) was used to select important attributes by selecting the first 10 attributes that gave the most FDR values. For shape and size there are totally 4 attributes. There were only 14 attributes used to distinguish the date palms' species. The algorithm used SVM. In experiments, it was found that 10 attributes from LBP or WLD histograms combined with 4 shape and size attributes yielded better results than others up to 99% accuracy. It is very high for fruit classification.

In addition to fruit identification and fruit classification, Machine Learning is also applied to other applications such as detection of bananas based on color and texture characteristics in natural environments [13]. The difficulty of this task is that the color of bananas and the color of the banana trees are the same green. Using the RGB color feature alone is not enough. Therefore, consider using HSV color model in the experiments. The bunch of bananas was isolated with a Histogram of Oriented Gradients (HOG), and texture characteristics were isolated by a Local Binary Patterns (LBP). Support Vector Machine (SVM) algorithm and AdaBoost algorithm were used to compare results. The results found that combination of HOG, LBP and SVM is the most efficient algorithm gaining 100% accuracy. This experiment shows that the Support Vector Machine (SVM) is an algorithm. It provides higher fruit classification performance than other algorithms, but may not work best for data types other than fruit.

The algorithm for multiclass classification has been proposed using differential classifiers [14]. Known as Standardized Variable Distances (SVD), the SVD algorithm is an

algorithm that uses the distance between the test data and the mean of the attributes in each class and the Z-score to calculate a score. The results show that SVD is able to classify the Wisconsin Breast Cancer Original (WBCO) and the LED Display Domain (led7digit) datasets more efficiently than the other algorithm. This proved that SVM was not always the best method. Although the performance of SVM is superior to other algorithms, the factor of efficient classification is finding the appropriate attributes to support the classification algorithm to work well.

This paper focuses on studying and searching for characteristics and classification methods that are suitable for separating species of the red-shelled dragon fruit. Based on the above literature review, color and texture attributes were attributes that could be used to differentiate species of red-barked dragon fruit with the dragon fruit image dataset. The algorithm may be experimented with SVM, k-NN, MDC and SVD, which have outstanding performance. Details will be explained in the next section.

3. The CBML Method. This paper presents the CBML algorithm which is an automatic method using content base to extract key features and Machine Learning to classify six species of dragon fruits in red bark group. Its main program is presented in Figure 2.

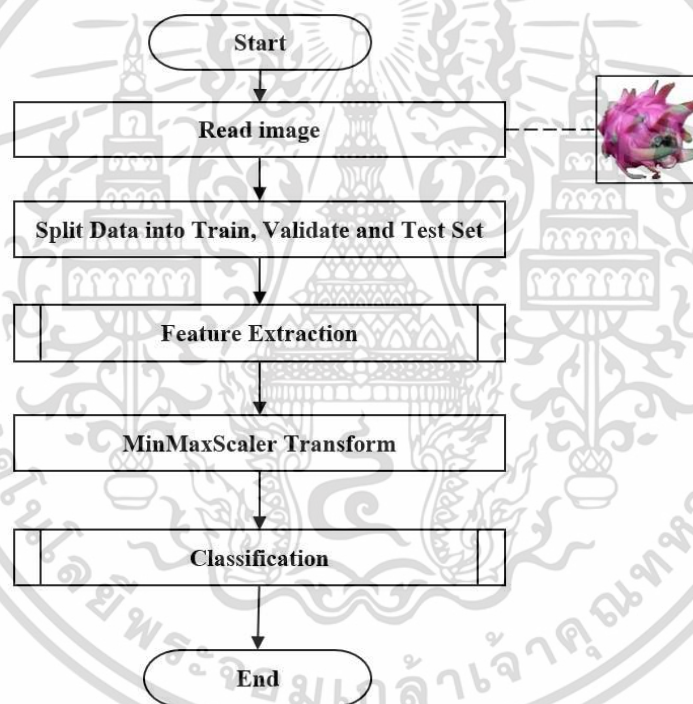


FIGURE 2. The main program of CBML method

This method starts with reading a dragon fruit image which consists of a red-shelled dragon fruit of any species on a white background. An example of a dragon fruit image is shown in Figure 2. Then random split data into 3 groups: Train, Validate, and Test. For each group it will do subprogram, the Feature Extraction, then do MinMaxScaler Transform, and then do subprogram, the Classification. The output result is the species of a dragon fruit image in red bark group.

3.1. Feature extraction. From the literature review as mentioned in Section 2, the topic of feature extraction to select appropriate attributes that allow for more accurate categorization can be summarized as Table 1 and thus this provides a guideline for selecting suitable features that enable more accurate classification in CBML method.

From Table 1, [11] and [12] classified fruits and used texture features of GLCM and colors. The possible attributes of GLCM are Dissimilarity (D), Angular Second Moment

TABLE 1. Comparison of characterization from feature extraction in many methods

Ref.	Data	Features	Classification
[11]	8 types of Mixed Fruits	16 GLCM of RGB (4 Directions from Contrast (Ct), Correlation (Cn), Energy (Ey) and Homogeneity (Hy) and 12 statistical features (Mean, Standard Deviation, Skewness, Kurtosis) of RGB)	SVM (Kernel = not specified)
[12]	15 types of Mixed Fruits	5 GLCM of V channel from HSV (contrast, energy, local homogeneity, cluster shade and cluster prominence) and 8 statistical features of H and S channel from HSV (Mean, Standard Deviation, Skewness, Kurtosis)	Minimum Distance Criterion (MDC) (distance = not specified)
[8]	4 types of Dates	Use Local Binary Pattern (LBP) and Weber Local Descriptor (WLD) from each channel of RGB and then use Fisher Discrimination Ratio (FDR) to select the top-10 highest FDR value combined with 4 shape and size features (Major axis length, Minor axis length, Ellipse eccentricity and Area)	SVM (kernel = RBF)
[13]	detect banana and background	Histogram of Oriented Gradients (HOG) and Local Binary Patterns (LBP)	SVM (Kernel = not specified) compared with Adaboost
[14]	public dataset from Wisconsin Breast Cancer Original (WBCO) and LED Display Domain (led7digit)	9 attributes from WBCO and 7 attributes from led7digit.	SVM (Kernel = RBF) k-NN ($k = 3$, distance = Euclidean) MDC (distance = Minkowski, $p = 3$) SVD (distance = Manhattan) SVM (Kernel = RBF) k-NN ($k = 3$, distance = Chebyshev) MDC (distance = Minkowski, $p = 3$) SVD (distance = Hellinger)
CBML method	6 species of Thai Dragon Fruit from red bark group	2 attributes GLCM of RGB (Dissimilarity (D) and ASM only Directions: 0°) and 32 attributes of color features with RGB, HSV and AB for each channel in any color model using four statistical features (Mean, Standard Deviation, Skewness, and Kurtosis) Total 34 attributes Each attribute used MinMaxScaler to normalization into 0 to 1 value.	SVM (Kernel = Polynomial, degree = 8)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




FIGURE 5. The mean of dissimilarity of texture feature in any degree

with RGB, HSV and AB for each channel in any color model using four statistical features (Mean, Standard Deviation, Skewness, and Kurtosis) as shown as the last row in Table 1.

Before the feature data is processed, the scaling value of the data is adjusted to a value in the range of 0-1 with the MinMaxScaler Transform (Equation (1)) using the data in Train Set. The scale transform in Train Set is a reference criterion for adjusting the value of the Validate Set and the Test Set.

$$\text{MinMaxScaler Transform} = (x - \min) / (\max - \min) \quad (1)$$

where, in each attribute max is not equal to min, x is the value, min is the minimum value in the Train Set, and max is the maximum value in the Train Set. The *MinMaxScaler Transform* is a normalization transform of any value between min and max into 0 to 1.

3.2. Classification. For classification in this research, the performance of the SVM, k-NN, MDC [12] and SVD [14] was compared to study and find the most suitable method to classify 6 species of the red bark dragon fruit. The SVM algorithm was defined 4 kernels: Linear, Polynomial (definition degree = 8), Radial Basis Function (RBF), and Sigmoid. All sklearn processed the k-NN, MDC [12] and SVD [14] with 5 effective classification distances [15]: Manhattan, Euclidean, Minkowski (defined $p = 3$), Hellinger [16] and Chebyshev, where k-NN is set to k equal to 3. The results will be described in the next section.

4. Experiment Results. Dataset is created by taking a photo of a dragon fruit on white background. Botanists listed the species' validity labels used for validation as baseline information. There are 9,754 images, divided into the red bark group 7,834 images and the yellow bark group 1,920 images. The dataset used in this research is a dataset obtained from randomly selected images of 6 species of red-shell dragon fruit, 1,000 images of each species, for a total of 6,000 images out of 7,834 images. The image size is 100×100 pixels. Some examples of images are shown in Figure 6. All images are a dragon fruit with red bark on white background.

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



FIGURE 6. Examples of input images

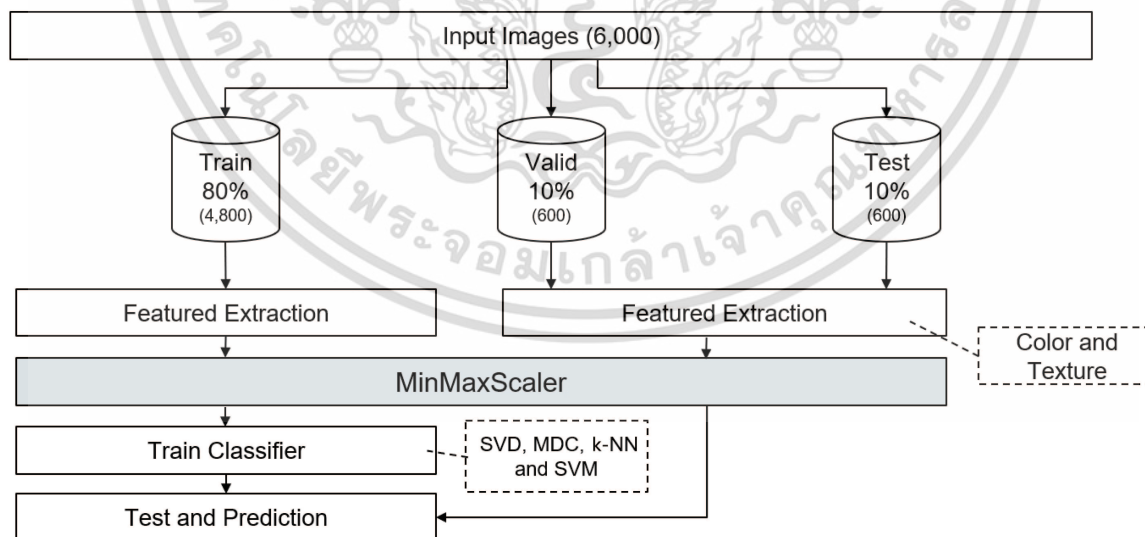


FIGURE 7. Train Set, Validate Set, and Test Set using the 10-Folds Validation technique

The experiment divided the 1,000 images in each species into 800 images for the Train Set, 100 images for the Validate Set and the remaining 100 images for the Test Set, using the 10-Folds Validation technique as shown in Figure 7. ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

The purpose of the experiment was to study and find the most suitable characteristics and classification methods. Therefore, the dataset was extracted with color and texture

attributes, processed with different algorithms, namely SVM, k-NN, MDC [12] and SVD [14], each of which has defined different parameters. All of the experimental results were shown in Table 2. From Table 2, columns are feature attributes of CBML (34 attributes), 28 attributes of [11], and 14 attributes of [8]. Rows are the classification algorithms, that is, SVM, k-NN, MDC [12] and SVD [14]. The results from k-NN, MDC and SVD training cannot reach 100% accuracy. Only the SVM with polynomial, on the second row, training can reach 100% accuracy with the methods between CBML and [11]. The CBML method gave better accuracy of 98.47% than [11] with accuracy rate of 94.20%.

The confusion matrix with SVM algorithm is shown in Figure 8. The accuracy results for Pink, Siam Red, Taiwan Red, Ruby Red, Jumbo White, and Vietnamese White species are 99.5, 99.6, 97.4, 97.4, 98.2, and 98.7, respectively. The Taiwan Red is the most similar

TABLE 2. Accuracy comparison of different features and different classifications

Algorithm	Distance/ Kernel	CBML with 34 attributes color and texture			28 attributes color and texture [11]			14 attributes texture and shape [8]		
		Train	Valid	Test	Train	Valid	Test	Train	Valid	Test
		SVM	Linear	91.22	90.90	90.75	83.12	82.65	82.55	57.36
Polynomial	100.00		98.28	98.47	100.00	94.10	94.20	94.83	52.82	52.88
RBF	92.86		92.33	92.50	87.25	86.17	86.22	62.87	58.98	59.23
Sigmoid	38.97		38.85	38.75	21.59	21.62	21.87	11.32	11.12	11.30
k-NN	Manhattan	96.51	92.18	92.35	93.72	86.12	85.92	70.80	45.58	46.75
	Euclidean	96.89	92.87	93.23	94.01	87.00	86.87	69.64	45.67	45.13
	Minkowski	97.04	93.12	93.20	94.21	86.70	87.13	69.10	44.62	44.35
	Hellinger	97.05	93.02	92.82	94.25	86.68	86.62	67.19	39.73	40.63
	Chebyshev	93.46	92.18	91.90	93.90	85.93	86.00	67.94	42.27	41.17
MDC [12]	Manhattan	61.95	61.63	62.08	54.99	54.88	55.10	42.95	43.00	43.27
	Euclidean	64.96	64.58	64.52	59.29	59.43	59.13	44.64	44.43	44.27
	Minkowski	65.77	65.60	65.57	61.16	60.80	60.70	43.80	43.02	43.98
	Hellinger	67.15	63.87	64.22	56.86	56.90	57.17	43.98	43.52	43.50
	Chebyshev	64.46	64.17	63.68	58.56	58.45	58.30	37.63	36.93	37.18
SVD [14]	Manhattan	62.42	62.28	62.50	56.65	56.32	56.22	44.05	43.70	44.17
	Euclidean	63.88	63.72	63.88	58.89	59.07	58.70	44.60	44.38	44.50
	Minkowski	64.68	64.33	64.48	59.97	59.93	59.73	44.34	44.10	43.97
	Hellinger	63.90	63.60	64.08	57.73	57.80	57.70	45.06	45.43	45.00
	Chebyshev	69.62	66.43	66.43	60.86	60.87	60.58	43.09	42.48	42.47




FIGURE 8. The confusion matrix with SVM algorithm

to Ruby Red species. The results were found that SVM (Kernel = Polynomial, degree = 8) had the highest efficiency in classifying the species of red-shelled dragon fruit. The CBML method uses only 34 attributes from 60 attributes, and this can reduce almost 50%. The CBML method using SVM with Polynomial can characterize and classify the most suitable in the species classification of Thai red dragon fruits.

5. Remarkable Conclusions. The CBML method can automatically characterize and classify method suitable for the separation of 6 species of Thai red dragon fruits. The features extraction from texture and color with 34 attributes and Machine Learning using SVM with Polynomial in 8 degree can increase the efficiency of classifying species of red dragon fruits. The CBML method can achieve with 98.47% accuracy. The correct classification of red dragon fruit can be very helpful. For example, plants can have automated systems for separating and labeling species, farmers can sell dragon fruits for a better price, and consumers who allergy with the species will be able to avoid them properly or choose their favorite species. The CBML used only the laboratory dataset. In fact, if the Thai dragon fruits can be classified of their species with nature outdoor environment dataset, this will be more useful such as, harvesting dragon fruit with a robot, detecting the ripeness of the fruit to manage for transportation and distribution, counting of produce before harvesting, or other approaches that are expected to enhance human well-being or help relieve labor. This will continue to develop in the future work.

REFERENCES

- [1] A. Trivellini, M. Lucchesini, A. Ferrante, D. Massa, M. Orlando, L. Incrocci and A. Mensuali-Sodi, Pitaya, an attractive alternative crop for Mediterranean Region, *Agronomy*, vol.10, no.8, DOI: 10.3390/agronomy10081065, 2020.
- [2] National Bureau of Agricultural Commodity and Food Standards, Ministry of Agriculture and Cooperatives, *Thai Agricultural Standard: Dragon Fruit*, <https://www.acfs.go.th/standard/download/eng/DRAGON-FRUIT-ENG.pdf>, 2015.
- [3] Department of Agricultural Extension, Ministry of Agriculture and Cooperatives, *Agricultural Production Information Service System*, <https://production.doae.go.th/service/site/login>, 2020.
- [4] A. Kumaresan, S. Swain, V. Baskaran, K. Venkatesan, S. Krishnan and B. Narayanasamy, Distinguishing three Dragon fruit (*Hylocereus* spp.) species grown in Andaman and Nicobar Islands of India using morphological, biochemical and molecular traits, *Scientific Reports*, vol.11, DOI: 10.1038/s41598-021-81682-x, 2021.
- [5] S. K. Behera, A. K. Rath, A. Mahapatra and P. K. Sethy, Identification, classification & grading of fruits using machine learning & computer intelligence: A review, *Journal of Ambient Intelligence and Humanized Computing*, DOI: 10.1007/s12652-020-01865-8, 2020.
- [6] K. Hameed, D. Chai and A. Rassau, A comprehensive review of fruit and vegetable classification techniques, *Image and Vision Computing*, vol.80, pp.24-44, 2018.
- [7] C. Janiesch, P. Zschech and K. Heinrich, Machine learning and deep learning, *Electronic Markets*, vol.31, pp.685-695, 2021.
- [8] G. Muhammad, Automatic date fruit classification by using local texture descriptors and shape-size features, *Proc. of UKSim-AMSS 8th European Modelling Symposium on Computer Modelling and Simulation (EMS2014)*, pp.174-179, 2014.
- [9] I. M. Hameed, S. H. Abdhussain and B. M. Mahmmod, Content-based image retrieval: A review of recent trends, *Cogent Engineering*, vol.8, DOI: 10.1080/23311916.2021.1927469, 2021.
- [10] I. A. Siradjuddin, A. Sakinah and M. K. Sophan, Combination of feature engineering and feature learning approaches for classification on visual complexity images, *International Journal of Innovative Computing, Information and Control*, vol.17, no.3, pp.991-1005, 2021.
- [11] S. Jana, S. Basak and R. Parekh, Automatic fruit recognition from natural images using color and texture features, *Proc. of the 2nd International Conference on 2017 Devices for Integrated Circuit (DevIC2017)*, pp.620-624, 2017.
- [12] A. Selvaraj, N. Shebiah, S. Nidhyananthan and L. Ganesan, Fruit recognition using color and texture features, *Journal of Emerging Trends in Computing and Information Sciences*, vol.1, no.2, pp.90-94, 2010.

เอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [13] L. Fu, J. Duan, X. Zou, G. Lin, S. Song, B. Ji and Z. Yang, Banana detection based on color and texture features in the natural environment, *Computers and Electronics in Agriculture*, vol.167, DOI: 10.1016/j.compag.2019.105057, 2019.
- [14] A. Elen and E. Avuçlu, Standardized variable distances: A distance-based machine learning method, *Applied Soft Computing*, vol.98, DOI: 10.1016/j.asoc.2020.106855, 2021.
- [15] H. A. A. Alfeilat, A. B. A. Hassanat, O. Lasassmeh, A. S. Tarawneh, M. B. Alhasanat, H. S. E. Salman and V. B. S. Prasath, Effects of distance measure choice on k-nearest neighbor classifier performance: A review, *Big Data*, vol.7, no.4, pp.221-248, 2019.
- [16] E. Hellinger, New justification of the theory of quadratic forms of infinite variables, *Journal for Pure and Applied Mathematics*, vol.136, pp.210-271, 1909 (in German).



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

DIP-CBML: A New Classification of Thai Dragon Fruit Species from Images

Naruwan Yusamran, Nualsawat Hiransakolwong

Department of Computer Science-School of Science, King Mongkut's Institute of Technology, Ladkrabang Bangkok, Thailand.

Abstract—The attractiveness of dragon fruit is that it has a strange exterior, beautiful colors, and high nutritional value. In Thailand, there is both import and export of dragon fruit. Each package for export must contain only one species of dragon fruit. From the survey, there are seven species of dragon fruit cultivated in Thailand and only some farmers can identify them on his/her farm. Therefore, this research focuses on the classification of Thai dragon fruit from laboratory images and outdoor images; which is different from the previous works which studied only laboratory images. This method was named DIP-CBML that stands for digital image processing with content-based and machine learning. The method consists of image type identification, pre-processing, red and yellow classification, image background removal, and six classes of red species classification. From the results, DIP-CBML can work with both datasets. It gave 100%, 100% and 95.53% accuracy for the image type identification, red and yellow classification, and the classification of six red species respectively. Hopefully, this research will lead to the innovation for the pre-harvest classification of Thai dragon fruit cultivars, applied to industrial applications, and robot harvesting. In the future, may add value to the yield of Thai dragon fruit cultivation.

Keywords—Dragon fruit; classification model; outdoor dataset; image pre-processing; segmentation

I. INTRODUCTION

Dragon Fruit is a fruit in the cactus family (Cactaceae) with genus *Hylocercus* Spp. and *Selenicereus* Sp. It has been planted in Thailand since 1997. With its unusual exterior and beautiful colors, it has received much attention. The advantage of dragon fruit is that it is a fruit that has high nutritional value. It can be used in the food, pharmaceutical, and cosmetic industries [1-4]. Since dragon fruit is a juicy fruit, it will be bruising and perishable in a short time after harvesting. It must be eaten or processed quickly, or storing at low temperatures for slowing down spoilage [5].

Currently, there is import and export of dragon fruit. Therefore, the agricultural standard for dragon fruit has been established by the National Bureau of Agricultural Commodity and Food Standards (ACFS), the Ministry of Agriculture, and Cooperatives of Thailand. Dragon fruit is divided into three groups by the peel color and the pulp color, namely Group 1, red peel with white pulp (*Hylocereus undatus*), Group 2, red peel with red pulp (*Hylocereus polyrhizus*) or pink pulp (*Hylocereus* spp.) and Group 3, yellow or gold peel with white pulp (*Hylocereus* sp. and *Selenicereus* sp.). The package must contain the same dragon fruit species per package [6].

From a survey on the cultivation of dragon fruit in Thailand. Loei Province located at the top of the Northeast of Thailand is the area that can harvest the most products in the country [7]. It was found that there are seven species of Thai dragon fruits planted. If divided like ACFS, the First group has two species, which are Jumbo White and Vietnamese White. The second group has four species, which are Pink, Siam Red, Taiwan Red, and Ruby Red. The third group has only one species called Israel Yellow. Each species has different care and maintenance which affects cultivation costs and selling prices.

The main problem is that only some farmers can identify the cultivars which are grown. Like the middleman, most farmers only know the color of the peel and of the pulp. As a result, the price of each species of dragon fruit is determined according to the standard in only three groups. If farmers or middlemen can classify dragon fruit species, they know how to manage production of dragon fruit, take care the produce before and after harvesting, and manage the transportation according to the specific morphology of each species. This will affect the cost and selling price, and also promote the conservation of fruit species.

However, species identification based on morphology requires a great deal of knowledge and expertise. For the general public new farmers and middlemen can identify dragon fruit species accurately and easily, the researcher has researched only the laboratory dataset [8,9] which gave a high accuracy of 98%.

Therefore, this research will present the classification of Thai dragon fruit species from images in both indoor (laboratory) and outdoor datasets. The research conducted experiments with image processing techniques, content-based techniques, machine learning, and deep learning. In the future, hopefully, this will lead to the development of innovations for the classification of Thai dragon fruit species pre or post harvesting that can be easy to use, convenient, and suitable for people. This can be applied to industrial applications and robot harvesting. It may add value to the yield of Thai dragon fruit cultivation. This paper has presented Theories and Literature Reviews in Section II, The DIP-CBML Method in Section III, Experiment Results in Section IV, Discussion in Section V, Conclusions in Section VI and Suggestion in Section VII.

II. THEORIES AND LITERATURE REVIEWS

A. Color Model

Color Model is a color system that controls the display of digital images on a digital device. Each type of color model has its own way of generating colors that have different structures. Therefore, different types of color models are used for different purposes [10]. The most popular color models in image processing are the RGB, HSV, and Lab model.

The RGB is a color system formed by the combination of primary colors. There are Red, Green, and Blue which are channels of color digital images. Each channel has 0-255 color levels [11].

The HSV is a color model which is close to the color perception of human vision. It consists of Hue (H), Saturation (S), and Value (V). Hue is the color tone defined by the angle of the color wheel. In image processing by OpenCV, the H value ranged from 0° to 180° . The S is the saturation of the color tone. If S is 0, the white color is always displayed. The V is the brightness of the tone. If the brightness value is 0, the result will be black. In OpenCV processing, S and V values ranged from 0 to 255. If both values are set to 255, it will display a pure color tone [12, 13].

The Lab color model consists of three channels. There are the L channel, a channel, and b channel. L channel is the lightness value, an a channel is a green gradation to red, b channel is a blue gradation to yellow. In OpenCV, Lab values are scaled in the range from 0 to 255 for all three channels [11, 13].

B. Digital Image Processing

Digital image processing is a process that uses a digital image as input for a specified processing purpose, such as image resizing, converting a color image to grayscale, data augmentation, etc. A digital image can be represented by $F(x,y)$ where x and y are spatial coordinates. Each coordinate is called a pixel. There are three types of images: color images, grayscale images, and binary images [14].

C. Image Pre-processes

Image pre-processing is an important step in digital image processing because the raw data from the acquisition, which is interpolated with multifactorial noise, cannot be processed immediately. Therefore, images must be done with image pre-processes to reduce those noise. For example, image segmentation is a technique that helps extract and segment desired or unwanted image data. It helps to get more specific information and it is easier to analyze information. However, processed data must be ensured that the remaining information is correct. There is no excess or missing [15]. Techniques used in image segmentation are the segmentation by thresholding-based, edge-based, area-based, and energy-based [16-18]. There are also other techniques to prepare data such as intensity estimation, geometric estimation, elementary processing, holistic processing, etc. [15].

D. Feature Extraction

Feature extraction is the process of extracting important characteristics of an image to describe all information in the

image. The feature descriptor may be all or part of the image data that can represent the whole image. In general, attributes about color, shape, size, and texture are used in image analysis or image classification. Of course, image data may not have only one attribute that can identify specific characteristics. For Image classification by machine learning, the image features will be represented by a feature vector that is a 1-dimensional array [14, 15]. In contrast for deep learning, the feature extraction process is performed automatically. The researchers are responsible for specifying the desired feature map size, making it very convenient for researchers.

E. Image Classification Model

The Image Classification Model is a classifier that was created to identify or classify groups of image data. The classifiers use rule-based classifiers which are processed under a "condition" that is defined in the IF condition THEN conclusion form. Image classification model with a content-based feature in which researchers must extract features for suit methods such as support vector machine (SVM), k-nearest neighbor (KNN) and decision trees (DT), etc. [19-24].

The deep learning model is the popular automated method. The model gives high predictive performance [25] by mimicking the operation of human neurons by building a neural network with multiple nonlinear processing layers [14, 26]. Each layer takes the result of the previous layer as input. The strength of deep learning is that it supports the extraction of ambiguous features. The model extracts feature automatically. The researcher is responsible for preparing the data that will be used for learning only. It is very convenient for researchers.

F. Literature Reviews

This research focuses on reviewing literature related to fruit classification to study methods that can be used to classify Thai dragon fruit from images. Literature reviews are found that most researchers carried out research in four major steps: data acquisition, data pre-processes, feature extraction, and classification [15, 27]. Image datasets used include both image datasets created in the laboratory [22, 24, 28-31] and image datasets created at the outdoor environment [20, 23, 32-37]. Of course, image datasets from outdoor environments are more complex than those created in laboratories. Therefore, the steps to process this type are also more complicated.

Most researchers focused on image pre-processing like image segmentation techniques to prepare image data differently. Either the graph cut method [20], the conversion of a color image to a binary image by calculating the threshold value [8, 29], or using machine learning to segment the fruit from the background. This can be applied to the detection of fruit on the tree [23, 33, 34, 36, 37]. It reduces the complexity of the image and improves efficiency in feature extraction and classification. Muresan and Oltean [28] has proposed the use of threshold values in image segmentation with the HSV color model to separate the dragon fruit from the background of the plant. The objective is to detect and count the amount of dragon fruit on the tree by the image dataset of *Hylocereus Undatus* dragon fruit species in the outdoor environment. The accuracy is more than 80%.

Jana. et al. [20] has presented the recognition of fruits from the natural image in eight types. The image data was prepared by the graph cut method, which can separate the background from the fruit very well. After the image data preparation step, color and texture features were used for fruit recognition with the support vector machine (SVM) algorithm, giving an accuracy of 83.33%.

Muhammad [22] presented the use of color, texture, shape, and size attributes in classifying four date palm species by histogram of the local binary pattern (LBP) and Weber local descriptor (WLD) data. The Fisher discrimination ratio (FDR) was used to select the top 10 most important features that gave the greatest FDR. For shape and size features, the image data were analyzed from four features, namely Major axis length, Minor axis length, Ellipse eccentricity, and Area. In total, there are 14 features with a support vector machine (SVM) which gives an accuracy of up to 99%.

Fu. et al. [23] has presented the detection of bananas on the tree with machine learning. There is an image data pre-processing to reduce the complexity of the image by using Otsu's algorithm to find threshold values for converting HSV images to binary images. In the detection process, a histogram of oriented gradients (HOG) and local binary patterns (LBP) were used to extract the shape and texture features of the banana. The experiments found that the algorithm which combines HOG, LBP, and SVM gives maximum efficiency. It has an accuracy of 100% for the training set and 89.63% for the test set.

The DIPDEEP method [8] was the classification of Thai dragon fruit from a laboratory images dataset. DIPDEEP used image processing techniques to prepare images based on a threshold value to separate the background from the dragon fruit. Then, the images were used to classify the seven cultivars using rule-based classification techniques to classify dragon fruit groups by skin color and deep learning model based on a 13-layers of convolutional neural network that starts with an RGB image size of 100x100 pixels as an input layer and ends with six output nodes. Optimizer based on Adam algorithm and set Learning rate equal to 0.001, batch size and epoch equal to 100. The accuracy of red and yellow classification was 100%, the accuracy of DIPDEEP was 98.80%. For outdoor images, the results were not satisfactory.

The CBML model [9] was the classification of Thai red dragon fruit from a laboratory images dataset. CBML method used a content-based model that uses a total of 34 attributes, consisting of two attributes of texture features from dissimilarity (D) and asm properties only directions: 0° of GLCM algorithm with RGB image and 32 attributes of color features with RGB, HSV, and AB of Lab color model, for each channel in any color model using four statistical features: mean, standard deviation, skewness, and kurtosis. Each attribute used minmaxscaler to normalize into the 0 to 1 range and uses machine learning for giving optimization results with the support vector machine (SVM), setting kernel for polynomial in 8 degrees. It has an accuracy of 100% for the training set and 98.47% for the test set. The outdoor image was not processed.

Therefore, this paper focused on modeling the classification of Thai dragon fruit species from images that support two types of image datasets; laboratory and outdoor. The required model will support pre- and post-harvest processing. Hopefully, this research will be applied to industrial applications and agriculture technology.

III. THE DIP-CBML METHOD

This paper presents algorithms to classify species of Thai dragon fruits automatically that support two types of image datasets called DIP-CBML which stands for digital image processing with content-based and machine learning. The DIP-CBML will be able to process both types of images when DIP-CBML is able to classify the image types. It makes subsequent processing work correctly according to the characteristics of the two image types which are different processes. If the DIP-CBML can classify the group of dragon fruit from the peel color which is red or yellow, the processing time was reduced because the yellow group takes shorter time to process than the red group. Therefore, the DIP-CBML structure consists of image type identification, pre-processing, red and yellow classification, image background removal, and six classes of red classification as Fig. 1.

A. Datasets

The image datasets consisted of 9,754 laboratory images and 9,067 outdoor images from [8], each image containing one dragon fruit of one species. Both datasets were taken with a mobile phone camera. The 1:1 aspect ratio was set for laboratory recording. Unlike the outdoor images, the aspect ratio is set independently, i.e., 3:4 and 9:16, resulting in different image sizes with any lighting conditions.

In addition, the characteristics of the images are different, because the images in the laboratory are an image of the post-harvest dragon fruit placed in a photographic box and used black velvet fabric in the background as Fig. 2(a), but the outdoor images are the dragon fruit growing on the tree until it is ready to be harvested as Fig. 2(b). Obviously, the outdoor images have more complex backgrounds such as sky, ground, grass, and branches, while the laboratory images have a black background.

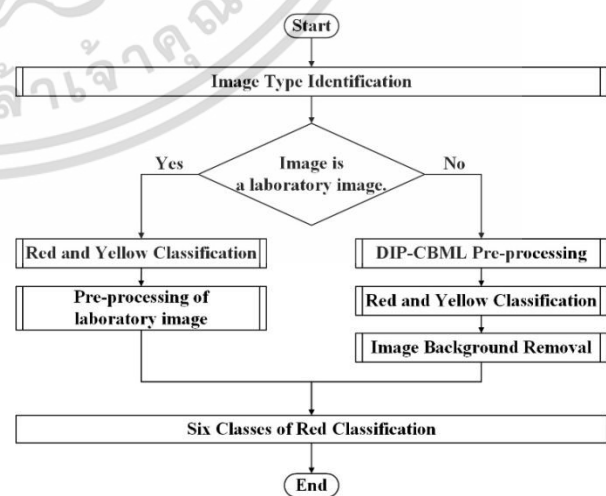


Fig. 1. The Steps of DIP-CBML method.




Fig. 2. Examples of two datasets as (a) laboratory images and (b) outdoor images.

B. Image Type Identification

This step is used to identify the type of images from either laboratory image or outdoor image because the image data pre-processing of the two types are different. The procedure is shown in algorithm 1.

Algorithm 1: Image Type Identification

```

Input: Original image with RGB color model.
Output: Type of image; laboratory or outdoor.
Resized Image = Resize the input image to not over 300 on each side.
R = R channel of Resized Image.
Gray = Gray scale of Resized Image.
Mean Threshold = (Sum of R value)/(image size)
MKR = The conversion result of R image to binary by Mean Threshold.
BG Pixel = The gray pixel at the same coordinate as a black pixel in the MKR.
If (BG Pixel != 0) then
    MP = Mean value of BG Pixel
    STD = Standard Deviation value of BG Pixel
    KS = Kurtosis value of BG pixel
    If (MP < 31.77) then
        | Output is a laboratory image type.
    else if (MP > 48.62) then
        | Output is an outdoor image type.
    else
        If (STD < 15.27) then
            | Output is a laboratory image type.
        else if (STD > 20.52) then
            | Output is an outdoor image type.
        else
            If (KS >= 8.32 && KS <= 54.37) then
                | Output is a laboratory image type.
            else
                | Output is an outdoor image type.
            End
        End
    End
End
else
    | Output is an outdoor image type.
End
    
```

From the characteristics of the laboratory images with a flat background, it is not as complex as the outdoor images. Therefore, the three statistical properties of the background pixels are used to identify the type of images. There are the mean, standard deviation, and kurtosis as shown in Fig. 3.




Fig. 3. The statistical properties of each type of image.

From the random 700 samples of each type of image, it was found that the laboratory images had an average of background pixels in a gray level ranging from 2.39-48.62 and outdoor images in ranging 31.77-196.22, because there is an overlap range. When considering the other statistics of the overlapping range, it was found that other statistics such as mode, median, standard deviation and skewness still overlap. Therefore, the statistics value that has the least overlap is the standard deviation. From the overlapping average range, it was found that the laboratory images had a standard deviation of background pixels in a gray level ranging from 6.88-20.52 and outdoor images from 15.27-44.78. Successively, at the overlapping standard deviation range, it was found that a kurtosis of background pixels in a gray level range is not overlapping. The laboratory images had a kurtosis of background pixels in a gray level ranging from -0.15-5.71 and outdoor images from 8.32-54.37.

Therefore, this step begins with the original image being reduced to a size of no more than 300x300 in proportion. Set the R image to represent the R channel of the RGB image and Gray to represent the grayscale image. The R image was used to create a segmentation mask, which is a binary image, using the mean threshold as the threshold value for the binary conversion as equation (1).

$$\text{Mean Threshold} = (\text{Sum of R value})/(\text{image size}) \quad (1)$$

If any pixel of the R image is greater than the mean threshold, this pixel will be set to white as the object, otherwise, this pixel will be set to a black background. The morphology function opening is used to decrease noises of the object, the Fill Hole from OpenCV is used to fill in any hole in the object, and the morphology function erosion is used to slightly decrease the edges of the image, respectively. The result is the MKR mask, a binary image with black pixels as the background (BG) as shown in Fig. 4 on the 2rd row.




Fig. 4. Characteristics of Laboratory and Outdoor images after converting to binary mask by using the mean threshold.

For an image where background pixels are not found, it can be concluded that it is an outdoor image. On the other hand, calculate the mean, standard deviation and kurtosis of BG pixels which is a gray pixel at the same coordinate as a black pixel in the MKR and replace mean with MP, replace standard deviation with STD and replace kurtosis with KS.

As mentioned above, the mean of the background pixels of both images overlaps. Therefore, the type of image can be clearly identified. An image with an average less than 31.77 is a laboratory image. An image with an average greater than 48.62 is an outdoor image. If any image is within the overlapping average range of the background pixels which is from 31.77-48.62, consider a standard deviation of the background pixels instead. If a standard deviation of the background pixels less than 15.27, an image is a laboratory image. If a standard deviation of the background pixels greater than 20.52, an image is an outdoor image. As the same, any image is within the overlapping standard deviation range of the background pixels which is from 15.27-20.52, consider a kurtosis of the background pixels instead. If a kurtosis of the background pixels between 8.32 and 54.37, an image is a laboratory image. On the other hand, that image was an outdoor image.

C. DIP-CBML Pre-processing

As mentioned above, the image data pre-processing of the two types are different. The laboratory image can use the process of creating MKR mask as image pre-processing but not for an outdoor image. Therefore, the pre-processing of DIP-CBML was used to support an outdoor image especially. This process still aims to separate the background from the dragon fruit by creating a mask that can be used to divide into two parts. The steps as shown in algorithm 2 and Fig. 5, DIP-CBML uses the graph cut algorithm to create the segmentation mask. It is generally known that graph cut requires a position of interest object covered in a rectangle. Therefore, it needs to locate the dragon fruit before the graph cut algorithm was used to create the segmentation mask.

To locate the dragon fruit, the HSV color model was used to create a binary image that helps locate the fruit in the image by HSV ranging same as [8] which consists of the H range, S range, and V range in the OpenCV system. There are H ranging from 0-23 and 151-179 for a red and 23-37 for a yellow. For S and V ranging from 100-255. The result is a binary image that is created by any pixel in the HSV image within this range will be scaled as a white pixel represent for a fruit pixel. On the contrary, a black pixel is an out of range; represent for a background pixel. Then, bring the binary image

to the detect location of dragon fruit subprogram as shown in Fig. 5.

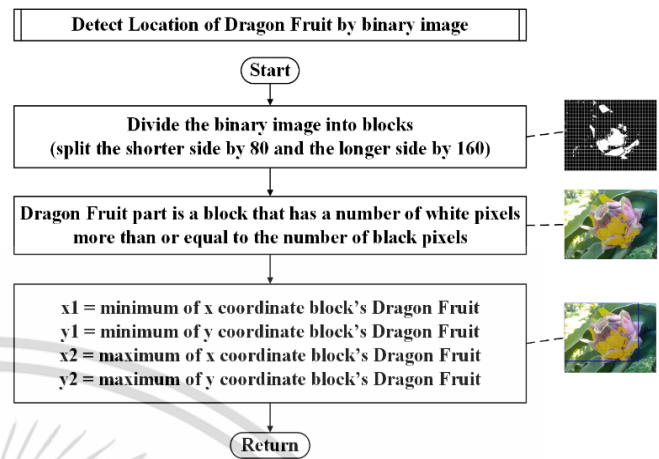


Fig. 5. Flowchart of detecting dragon fruit location.

In Fig. 5, the binary image is divided into grid blocks by that have no more than 160x80 blocks. The size of each block was calculated by dividing the shorter side by 80 and the longer side by 160. For example, the image size is 4,608x2,240 pixels, the longer side was divided, as $4,608/160 = 28.8$ approximated 29, and the shorter side was divided, as $2,240/80 = 28$. Therefore, each block size is equal to 29x28 pixels. Then, the binary image is segmented into many blocks with 29x28 pixels as the grid block size. From this block size, the number of blocks is equal to 158x80 blocks. The number of blocks is not over 160x80 blocks. Any block with the number of white pixels greater than or equal to the number of black pixels is defined as part of the dragon fruit. The position of all the blocks that are part of the dragon fruit is the location of the fruit. If all blocks are merged into one rectangle then let x1 equal the minimum value of the x-coordinate, y1 equal the minimum value of the y-coordinate, x2 equal the maximum value of the x-coordinate, and y2 equal the maximum value of the y-coordinate. The coordinate (x1,y1) is the northwest corner of the rectangle, and the coordinate (x2,y2) is the southeast corner of the rectangle. The coordinates (x1,y1,x2,y2) will be the boundary used to segment the image with the graph cut, which must not be equal to the border of the image. If the coordinates (x1,y1,x2,y2) is equal to the border of the image, the binary image was modified by the morphology function erosion with kernel size 5x5 and returned to the detect location of dragon fruit processes until the coordinates are not equal to the border of the image. Then, the coordinates (x1,y1,x2,y2) were set as the rectangle that will be used to create the mask by the graph cut algorithm that can separate the background from the dragon fruit.

To create the mask, DIP-CBML uses a graph cut algorithm with the coordinates which were modified to four directions, namely (x1,y1,x2,y2), (0,y1,x2,y2), (x1,0,x2,y2), and (0,0,x2,y2) because the background around the fruit was removed as shown in Fig. 6. The four results are RGB color images, converted them to a mask that is a binary image by setting the part of the dragon fruit to be a white pixel and the

background part to be black. Then we bring all four masks to the white pixels together with an intersection mask represented by the HSV1-Mask.

The HSV1-Mask can be used to separate the background from the dragon fruit where black pixels refer to the background and white pixels refer to dragon fruit. Any coordinate in RGB image that has the same coordinates as a background pixel are changed to 0. The result is RGB image with some or all of its background black, represented by the Image-HSV1. The illustration of DIP-CBML pre-processing as shown in Fig. 6 and the result of this step is shown in Fig. 7(b).

Algorithm 2: DIP-CBML pre-processing

```

Input: Original image with RGB color model.
Output: Image-HSV1, HSV1-Mask, and Coordinates (x1,y1,x2,y2).
hsv_img = Result of converting input image RGB to HSV color model.
binary_img = Result of converting hsv_image to binary by HSV ranges from [8]
(x1,y1,x2,y2) = Return values of Detecting Dragon Fruit Location by binary_img

While ((x1,y1,x2,y2) == Border of image) do
    Erosion binary_img with kernel 5x5
    (x1,y1,x2,y2) = Return values of Detecting Dragon Fruit Location by eroded binary_img
End

IMG1, IMG2, IMG3 and IMG4 = Return values of Grab Cut 4Directions by Coordinates (x1,y1,x2,y2).
M1, M2, M3 and M4 = Return values of Converting IMG1, IMG2, IMG3 and IMG4 to mask

HSV1-Mask = Result of Intersection all Masks (M1, M2, M3 and M4)
Image-HSV1 = Output of Removing Background by HSV1 Mask
    
```




Fig. 6. Illustration of DIP-CBML pre-processing.




Fig. 7. Examples of output with DIP-CBML pre-processing (a) Original images (b) Image-HSV1.

D. Red and Yellow Classification

Red and yellow classification is the procedure to classify the dragon fruit group into two groups using the characteristics of its peel color, consisting of dragon fruit red peel, and yellow peel. This process has already been discussed in [8]. The laboratory images can use the original image for processing. The results of the laboratory images are highly satisfactory, but the results of outdoor images are not. Therefore, in this research, the Image-HSV1 was used as an input image to classify the dragon fruit groups based on peel color instead of the original image.

The process uses HSV color images to calculate the red ratio and yellow ratio by using the HSV range of red and yellow as the threshold value for counting the number of red pixels and the number of yellow pixels. There is an H value from 23-37 for yellow. The red is divided into two ranges: 0-23 and 151-179. The Saturation (S) and Value (V) values are set from 100-255. Then divide each value by the image size and multiply by 100 to calculate the percentage as Eq. (2) and (3). If any image has a yellow ratio greater than a red ratio, it is an image of yellow peel. The method can immediately be classifying the species of dragon fruit in the image because there is only one species of yellow peel in the dragon fruit.

$$Yellow\ ratio = \frac{YP}{(image\ size)} * 100 \quad (2)$$

$$Red\ ratio = \frac{RP}{(image\ size)} * 100 \quad (3)$$

where YP is the number of yellow pixels and RP is the number of red pixels.

This work has performed greatly for the results of outdoor images. For laboratory images, the results are still satisfactory. This step reduces the volume of the dataset because the remaining data are red peel groups and affects processing time. It is an advantage of adding this step into research operations.

E. Image Background Removal

Image background removal is a process in which only the background is removed from the image. From Fig. 7(b), the pre-process can remove the background of some images completely, especially the laboratory images. While some outdoor images still have backgrounds left. Therefore, DIP-CBML added this process to remove the remaining background, especially the outdoor image by following the steps in algorithm 3. The illustration of image background removal process is shown in Fig. 8.




Fig. 8. Illustration of image background removal.

Algorithm 3: Image Background Removal

Input: Original image with RGB color model.
 Output: Fit scaled image.
 HSV2-Mask = Result of remaining background removal by HSV color model.
 A-Mask = Result of background removal by Lab color model.
 HSVA-Mask = Result of Intersection A-Mask and HSV2-Mask
 Erosion Mask = Result of Erosion HSVA-Mask with kernel 5x5
 Filled Hole Mask = Result of Fill Hole HSVA-Mask by OpenCV Library
 Removed Background Image = Result of Removing Background in the input image by Filled Hole Mask
 Fit Scaled image = Result of cropping proportion of fruit and fit scale its size not over 100 on each side

This process is designed with two background removals, first using an output of pre-process procedure as shown in algorithm 2; input to a subprogram of the remaining background removal by the HSV color model and the second using the original image input to subprogram of the background removal by lab color model. Both subprograms yield two masks named HSV2-Mask as Fig. 10(b) and named A-Mask as Fig. 10(c) respectively. After that take the two masks to the intersection represented by the HSVA-Mask as Fig. 10(d). Use the morphology function erosion to remove extraneous pixels in the HSVA-Mask with kernel size 5x5 and fill the hole with the OpenCV library. Then use the modified HSVA-Mask to remove the background from the image where black pixels refer to background pixels and white pixels refer to dragon fruit pixels. Any coordinate in the original RGB image with the same coordinate as the background pixel will be changed to 255. The result will be a dragon fruit image with a white background, as Fig. 10(e), and the final step is to fit scale the image of the dragon fruit proportion to 100x100 pixels, the result is Fig. 10(f).

1) *Subprogram of remaining background removal by HSV color model:* This subprogram is the remaining background removal process. The input data is the result of pre-processing as shown in algorithm 2 and Fig. 6. consisting of Image-HSV1, HSV1-Mask, and Coordinates (x1,y1,x2,y2). This data will be used as initial processing steps in the algorithm 4 which is processed similarly to pre-processing as mentioned in Section 3(C). The output of the pre-processing procedure was reprocessed again to remove any pixel that expected part of the background out of the image. The final output of this subprogram is a binary image named HSV2-Mask that can be used to split the background off.

As algorithm 4, starting from the processing of the check mask and image subprogram as shown in algorithm 5, the Image-HSV1 is recalculated for the yellow ratio and the HSV1-Mask is detected for the new coordinates, represented by coordinates (a1,b1,a2,b2) by the detect location of dragon fruit subprogram as Fig. 5 and take the coordinates (a1,b1,a2,b2) to remove the background from the image by 4 graph cut. The result is a binary image represented by the RM-Mask.

If the background has been completely removed, the yellow ratio of Image-HSV1 will be equal to 0 that means not a yellow pixel in the image already or the new coordinates (a1,b1,a2,b2) must be equal to the old coordinates (x1,y1,x2,y2) that means if continue to remove background again, the result is still the same, but if these conditions are not met, the RM-Mask will be used as a mask to remove the background from the original image again; where black pixels refer to background pixels and white pixels refer to dragon fruit pixels. Any coordinate in RGB image that has the same coordinates as a background pixel is changed to 0. The result is RGB image represented by Image-HSV2. The yellow ratio of Image-HSV2 is recomputed and increases the value of the NR variable by 1 to count the number of background removal attempts. This will not remove the background more than 3 times.

After that, if the yellow ratio of Image-HSV2 is equal to 0 or the coordinates (a1,b1,a2,b2) are equal to the original coordinates. (x1,y1,x2,y2) sets the HSV2-Mask value to be the same as the RM-Mask and terminates the subprogram immediately because the background is considered eliminated, but if the conditions are not met, it will continue to remove the background by using the RM-Mask as the initial data to remove the next background.

The process is restarted using the RM-Mask as the starting point, creating a new set of inputs: specifying new (x1,y1,x2,y2) coordinates with the detect location of dragon fruit subprogram, creating a new HSV1-Mask by 4 Graph Cut that used new (x1,y1,x2,y2) coordinates and reconstructing new Image-HSV1 with a new HSV1-Mask. After that, the new HSV1-Mask and new Image-HSV1 were processed with the check mask and image subprogram again to compute the yellow ratio, specify the coordinates (a1,b1,a2,b2), and finally create a new RM-Mask. This new RM-Mask will be used to reconstruct the Image- HSV2 and calculate the yellow ratio of the new Image-HSV2, with the NR variable increased by 1 as before. The image with the background removed will have a yellow ratio of 0 or coordinates (a1,b1,a2,b2) equal to coordinates (x1,y1,x2,y2). If this condition is met, the background removal will be stopped. Set the mask HSV2-Mask as same as RM-Mask. On the other hand, we will remove the background repeatedly, but not more than three times, because it may remove the background too much and cause the dragon fruit part to be removed as well. The results obtained from this step are shown in Fig. 10(b).

Algorithm 4: Remaining Background Removal by HSV Color Model

```

Input: Image-HSV1 , HSV1-Mask and (x1,y1,x2,y2).
Output: HSV2-Mask.
Yellow_Ratio, (a1,b1a2,b2) and RM-Mask = Return values of Check Mask and Image by Image-HSV1 and HSV1-Mask.

NR = 0 /*stand for number of removing*/
If (Yellow_Ratio == 0) then
    | RM-Mask = HSV1-Mask
else
    | If ((a1,b1a2,b2)==(x1,y1,x2,y2)) then
        | RM-Mask = HSV1-Mask
        | Yellow_Ratio = 0
    else
        | Image-HSV2 = Remove Background by RM-Mask
        | Yellow Ratio = Yellow Ratio of Image-HSV2
        | NR++
    End
End
While (Yellow_Ratio!=0 && (a1,b1a2,b2)!=(x1,y1,x2,y2)) do
    | If (NR<=3) then
        | (x1,y1,x2,y2) = Detecting Dragon Fruit Location by RM-Mask
        | While ((x1,y1,x2,y2) == Border of image) do
            | Erosion RM-Mask with kernel 5x5
            | (x1,y1,x2,y2) = Return values of Detecting Dragon Fruit Location by eroded RM-Mask
        End
        | HSV1-Mask = GrabCut 4Directions by (x1,y1,x2,y2)
        | Image-HSV1 = Remove by HSV1-Mask
        | RM-Mask = Return values of Check Mask and Image by Image-HSV1 and HSV1-Mask.
        | Image-HSV2 = Remove background by RM-Mask
        | Yellow_Ratio = Yellow Ratio of Image-HSV2
        | NR++
    else
        | Yellow_Ratio = 0
    End
End
HSV2-Mask =RM-Mask
    
```

Algorithm 5: Check Mask and Image Subprogram

```

Input: image and mask data.
Output: Yellow_Ratio of input image, Coordinates (a1,b1a2,b2) and RM-Mask.
Yellow_Ratio = Yellow Ratio of input image.
(a1,b1,a2,b2) = Detect Location of Dragon Fruit by input mask.
RM-Mask = GrabCut 4Directions by (a1,b1,a2,b2)
    
```

2) *Subprogram of background removal by lab color model:* The subprogram of background removal by lab color model is a process that uses Lab color model's properties to remove background pixels as shown in the algorithm 6. The illustration of background removal by lab color model process

as shown in Fig. 9. First, the original image, which is RGB color model, is converted to a Lab color model. After that, a channel is split and converted to a binary image by Otsu' Threshold. Take the binary image into the process of the detect location of dragon fruit subprogram as shown in Fig. 5, which gives the coordinates (x1,y1,x2,y2) as the location of the dragon fruit.

As before, take the coordinates (x1,y1,x2,y2) as the rectangle that will be used to remove the background from the image by graph cut with four directions. If (x1,y1,x2,y2) is the same coordinate as the border of the image, Use the morphology function erosion with kernel size 5x5 to modify the binary image before reading the new position again until the coordinates (x1,y1,x2,y2) are not equal to the border of the image.

Take the results from graph cut with four directions and convert them to a mask. Make the dragon fruit part into white pixels. The background part is black. Bring all four masks to find the white pixels together by using the intersection area. The result is a binary image, represented by A-mask which can be used to remove the background from the image. The results obtained from this step are shown in Fig. 10(c).

Algorithm 6: Background Removal by Lab Color Model

```

Input: Original image with RGB color model.
Output: A-Mask.
lab_img = Result of converting input image RGB to Lab color model.
binary_img = Result of converting A channel of lab_img to binary image by Otsu's Threshold
(x1,y1,x2,y2) = Return values of Detecting Dragon Fruit Location by binary_img
While ((x1,y1,x2,y2) == Border of image) do
    | Erosion RM-Mask with kernel 5x5
    | (x1,y1,x2,y2) = Return values of Detecting Dragon Fruit Location by eroded binary_img
End
IMG1, IMG2, IMG3 and IMG4 = Return values of Grab Cut 4Directions by Coordinates (x1,y1,x2,y2).
M1, M2, M3 and M4 = Return values of Converting IMG1, IMG2, IMG3 and IMG4 to mask
A-Mask = Result of Intersection all Masks (M1, M2, M3 and M4)
    
```




Fig. 9. Illustration of background removal by lab color model subprogram.




Fig. 10. Example Output of image background removal (a) HSV1-Image is an input image. (b) HSV2-Mask is an output from subprogram of remaining background removal by HSV color model. (c) A-Mask is an output from subprogram of background removal by Lab color model. (d) HSVA- Mask is an output from intersection A-Mask and HSV2-Mask process. (e) Output from remove background by HSVA-Mask process. and (f) Output from fit scale fruit to 100x100 process.

F. Six Classes of Red Classification

From the procedure in Fig. 1, this method classifies the dragon fruit into two groups from the peel color. Because there is only one species of yellow-skinned in the dataset. For red-skinned dragon fruit, the background in the image will be removed. Then, the dataset will leave only the image of six species of red peel. Therefore, at this stage, only the red-skinned dragon fruit species will be classified by using the content-based technique and deep learning.

Classification using the content-based technique in this research is divided into two parts: feature extraction and classification model. The feature extraction section consists of 24 color attributes, 3 texture attributes, and 2 attributes from edge and line feature. A total of 29 attributes are used as shown in Table I. In The classification model section used a machine learning method by support vector machine algorithm (SVM) with polynomial kernel (degree = 11).

The deep learning models such as DIPDEEP[8], VGG16[38], ResNet50[39], and MobileNetV2[40] were used to classify six species of red peel dragon fruit. All models start with an RGB image size of 100x100 pixels as an input layer and end with six output nodes. There is an optimizer using the Adam algorithm. The learning rate was set at 0.001. For the training process, the batch size and epochs were set at 100. The remaining parameters are not specified using all Keras default values.

For an experiment, DIP-CBML was compared with CBML[9] which is the model that uses content-based

techniques, and DIPDEEP[8], VGG16[38], ResNet50[39], and MobileNetV2[40] are the models that use deep learning techniques.

TABLE I. FEATURE EXTRACTION OF DIP-CBML METHOD

Extracted Features	Description	Feature Dimension
Colors	Statistical features (mean, standard deviation, skewness, kurtosis) extracted from color channel R,G,B of RGB color model H of HSV color model and a, b of Lab color model.	24
Texture	Properties features (dissimilarity, contrast and asm) extracted from GLCM of RGB only 0° direction.	3
Edge and Line	The ratio of edge pixels from Canny Edge algorithm and the number of lines from Hough Transform Standard algorithm	2

G. Feature Extraction of DIP-CBML

1) *Color feature*: Color features used in this research include statistical properties of the RGB, HSV, and Lab color models. All three models were split from three channels to one channel to get six image data: Red (R), Green (G), Blue (B), Hue (H), Red/Green Value (a), and Blue/Yellow Value (b). The pixel data of each image were calculated for the mean, standard deviation, skewness, and kurtosis as Eq. (4) to (7) [41]. The total of color features is 24 attributes.

$$Mean = \frac{1}{N} \sum_{k=0}^{N-1} P_k \quad (4)$$

$$Standard\ Deviation = \sqrt{\frac{1}{N} \sum_{k=0}^{N-1} (P_k - Mean)^2} \quad (5)$$

$$Skewness = \frac{\frac{1}{N} \sum_{k=0}^{N-1} (P_k - Mean)^3}{\left[\frac{1}{N} \sum_{k=0}^{N-1} (P_k - Mean)^2 \right]^{\frac{3}{2}}} \quad (6)$$

$$Kurtosis = \frac{\frac{1}{N} \sum_{k=0}^{N-1} (P_k - Mean)^4}{\left[\frac{1}{N} \sum_{k=0}^{N-1} (P_k - Mean)^2 \right]^2} - 3 \quad (7)$$

where P_k is the pixel value in order k of image pixel and N is the number of image pixels.

2) *Texture feature*: Texture features used in this research are the features from the gray-level co-occurrence matrix (GLCM) algorithm of RGB images. For feature extraction, importing RGB images into the GLCM algorithm with the skimage.feature library. Three features of GLCM have been extracted: dissimilarity (D), angular second moment (ASM), and contrast (Ct). Each feature uses horizontal direction information (0°). For a total of three features as Eq. (8) to (10) [42,43].

$$Dissimilarity = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} g(i,j) \cdot |i-j| \quad (8)$$

$$Angular\ Second\ Moment = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (g(i,j))^2 \quad (9)$$

$$Contrast = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i-j)^2 \cdot g^2(i,j) \quad (10)$$

where n is the number of gray levels, $g(i,j)$ is the value of GLCM normalized where i and j are column and row numbers of GLCM normalized as a square matrix $n \times n$ in size. The values of i and j are between 0 and $n-1$.

3) *Edge and line features*: Edge and line features are representative of the density of the bracts surrounding the dragon fruit. If there are many bracts, the number of edges and lines will also be large. Each specie of dragon fruit has different a number of bracts. The edge of a fruit part and the direction of a line seem to be characteristics of dragon fruit. The edge and line may be a suitable feature for modeling the dragon fruit classification. Edge and line features are used in this research include the edge pixel ratio by processing with the canny edge algorithm[44,45] and the number of straight lines by processing the hough transform algorithm[46,47].

The canny edge algorithm [44,45] is a popular edge detection algorithm with multi-steps used to detect any pixel expected that is the edge of the object in the image. It consists of the noise removal with a 5x5 Gaussian filter, finding the intensity gradient of the image and direction, removing any unwanted pixels by a local maximum in its neighborhood in the direction of gradient and the last step is selecting whether the pixel expected is the edge or not by two threshold values, $minVal$ and $maxVal$. Any pixels with an intensity gradient more than $maxVal$ are sure to be edges and less than $minVal$ are sure to be non-edges. Any pixels with an intensity gradient between two thresholds are identified as edges or not by their connectivity. If they are connected to the sure-edge pixels, they are decided to be part of the edges. Otherwise, they will be rejected. It is very important to define two thresholds to get the correct result.

Therefore, to get an edge pixel ratio, this method uses the output image of the image background removal process which is the image that was scaled of the dragon fruit proportion to 100x100 pixels as shown in Fig. 10(f) and converted to a grayscale image. Then bring the grayscale image to frequency distribution by histogram. Set the data layer equal to 10. Use the lower boundary of the first layer and the last layer as lower threshold as $minVal$ and upper threshold as $maxVal$ respectively. The thresholds are processed to determine edge pixels using the canny edge algorithm through the `cv.Canny` function of the OpenCV library[45]. The resulting image is a binary image with white pixels representing the edge pixels. So, the edge pixel ratio is equal to the number of white pixels divided by the image size and times 100, as shown in Eq. (11).

$$Ratio\ of\ Edge = (Edge\ pixels/image\ size) * 100 \quad (11)$$

For the line features, the Hough transform algorithm[46,47] was used. Typically, it is a detection of the shape in the picture; that shape can be represented in a mathematical form such as lines, circles, ellipses, etc. It can detect the shape even if it is broken. This paper focuses on the straight line detection. The line equation in parametric form as shown in Eq. (12).

$$y = x \cos\theta + \rho \sin\theta \quad (12)$$

where x,y is a pixel coordinate, ρ (rho) is the perpendicular distance from the origin to the line, and θ (theta) is the angle by

this perpendicular line and horizontal axis measured counter clockwise.

That means any pixels that are on the same line, have the same ρ and θ value. The first step of the algorithm is creating a 2D array as the accumulator, to collect the calculated values of each pair of ρ and θ for each pixel. The array initial with a zero value. Let rows equal to the ρ and columns equal to the θ . Any pixel was expected to be an edge of the object in the image, the ρ was computed by the pixel coordinate (x,y) and every possible θ . Then increment the values by 1 in the accumulator at the column and row that correspond to the ρ and θ value that is a result of computing. The number in each cell of the accumulator means the number of pixels that can be on the same line. In the last, this algorithm required minimum voting as a threshold to decide the group of pixels that can be the line. It may be the minimum length of the line that should be detected.

Therefore, to get the number of straight lines, this method takes the results of the canny edge algorithm to be processed, using the function `cv.HoughLines` of the OpenCV library[47], setting ρ which is the distance resolution of the accumulator in pixels to 1, and θ which is the angle resolution of the accumulator in radians to $\pi/180$. An accumulator value was distributed to the histogram frequency, set the data layer equal to 11, take the data from layers two to six which are normal curve area, calculate the mean that rounded up to make an integer, and set it as the threshold as a minimum length of the line that should be detected. Finally, get the number of straight lines from the result of the `cv.HoughLines` function. From the hypothesis, any dragon fruit with more bracts around the fruit will also have more straight lines.

4) *MinMaxScaler*: Because the result of the feature extraction mentioned above gives results in numbers with different scales. Therefore, this method adjusts the scale to the same scaling by `MinMaxScaler` which will have a scale between 0 to 1 by using the formula as in Eq. (13).

$$MinMaxScaler\ Transform = (x - min) / (max - min) \quad (13)$$

where x is the data, min is the lowest value in the column, and max is the maximum value of the data in the column.

IV. EXPERIMENTAL RESULTS

The image dataset consists of 9,754 laboratory images and 9,067 outdoor images. Each dataset includes seven species of Thai Dragon Fruit. The laboratory images were divided into Jumbo White 1,172 images, Vietnamese White 1,190 images, Pink 1,309 images, Siam Red 1,869 images, Taiwan Red 1,184 images, Ruby Red 1,110 images, and Israel Yellow 1,920 images. The outdoor images were divided into Jumbo White 1,241 images, Vietnamese White 2,478 images, Pink 1,013 images, Siam Red 950 images, Taiwan Red 1,021 images, Ruby Red 871 images, and Israel Yellow 1,493 images.

The experiment was divided into three experiments. The first experiment is the image type identification. The second experiment is the red and yellow classification. The final experiment is the classification of six classes from the red peel group.

A. Experiment 1

The first experiment is the image type identification which is laboratory image or outdoor image. Before doing the experiment, images of two types were randomly selected 700 images per type (100 images per species) to study an average of background pixels in a gray level range. Test the range with all data. The experiment results are shown in Table II.

TABLE II. RESULTS OF IMAGE TYPE IDENTIFICATION

Types	Number of Samples	Accuracy (%)	Number of Samples	Accuracy(%)
Laboratory Image	700	100.00	9,754	100.00
Outdoor Image	700	100.00	9,067	100.00
Laboratory Image and Outdoor Image	1,400	100.00	18,821	100.00

B. Experiment 2

The Second experiment is the classification of the dragon fruit group from the peel color which is red or yellow. All images were divided into three methods. There are non-pre-processing, graph cut with [23] localization and pre-processing of DIP-CBML. The experiment results are shown in Table III.

TABLE III. CLASSIFICATION RESULTS BETWEEN RED AND YELLOW WITH THREE DIFFERENT METHODS

Types	Number of Samples	Accuracy(%)		
		Non-pre-processing	[23]+Graph Cut	Pre-processing of DIP-CBML
Laboratory Image	9,754	100.00	100.00	100.00
Outdoor Image	9,067	97.06	99.96	100.00
Laboratory Image and Outdoor Image	18,821	98.53	99.98	100.00

C. Experiment 3

The Third experiment is the classification of six classes from the red peel group by content-based and deep-learning models. The datasets used for this experiment are the results of the image background removal procedure, which is a dragon fruit image with a white background as Fig. 10(f). Before doing the experiment, the images were randomly selected at 1,000 per class. Any class with less number than 1,000 will be added to the image data by the augmentation technique. Here, this method uses only the horizontal flip image method because the required amount is only small. After that, create the dataset into four forms. The first form is only the 6,000 laboratory images in the dataset which were pre-processed by the creating MKR mask method, namely the Laboratory dataset. The second form is only the 6,000 outdoor images in the dataset which were pre-processed by the DIP-CBML method, namely the Outdoor dataset. The third form combined 12,000 images between the first form and the second form, namely the Mixdata1 dataset. The last form is combined images both the 6,000 laboratory images and the 6,000 outdoor images which are pre-processed by the DIP-CBML method, namely the Mixdata2 dataset. Each dataset was divided into 80%, 10%, and 10% for the training set, the validate set, and the test set, respectively. Using the 10-folds validation technique the DIP-

CBML was compared with CBML[9], DIPDEEP[8], VGG16[38], ResNet50[39], and MobileNetV2[40]. The experiment results are shown in Table IV.

V. DISCUSSION

This research presents the classification of Thai dragon fruit species from images that support two types of image datasets; laboratory and outdoor called DIP-CBML. The first experiment results showed that DIP-CBML can identify image types correctly with accuracy 100.00%. Therefore, the proposed method can support two types of images.

After identifying image types, the next process is the classification of the dragon fruit groups; red peel color and yellow peel color. The experiment results showed that the pre-processing of DIP-CBML was able to increase efficiency in classifying dragon fruit groups from peel color by 100% when compared to classifying by the original image. For graph cut with [23] localization, it was found that the dragon fruit group could be classified by the color of the peel with an accuracy of 99.98%. Therefore, the pre-processing of the DIP-CBML gives better results. The volume of the dataset was reduced because the process can stop when a yellow peel specie was founded, the remaining data are red peel groups which affect processing time.

Finally, dragon fruit images were changed the background to white and fit proportion of fruit size not over 100 on each side which were used to perform datasets for the classification of six classes from the red peel group. The experiment results showed that the DIP-CBML can get 100% accuracy for training set, but the other models do not. The DIP-CBML can classify six species of red peel group with 97.85%, 94.00%, 95.53% and 95.05% accuracy for Laboratory dataset, Outdoor dataset, Mixdata1 dataset and Mixdata2 dataset respectively. The confusion matrix of best accuracy which is Mixdata1 dataset can be shown in Fig. 11. and an example of the misclassified images is shown in Fig. 12.




Fig. 11. Confusion matrix of DIP-CBML classification method with Mixdata1 dataset.



Fig. 12. Examples of the misclassified images.

TABLE IV. COMPARISON FOR ACCURACY OF DIFFERENT CLASSIFICATION METHODS AND DIFFERENT DATASETS FOR 6 SPECIES OF RED PEEL RESULTS BY 10-FOLD VALIDATION

Method	Mean (SD.)											
	Laboratory			Outdoor			Mixdata1			Mixdata2		
	Train	Valid	Test	Train	Valid	Test	Train	Valid	Test	Train	Valid	Test
CBML[9]	100.00 (0.00)	98.28 (0.42)	98.47 (0.62)	99.83 (0.03)	95.17 (1.09)	94.82 (1.24)	99.90 (0.01)	96.54 (0.45)	96.38 (0.68)	99.91 (0.01)	95.98 (0.91)	95.88 (0.56)
DIPDEEP[8]	100.00 (0.00)	98.45 (0.62)	98.80 (0.48)	99.80 (0.05)	94.42 (0.72)	94.18 (1.25)	99.68 (0.31)	95.02 (0.95)	94.96 (1.08)	99.66 (0.39)	94.18 (1.40)	94.34 (0.93)
VGG16[38]	100.00 (0.00)	98.80 (0.32)	98.70 (0.41)	99.81 (0.14)	93.55 (1.46)	93.33 (1.70)	99.78 (0.32)	95.32 (0.81)	95.35 (0.94)	99.69 (0.57)	94.16 (1.40)	94.47 (1.23)
ResNet50[39]	99.73 (0.85)	99.13 (1.64)	99.13 (1.65)	93.27 (18.60)	89.18 (18.15)	89.70 (18.00)	98.37 (3.20)	95.58 (3.55)	95.98 (3.74)	95.26 (9.80)	92.44 (9.97)	92.42 (10.58)
MobileNetV2[40]	86.56 (11.86)	85.43 (12.36)	86.05 (11.85)	73.56 (16.65)	71.35 (16.75)	71.27 (15.63)	90.95 (5.30)	88.53 (5.51)	88.98 (5.58)	70.44 (22.63)	68.88 (21.86)	68.63 (21.94)
DIP-CBML	100.00 (0.00)	97.58 (0.79)	97.85 (0.92)	100.00 (0.00)	94.27 (0.67)	94.00 (0.97)	100.00 (0.00)	95.32 (0.56)	95.53 (0.50)	100.00 (0.00)	95.00 (0.72)	95.05 (0.72)

VI. CONCLUSION

For this paper, the characteristics of laboratory and outdoor images were used to create the classification of Thai dragon fruit species from images that support two image datasets. The DIP-CBML method is used in the completed work. The channel R of RGB color model and gray image were used to identify the type of images between laboratory and outdoor images. The DIP-CBML can identify image type correctly with an accuracy of 100.00% with all datasets. The HSV color model and graph cut algorithm were used to pre-process the images which are able to increase efficiency in classification of dragon fruit groups by peel color with 100% accuracy for outdoor images. As a significant result, the method can classify image group of the laboratory type correctly with 100% accuracy same as other methods. Especially, non-pre-processed gives the same result. Therefore, if the laboratory type was detected, the method can use the original image of laboratory image to classify image groups. The HSV color model, channel of Lab color model and graph cut algorithm were used to remove the background of image which changed the background into white and fit scale on dragon fruit part to 100x100 pixels. The DIP-CBML used these images to classify the six species of Thai red dragon fruit by 29 features from color, texture, edge and line feature. The method gives 95.53% accuracy for both image types with a different pre-processed method. Finally, the entire research process was completed with all components. The precision of each step influences the others. The DIP-CBML may be developed again to increase the accuracy of the last step. The DIP-CBML was designed for the classification, especially Thai dragon fruit species. For other fruits, the DIP-CBML may work or not. This is a challenge for future research. Hopefully, the proposed model will be a guideline for developers to develop tools that can classify species of Thai dragon fruit from images that support pre- and post- harvesting image datasets. This research will add value to the yield of Thai dragon fruit cultivation and can be applied to industrial applications harvesting with robots.

VII. SUGGESTION

After a laboratory image was detected, the DIPDEEP[8] method may be used in the final step because it gives an accuracy of 98.80%. After an outdoor image was detected, the purpose method was used with an accuracy of 95.53%. The

combination of several methods in one application is a good approach that works.

REFERENCES

- [1] R. Goenaga, A. Marrero, and D. Perez, "Yield and Fruit Quality Traits of Dragon Fruit Cultivars Grown in Puerto Rico," *Horttechnology*, United States, vol. 30, no. 6, pp. 803-808, October 2020. <https://doi.org/10.21273/horttech04699-20>.
- [2] T. Perween, K. Mandal, and M. Hasan, "Dragon fruit: An exotic super future fruit of India," *J. Pharmacogn Phytochem. India*, vol. 7, no. 2, pp. 1022-1026, February 2018.
- [3] A. Trivellini, M. Lucchesini, A. Ferrante, D. Massa, M. Orlando, L. Incrocci, and A. Mensuali-Sodi, "Pitaya, an Attractive Alternative Crop for Mediterranean Region," *Agronomy*, Switzerland, vol. 10, no. 8, 1065, July 2020. <https://doi.org/10.3390/agronomy10081065>.
- [4] S. Wichienchot, M. Jatupornpipat, and R.A. Rastall, "Oligosaccharides of pitaya (dragon fruit) flesh and their prebiotic properties," *Food Chem. United Kingdom*, vol. 120, no. 3, pp. 850-857, November 2009. <https://doi.org/10.1016/j.foodchem.2009.11.026>.
- [5] S. Kosiyachinda, "Dragon Fruit," in *Thai Youth Encyclopedia*, vol. 38, THAI JUNIOR ENCYCLOPEDIA FOUNDATION by His Majesty King Bhumibol Adulyadej The Great. Bangkok: Thailand, 2013, pp. 106-139.
- [6] National Bureau of Agricultural Commodity and Food Standards, Ministry of Agriculture and Cooperatives. Thai agricultural standard: Dragon fruit. Available online: <https://www.acfs.go.th/standard/download/eng/DRAGON-FRUIT-ENG.pdf> (accessed on 9 March 2023).
- [7] Department of Agricultural Extension, Ministry of Agriculture and Cooperatives. Agricultural production information service system. Available online: <https://production.doae.go.th/service/site/login> (accessed on 9 March 2023).
- [8] N. Yusamran, and N. Hirasakolwong, "DIPDEEP: Classification for Thai dragon fruit," *Eng. Appl. Sci. Res. Thailand*, vol. 49, no. 4 pp. 521-530, Mar 2022.
- [9] N. Yusamran, and N. Hirasakolwong, "CBML: Classification Thai Red Dragon Fruit," *ICIC Express Letters, Part B (ICIC-ELB)*, Japan, vol. 13, no. 11 pp. 1165-1175, November 2022. <https://doi.org/10.24507/icicelb.13.11.1165>.
- [10] S. Przybylek, and C. Cena, "What is a Color Model? - Uses & Definition. Available online: <https://study.com/academy/lesson/what-is-a-color-model-uses-definition.html> (accessed on 9 March 2023).
- [11] R. Parekh, *Fundamentals of image, audio, and video processing using Matlab®: with applications to pattern recognition*, 1st ed. Boca Raton, FL: CRC Press (Taylor and Francis group), 2021.
- [12] W. Burger, and M. J. Burge, *Principles of Digital Image Processing Fundamental Techniques*. NY: Springer Undergraduate Topics in Computer Science – UtiCS, 2009.

- [13] Opencv Python Tutorials. Changing Colorspaces. Available online: https://opencv24-python-tutorials.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_colorspaces/py_colorspaces.html (accessed on 9 March 2023).
- [14] M. Elgendy, *Deep Learning for Vision Systems*, 1st ed. Shelter Island, NY: Manning, 2020.
- [15] K. Hameed, D. Chai, and R. Alexander, "A comprehensive review of fruit and vegetable classification techniques," *Image Vis Comput. United Kingdom*, vol. 80, pp. 24-44, December 2018. <https://doi.org/10.1016/j.imavis.2018.09.016>.
- [16] S. Srisuk, *Advanced Image Processing*. Bangkok, TH: Mahanakorn University of Technology, 2013.
- [17] S. K. Abdulateef, and M. D. Salman, "A Comprehensive Review of Image Segmentation Techniques," *Iraqi Journal for Electrical and Electronic Engineering. Iraq*, vol. 17, no. 2, pp. 166-175, December 2021. <https://doi.org/10.37917/ijeee.17.2.18>.
- [18] O. Marques, *Practical image and video processing using MATLAB*. Hoboken, NJ: Wiley-IEEE Press, 2011.
- [19] N. T. Bani, and S. Fekri-Ershad, "Content-based image retrieval based on combination of texture and colour information extracted in spatial and frequency domains," *The Electron. Libr. United Kingdom*, vol. 37, no. 4, pp. 650-666, August 2019. <https://doi.org/10.1108/EL-03-2019-0067>.
- [20] S. Jana, S. Basak, and R. Parekh, "Automatic fruit recognition from natural images using color and texture features," In *Proc. the 2nd International Conference on 2017 Devices for Integrated Circuit. DevIC 2017*, pp. 620-624, March 2017. <https://doi.org/10.1109/DEVIC.2017.8074025>.
- [21] S. Arivazhagan, R. N. Shebiah, S. S. Nidhyandhan, and L. Ganesan, "Fruit Recognition using Color and Texture Features," *J. emerg. trends comput. inf. sci.*, vol. 1, no. 2, pp. 90-94, October 2010.
- [22] G. Muhammad, "Automatic date fruit classification by using local texture descriptors and shape-size features," In *Proc. the UKSim-AMSS 8th European Modelling Symposium on Computer Modelling and Simulation, EMS 2014*, pp. 174-179, October 2014. <https://doi.org/10.1109/ems.2014.63>.
- [23] L. Fu, J. Duan, X. Zou, G. Lin, S. Song, B. Ji, and Z. Yang, "Banana detection based on color and texture features in the natural environment," *Comput. Electron. Agric. Netherlands*, vol. 167, 105057, December 2019. <https://doi.org/10.1016/j.compag.2019.105057>.
- [24] J. F. Reyes, E. Contreras, C. Correa, and P. Melin, "Image analysis of real-time classification of cherry fruit from colour features," *J. Agric. Eng. Italy*, vol. 52, no. 4, pp. 1-6, December 2021. <https://doi.org/10.4081/jae.2021.1160>.
- [25] W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders, and K. R. Müller, "Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications," *Proc. IEEE.*, vol. 109, no. 3, pp. 247 - 278, March 2021. <https://doi.org/10.1109/JPROC.2021.3060483>.
- [26] J. Schmidhuber, "Deep Learning in Neural Networks: An Overview," *Neural Networks. United Kingdom*, vol. 61, pp. 85-117, January 2015. <https://doi.org/10.1016/j.neunet.2014.09.003>.
- [27] S. L. Raja, N. Ambika, V. Divya, and T. Kowsalya, "Fruit Classification System Using Computer Vision: A Review," *Int. j. trend res. dev. India*, vol. 5, no. 1, pp. 22-26, February 2018. <https://doi.org/10.31219/osf.io/kt75d>.
- [28] H. Muresan, and M. Oltean, "Fruit recognition from images using deep learning," *Acta Univ. Sapientiae, Inform. Romania*, vol. 10, no. 1, pp. 26-42, August 2018. <https://doi.org/10.2478/ausi-2018-0002>.
- [29] R. E. Masithoh, H. Tampani, and L. Sutiarso, "Detection of White Dragon Fruits (*Hylocereus Undatus*) in Outdoor Environment Using Image Processing Technique," *Aust. J. Basic & Appl. Sci. Jordan*, vol. 7, no. 9, pp. 254-260, July 2013.
- [30] M. Momeny, A. Jahanbakhshi, K. Jafarnejad, and Y. D. Zhang, "Accurate classification of cherry fruit using deep CNN based on hybrid pooling approach," *Postharvest Biol. Technol. Netherlands*, vol. 166, 111204, August 2020. <https://doi.org/10.1016/j.postharvbio.2020.111204>.
- [31] Y. Osako, H. Yamane, S. Y. Lin, P. A. Chen, R. Tao, "Cultivar discrimination of litchi fruit images using deep learning," *Sci. Hortic. Technol. Netherlands*, vol. 269, 109360, July 2020. <https://doi.org/10.1016/j.scienta.2020.109360>.
- [32] H. Cecotti, A. Rivera, M. Farhadloo, and M. A. Pedroza, "Grape detection with convolutional neural networks," *Expert Syst. Appl. United Kingdom*, vol. 159, 113588, November 2020. <https://doi.org/10.1016/j.eswa.2020.113588>.
- [33] J. Liu, Z. Zhao, W. Jia, and Z. Ji, "DLNet: Accurate segmentation of green fruit in obscured environments," *J. King Saud Univ. - Comput. Inf. Sci. Saudi Arabia*, vol. 34, no. 9, pp. 7259-7270, October 2022. <https://doi.org/10.1016/j.jksuci.2021.09.023>.
- [34] Y. Wang, J. Lv, L. Xu, Y. Gu, L. Zou, Z. Ma, "A segmentation method for waxberry image under orchard environment," *Sci. Hortic. Netherlands*, vol. 266, 109309, May 2020. <https://doi.org/10.1016/j.scienta.2020.109309>.
- [35] H. S. Gill, O. I. Khalaf, Y. Alotaibi, S. Alghamdi, and F. Alassery, "Fruit Image Classification Using Deep Learning," *Comput. Mater. Contin. United States*, vol. 71, no. 1, pp. 5135-5150, January 2022. <https://doi.org/10.32604/cmc.2022.022809>.
- [36] R. Kirk, G. Cielniak, and M. Mangan, "L*a*b*Fruits: A Rapid and Robust Outdoor Fruit Detection System Combining Bio-Inspired Features with One-Stage Deep Learning Networks," *Sensors. Switzerland*, vol. 20, no. 1, 275, January 2020. <https://doi.org/10.3390/s20010275>.
- [37] Q. Sun, X. Chai, Z. Zeng, G. Zhou, and T. Sun, "Noise-tolerant RGB-D feature fusion network for outdoor fruit detection," *Comput. Electron. Agric. Netherlands*, vol. 198, 107034, July 2022. <https://doi.org/10.1016/j.compag.2022.107034>.
- [38] K. Simonyan, and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," In *Proc. the 3rd International Conference on Learning Representations ICLR 2015*, pp. 398-406, May 2015.
- [39] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," In *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2016*, pp. 770-778, June 2016.
- [40] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: inverted residuals and linear bottlenecks," In *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2018*, pp. 4510-4520, June 2018.
- [41] P. Inkeaw, *Documents for teaching the course process 204123 Introduction to data science (Introduction to Data Science)*. Chiang Mai, TH: Document Printing Unit Education Services and Student Quality Development Faculty of Science Chiang Mai University, 2021.
- [42] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Trans. Syst. Man Cybern. United States*, vol. SMC-3, no. 6, pp. 610-621, November 1973. <https://doi.org/10.1109/TSMC.1973.4309314>.
- [43] Y. Park, and J. M. Guldmann, "Measuring continuous landscape patterns with Gray-Level Co-Occurrence Matrix (GLCM) indices: An alternative to patch metrics?," *Ecol. Indic. Netherlands*, vol. 109, 105802, February 2020. <https://doi.org/10.1016/j.ecolind.2019.105802>.
- [44] J. Canny, "A Computational Approach to Edge Detection," *IEEE Trans. Pattern Anal. Mach. Intell. United States*, vol. PAMI-8, no. 6, pp. 679-698, November 1986. <https://doi.org/10.1109/TPAMI.1986.4767851>.
- [45] Opencv Python Tutorials, Canny Edge Detection. Available online: https://opencv24-python-tutorials.readthedocs.io/en/latest/py_tutorial_s/py_imgproc/py_canny/py_canny.html (accessed on 9 March 2023).
- [46] P. Mukhopadhyay, and B. B. Chaudhuri, "A survey of Hough Transform," *Pattern Recognit. United Kingdom*, vol. 48, no. 3, pp. 993-1010, March 2015. <https://doi.org/10.1016/j.patcog.2014.08.027>.
- [47] Opencv Python Tutorials, Hough Line Transform. Available online: https://opencv24-python-tutorials.readthedocs.io/en/latest/py_tutorial_s/py_imgproc/py_houghlines/py_houghlines.html (accessed on 9 March 2023).

ภาคผนวก ข
ข้อมูลวารสารที่ได้รับการตีพิมพ์



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Register Login

Engineering and Applied Science Research (EASR)

(former name "KKU Engineering Journal")

[About](#) [Editorial Team](#) [Current](#) [Archives](#) [In progress](#) [Announcements](#) [Publication Ethics](#)

Search

[Home](#) / [About the Journal](#)

About the Journal

Focus and Scope

Publication of the journal started in 1974. Its original name was "KKU Engineering Journal". English and Thai manuscripts were accepted. The journal was originally aimed at publishing research that was conducted and implemented in the northeast of Thailand. It is regarded a national journal and has been indexed in the Thai Journal Citation Index (TCI) database since 2004. The journal now accepts only English language manuscripts and became open access in 2015 to attract more international readers. It was renamed Engineering and Applied Science Research in 2017. The editorial team agreed to publish more international papers, therefore, the new journal title is more appropriate. The journal focuses on research in the field of engineering that not only presents highly original ideas and advanced technology, but also are practical applications of appropriate technology.

Peer Review Process

Engineering and Applied Science Research (EASR) was published by the Faculty of Engineering, Khon Kaen University (KKU), the journal was submitted to publish articles and research works in Engineering and Technology. All submitted manuscripts must be reviewed by at least two expert reviewers via the double-blinded review system.

Publication Frequency

The Engineering and Applied Science Research (EASR) is a monthly journal circulated every two months: January – February, March – April, May – June, July – August, September – October and November – December by the Faculty of Engineering at Khon Kaen University. Its purpose is to promote and disseminate knowledge, academic work and research in engineering and technology. Copies of the journals are sent to different academic institutions in the country. All articles to be published must be approved by experts in their related fields and have all rights reserved under the Patent Act of 1994.

Open Access Policy

This journal provides immediate open access to its content on the principle that making research freely available to the public supports a greater global exchange of knowledge.

- Creative Commons Copyright License
- The journal allows readers to download and share all published articles as long as they properly cite such articles; however, they cannot change them or use them commercially. This is classified as CC BY-NC-ND for the creative commons license.
- Retention of Copyright and Publishing Rights

The journal allows the authors of the published articles to hold copyrights and publishing rights without restrictions.

Publication charges

There are no charges to submit and publish all types of articles in the EASR journal. All articles published in our journal are open access and are freely and widely available to all readers via the journal website.

Sponsors

Faculty of Engineering, Khon Kaen University
Khon Kaen University

Sources of Support

Editorial board

Make a Submission

[Home Thai Jo](#)

THAIJO

Instructions

[Instructions for authors](#)
[Reference management](#)

Information

[For Readers](#)
[For Authors](#)
[For Librarians](#)

Indexed In

Notifiers

Journal Rank

1.2

2021 CiteScore

37th percentile
Powered by Scopus

Visitors

62,997	4,037
23,562	3,684
9,887	3,411
6,454	2,770

Counter installed 31 July 2019

Engineering and Applied Science Research (EASR)
2nd Floor, Pierichit Building, Faculty of Engineering,
Khon Kaen University, Muang, Khon Kaen, 40002, Thailand.
E-mail: kku.enjournal@gmail.com

Platform & workflow by
OJS / PKP

นโยบายการคุ้มครองข้อมูลส่วนบุคคล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



Scopus

Search Lists Sources SciVal

Create account Sign in

Source details

Feedback Compare sources

Engineering and Applied Science Research

Scopus coverage years: from 2017 to Present
 Publisher: Faculty of Engineering, Khon Kaen University
 ISSN: 2539-6161 E-ISSN: 2539-6218
 Subject area: [Engineering: General Engineering](#) [Computer Science: Computer Science Applications](#)
 Source type: Journal


[View all documents](#) [Set document alert](#) [Save to source list](#) [Source Homepage](#)

CiteScore 2022	1.6
SJR 2022	0.210
SNIP 2022	0.502

CiteScore CiteScore rank & trend Scopus content coverage

Improved CiteScore methodology
 CiteScore 2022 counts the citations received in 2019-2022 to articles, reviews, conference papers, book chapters and data papers published in 2019-2022, and divides this by the number of publications published in 2019-2022. [Learn more](#)

CiteScore 2022	CiteScoreTracker 2023
1.6 = 407 Citations 2019 - 2022 249 Documents 2019 - 2022 <small>Calculated on 05 May, 2023</small>	1.7 = 373 Citations to date 219 Documents to date <small>Last updated on 05 May, 2023. Updated monthly</small>



[View CiteScore methodology](#) [CiteScore FAQ](#) [Add CiteScore to your site](#)

About Scopus

- What is Scopus
- Content coverage
- Scopus blog
- Scopus API
- Privacy matters

Language

- 日本語版を表示する
- 查看简体中文版本
- 查看繁體中文版本
- Просмотр версии на русском языке

Customer Service

- Help
- Tutorials
- Contact us

ELSEVIER

[Terms and conditions](#) [Privacy policy](#)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Engineering and Applied Science Research

COUNTRY Thailand Universities and research institutions in Thailand Media Ranking in Thailand	SUBJECT AREA AND CATEGORY Computer Science Computer Science Applications Engineering Engineering (miscellaneous)	PUBLISHER Faculty of Engineering, Khon Kaen University	H-INDEX 9
PUBLICATION TYPE Journals	ISSN 25396218, 25396161	COVERAGE 2017-2022	INFORMATION Homepage How to publish in this journal kku.esjournal@gmail.com

SCOPE

Publication of the journal started in 1974. Its original name was "KKU Engineering Journal". English and Thai manuscripts were accepted. The journal was originally aimed at publishing research that was conducted and implemented in the northeast of Thailand. It is regarded a national journal and has been indexed in the Thai Journal Citation Index (TCI) database since 2004. The journal now accepts only English language manuscripts and became open access in 2015 to attract more international readers. It was renamed Engineering and Applied Science Research in 2017. The editorial team agreed to publish more international papers, therefore, the new journal title is more appropriate. The journal focuses on research in the field of engineering that not only presents highly original ideas and advanced technology, but also are practical applications of appropriate technology.

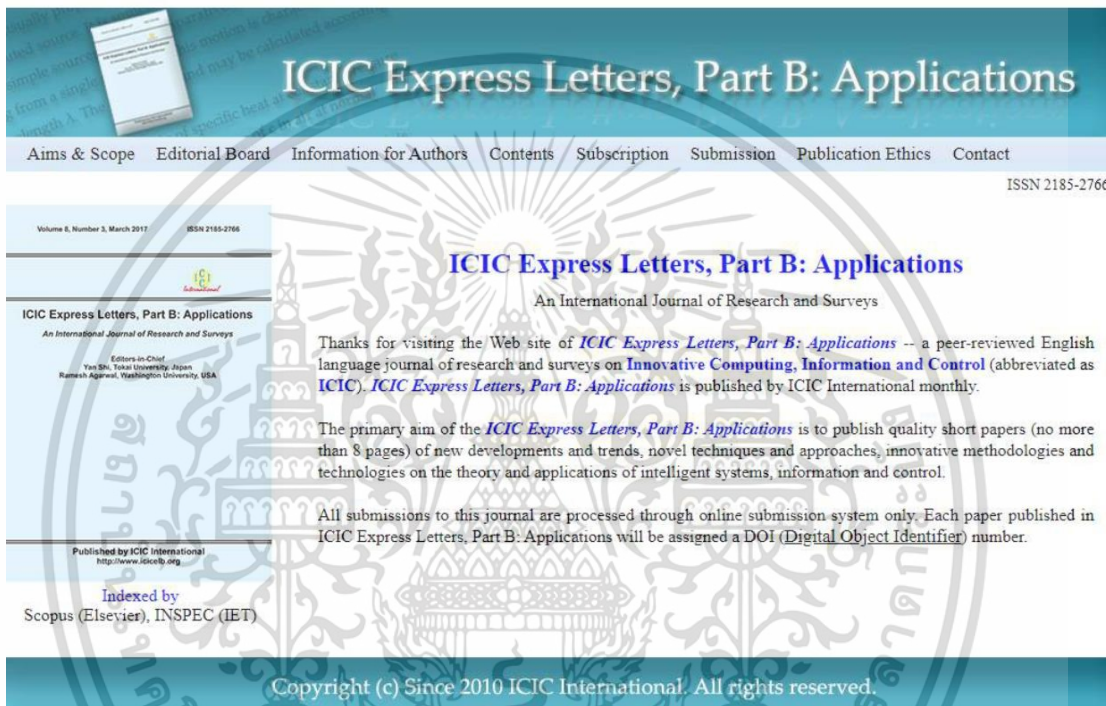


RECEIVE WITHDRAWALS INSTANTLY 24/7
No transfer fees

Your capital is ours. 100% ready. **Open an Account**

Metrics based on Scopus® data as of April 2023

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับบุคคลใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้ทำซ้ำโดยไม่ได้รับอนุญาตจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ICIC Express Letters, Part B: Applications

Aims & Scope Editorial Board Information for Authors Contents Subscription Submission Publication Ethics Contact

ISSN 2185-2766

Volume 6, Number 3, March 2017 ISSN 2185-2766

ICIC Express Letters, Part B: Applications
An International Journal of Research and Surveys

Editors-in-Chief
Yan Shi, Tokai University, Japan
Ramesh Agarwal, Washington University, USA

Thanks for visiting the Web site of *ICIC Express Letters, Part B: Applications* -- a peer-reviewed English language journal of research and surveys on **Innovative Computing, Information and Control** (abbreviated as **ICIC**). *ICIC Express Letters, Part B: Applications* is published by ICIC International monthly.

The primary aim of the *ICIC Express Letters, Part B: Applications* is to publish quality short papers (no more than 8 pages) of new developments and trends, novel techniques and approaches, innovative methodologies and technologies on the theory and applications of intelligent systems, information and control.

All submissions to this journal are processed through online submission system only. Each paper published in *ICIC Express Letters, Part B: Applications* will be assigned a DOI (Digital Object Identifier) number.

Published by ICIC International
<http://www.icicelb.org>

Indexed by
Scopus (Elsevier), INSPEC (IET)

Copyright (c) Since 2010 ICIC International. All rights reserved.

辽ICP备12003320号-2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



Search Lists Sources SciVal

Create account Sign in

Source details

Feedback Compare sources

ICIC Express Letters, Part B: Applications

Scopus coverage years: from 2010 to Present

Publisher: IEEE

ISSN: 2185-2766

Subject area: Computer Science: General Computer Science

Source type: Journal

View all documents Set document alert Save to source list

CiteScore 2022 1.0

SJR 2022 0.230

SNIP 2022 0.320

CiteScore CiteScore rank & trend Scopus content coverage

Improved CiteScore methodology

CiteScore 2022 counts the citations received in 2019-2022 to articles, reviews, conference papers, book chapters and data papers published in 2019-2022, and divides this by the number of publications published in 2019-2022. [Learn more](#)

CiteScore 2022 1.0 = $\frac{604 \text{ Citations } 2019 - 2022}{581 \text{ Documents } 2019 - 2022}$ <small>Calculated on 05 May, 2023</small>	CiteScoreTracker 2023 0.8 = $\frac{418 \text{ Citations to date}}{505 \text{ Documents to date}}$ <small>Last updated on 05 May, 2023 Updated monthly</small>
--	---



View CiteScore methodology CiteScore FAQ Add CiteScore to your site

About Scopus

- What is Scopus
- Content coverage
- Scopus blog
- Scopus API
- Privacy matters

Language

- 日本語を表示する
- 查看简体中文版本
- 查看繁體中文版本
- Просмотр версии на русском языке

Customer Service

- Help
- Tutorials
- Contact us

ELSEVIER


Terms and conditions Privacy policy

Copyright © Elsevier B.V. All rights reserved. Scopus® is a registered trademark of Elsevier B.V.

We use cookies to help provide and enhance our service and tailor content. By continuing, you agree to the use of cookies

RELX

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

SAI
The Science and Information Organization

HOME ABOUT US **JOURNALS** CONFERENCES CONTACT US

Home Call for Papers Indexing Submit your Paper Guidelines Fees Current Issue Archives Editors Reviewers Subscribe

International Journal of Advanced Computer Science and Applications (IJACSA)

Computer Science Journals - Open Access - Scopus Indexed

IJACSA is a scholarly computer science journal representing the best in research. Its mission is to provide an outlet for quality research to be publicised and published to a global audience. The journal aims to publish papers selected through rigorous double-blind peer review to ensure originality, timeliness, relevance, and readability.

In sync with the Journal's vision "to be a respected publication that publishes peer reviewed research articles, as well as review and survey papers contributed by international community of Authors", we have drawn reviewers and editors from Institutions and Universities across the globe. A double blind peer review process is conducted to ensure that we retain high standards. At IJACSA, we stand strong because we know that global challenges make way for new innovations, new ways and new talent.

International Journal of Advanced Computer Science and Applications publishes research, review and survey papers which offer a significant contribution to the computer science literature, and which are of interest to a wide audience. Coverage extends to all main-stream branches of computer science and related applications.

Open Access Statement: This is an open access journal which means that all content is freely available without charge to the user or his/her institution. Users are allowed to read, download, copy, distribute, print, search, or link to the full texts of the articles, or use them for any other lawful purpose, without asking prior permission from the publisher or the author. All past issues are available in the Archives.

** Indexing: The papers of this journal are submitted to Web of Science, Scopus, Inspec, Ei Compindex, Semantic Scholar, EBSCOhost, Microsoft Academic Search and Index Copernicus. The journal is Scientific level 1 in the Norwegian Register and included in the Federation of Finnish Learned Societies/Publication Forum. **

[CALL FOR PAPERS](#) [SUBMIT YOUR PAPER](#) [CURRENT ISSUE](#)

Bibliographic Information

- ✓ ISSN : 2156-5570 (Online)
- ✓ ISSN : 2156-107X (Print)
- ✓ DOI : 10.14569/issn.2156-5570
- ✓ Publication Frequency : Monthly

Clarivate Analytics 2022

- ✓ JCI 0.17

CiteScore

- ✓ 1.8 (2021) Q3

Dr Kohei Arai

Editor-in-Chief



Affiliation : Saga University, Japan.
Domains of Research : Computer Science, Human-Computer Interaction, Networking, Information Retrievals, Optimization Theory, Modeling and Simulation, Satellite Remote Sensing, Computer Vision, Decision Making, Methodology.
✉ editorijacsa@thesai.org

Upcoming Conferences

- Future of Information and Communication Conference (FICC) 2023**
2-3 March 2023 Virtual
- Computing Conference 2023**
22-23 June 2023 London, United Kingdom
- IntelliSys 2023**
7-8 September 2023 Amsterdam, The Netherlands
- Future Technologies Conference (FTC) 2023**
2-6 November 2023 San Francisco, United States

[BACK TO TOP](#)

COMPUTER SCIENCE JOURNAL	OUR CONFERENCES	HELP & SUPPORT
<ul style="list-style-type: none"> - About the Journal - Call for Papers - Submit Paper - Indexing 	<ul style="list-style-type: none"> - Computing Conference - Intelligent Systems Conference - Future Technologies Conference - Communication Conference 	<ul style="list-style-type: none"> - Contact Us - About Us - Terms and Conditions - Privacy Policy

© The Science and Information (SAI) Organization Limited. All rights reserved. Registered in England and Wales. Company Number 8933265. thesai.org

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

SAI
The Science and Information Organization

HOME ABOUT US **JOURNALS** CONFERENCES CONTACT US

Home Call for Papers Indexing Submit your Paper Guidelines Fees Current Issue Archives Editors Reviewers Subscribe

Indexing

To be recognized as an authoritative, high-quality source of information, a journal must be widely available. Authors publish with us for the heightened visibility, research activity, and industry credibility.

IJACSA is covered by following databases and archives:

- Scopus (Q3 | Cite Score 1.8)
- Web of Science (Clarivate | JCI 0.17)
- Inspec (IET)
- Ei Compendex
- Norwegian Register for Scientific Journals, Series and Publishers (NSD)
- Julkaisuforum Publication Forum (Federation of Finnish Learned Societies)
- Genamics JournalSeek
- Semantic Scholar
- EBSCOhost
- Ex Libris
- Microsoft Academic Search
- WorldCat
- CNKI

SAI BACK TO TOP

COMPUTER SCIENCE JOURNAL **OUR CONFERENCES** **HELP & SUPPORT**

- About the Journal
- Call for Papers
- Submit Paper
- Indexing
- Computing Conference
- Intelligent Systems Conference
- Future Technologies Conference
- Communication Conference
- Contact Us
- About Us
- Terms and Conditions
- Privacy Policy

© The Science and Information (SAI) Organization Limited. All rights reserved. Registered in England and Wales. Company Number 8933205. the sai.org

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Master Journal List Search Journals Match Manuscript Downloads Help Center Welcome, Naruwan Yusamran Settings Log Out

INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS

ISSN / eISSN 2158-107X / 2156-5570
Publisher SCIENCE & INFORMATION SAI ORGANIZATION LTD, 19 BOLLING RD, BRADFORD, WEST YORKSHIRE, ENGLAND, 00000

General Information

Journal Website	Visit Site	Publisher Website	Visit Site
1st Year Published	2010	Frequency	Monthly
Issues Per Year	12	Country / Region	UNITED STATES OF AMERICA
Primary Language	English		

Web of Science Coverage

Collection	Index	Category	Similar Journals
Core Collection	Emerging Sources Citation Index (ESCI)	Computer Science, Theory & Methods	Find Similar Journals

Search a topic within this journal

Journal Citation Report™ (JCR)

Journal Citation Indicator (JCI) MLW METRIC

The Journal Citation Indicator is a measure of the average Category Normalized Citation Impact (CNCI) of citable items (articles & reviews) published by a journal over a recent three-year period. It is used to help you evaluate journals based on other metrics besides the Journal Impact Factor (JIF).

Year	JCI	Category
2021	0.17	Computer Science, Theory & Methods
2020	0.17	Computer Science, Theory & Methods

Peer Review Information

Web of Science Reviewer Recognition	No	Claimed Reviews on Web of Science	2,498
Public Reports on Web of Science	No	Signed Reports on Web of Science	No
Transparent Peer Review on ScholarOne	No		

Editorial Disclaimer: As an independent organization, Clarivate does not become involved in and is not responsible for the editorial management of any journal or the business practices of any publisher. Publishers are accountable for their journal performance and compliance with ethical publishing standards. The views and opinions expressed in any journal are those of the author(s) and do not necessarily reflect the views or opinions of Clarivate. Clarivate remains neutral in relation to territorial disputes, and allows journals, publishers, institutes and authors to specify their address and affiliation details including territory.

Criteria for selection of newly submitted titles and re-evaluation of existing titles in the Web of Science are determined by the Web of Science Editors in their sole discretion. If a publisher's editorial policy or business practices negatively

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Rank by Journal Citation Indicator (JCI)

Journals within a category are sorted in descending order by Journal Citation Indicator (JCI) resulting in the Category Ranking below. A separate rank is shown for each category in which the journal is listed in JCR. Data for the most recent year is presented at the top of the list, with other years shown in reverse chronological order.


Only journals which have a calculated JCI value are included in the JCI ranking. The total number of journals displayed in this ranking may be less than the category overall.

CATEGORY

COMPUTER SCIENCE, THEORY & METHODS

127/143

JCR YEAR	JCI RANK	QUARTILE	JCI PERCENTILE
2021	127/143	Q4	11.54
2020	122/137	Q4	11.31
2019	122/137	Q4	11.31
2018	119/135	Q4	12.22
2017	118/132	Q4	10.98





Search Lists Sources SciVal

Create account Sign in

Source details

Feedback Compare sources

International Journal of Advanced Computer Science and Applications

Scopus coverage years: from 2017 to Present
Publisher: Science and Information Organization
ISSN: 2158-107X E-ISSN: 2156-5570
Subject area: Computer Science: General Computer Science
Source type: Journal

CiteScore 2022	2.1
SJR 2022	0.258
SNIP 2022	0.512

View all documents Set document alert Save to source list Source Homepage

CiteScore CiteScore rank & trend Scopus content coverage

Improved CiteScore methodology
CiteScore 2022 counts the citations received in 2019-2022 to articles, reviews, conference papers, book chapters and data papers published in 2019-2022, and divides this by the number of publications published in 2019-2022. [Learn more](#)

CiteScore 2022
2.1 = 9,537 Citations 2019 - 2022 / 4,553 Documents 2019 - 2022
Calculated on 05 May, 2023

CiteScoreTracker 2023
1.7 = 6,493 Citations to date / 3,875 Documents to date
Last updated on 05 May, 2023 - Updated monthly

CiteScore rank 2022
Category: Computer Science
Rank: #129/233
Percentile: 44th
General Computer Science

About Scopus
What is Scopus
Content coverage
Scopus blog
Scopus API
Privacy matters

Language
日本語を表示する
查看简体中文版本
查看繁體中文版本
Просмотр версии на русском языке

Customer Service
Help
Tutorials
Contact us

ELSEVIER

Terms and conditions Privacy policy

Copyright © Elsevier B.V. All rights reserved. Scopus is a registered trademark of Elsevier B.V.

We use cookies to help provide and enhance our service and tailor content. By continuing, you agree to the use of cookies


RELX

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

International Journal of Advanced Computer Science and Applications

COUNTRY United Kingdom <small>Universities and research institutions in United Kingdom Media Ranking in United Kingdom</small>	SUBJECT AREA AND CATEGORY Computer Science Computer Science (miscellaneous)	PUBLISHER Science and Information Organization	H-INDEX 35
PUBLICATION TYPE Journals	ISSN 21565570, 2158107X	COVERAGE 2017-2022	
SCOPE Information not localized			

Join the conversation about this journal



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ	นางสาวนรพรรณ อยู่สำราญ
วัน เดือน ปีเกิด	23 กุมภาพันธ์ พ.ศ. 2528
ที่อยู่ปัจจุบัน	676 หมู่ 11 ตำบลเมือง อำเภอเมืองเลย จังหวัดเลย 42000
ประวัติการศึกษา	พ.ศ. 2550 วิทยาศาสตรบัณฑิต (วท.บ.) สาขาวิชาวิทยาการคอมพิวเตอร์ คณะทรัพยากรและสิ่งแวดล้อม มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา เกรดเฉลี่ย 2.96 พ.ศ. 2553 หลักสูตรประกาศนียบัตรบัณฑิตวิชาชีพครู คณะครุศาสตร์ มหาวิทยาลัยราชภัฏสวนดุสิต เกรดเฉลี่ย 3.72 พ.ศ. 2553 วิทยาศาสตรมหาบัณฑิต (วท.ม.) สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหาร ลาดกระบัง เกรดเฉลี่ย 3.66
ทุนการศึกษาที่ได้รับ	ทุนรัฐบาลทางด้านวิทยาศาสตร์และเทคโนโลยี (กระทรวงอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม) เพื่อศึกษาภายในประเทศ ตามความ ต้องการของมหาวิทยาลัยราชภัฏเลย ประจำปี 2562

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้