

การประมาณขนาดและการจำแนกผลไม้ด้วยเทคนิคปัญญาประดิษฐ์



นางสาวไอริน วรรณทอง

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมเมคคาทรอนิกส์

มหาวิทยาลัยเทคโนโลยีสุรนารี

ปีการศึกษา 2567

ESTIMATING FRUIT DIMENSION AND CLASSIFICATION SIZE USING
ARTIFICIAL INTELLIGENCE TECHNIQUES

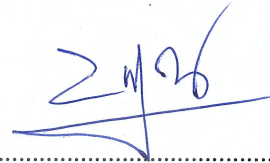


A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Mechatronics Engineering
Suranaree University of Technology
Academic Year 2024

การประเมินขนาดและการจำแนกผลไม้ด้วยเทคนิคปัญญาประดิษฐ์

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้บัณฑิตวิทยาลัยฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(รศ. ดร. บัณฑิต กฤตาคม)
ประธานกรรมการ



(รศ. ดร. จีระพล ศรีเสรีภูผล)
กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(ผศ. ดร. ไตรภูา แข็งการ)
กรรมการ

มหาวิทยาลัยเทคโนโลยีสุรนารี



(รศ. ดร. ยุพาพร รักสกุลพิวัฒน์)
รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ



(รศ. ดร. พรศิริ จงกล)
คณบดีสำนักวิชาวิศวกรรมศาสตร์

ไอริณ วรรณทอง : การประมาณขนาดและการจำแนกผลไม้ด้วยเทคนิคปัญญาประดิษฐ์
(ESTIMATING FRUIT DIMENSION AND CLASSIFICATION SIZE USING ARTIFICIAL
INTELLIGENCE TECHNIQUES)

อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร.จิระพล ศรีเสริฐผล, 95 หน้า

คำสำคัญ: เทคนิคปัญญาประดิษฐ์/การมองเห็นด้วยคอมพิวเตอร์/โครงข่ายประสาทเทียม/
การประมวลผลภาพ/มะม่วงน้ำดอกไม้

การส่งออกมะม่วงน้ำดอกไม้ เป็นหนึ่งในผลิตภัณฑ์ทางการเกษตรของไทย สามารถสร้างมูลค่าการส่งออกได้มากกว่าสามพันล้านบาทต่อปี โดยในการส่งออกมะม่วงน้ำดอกไม้ไปยังต่างประเทศจำเป็นต้องมีการฉายรังสี เพื่อวัตถุประสงค์ในการชะลอการสุกระหว่างการขนส่ง และเพื่อป้องกันการแพร่ระบาดของแมลง และมะม่วงน้ำดอกไม้จะต้องมีคุณภาพที่ดี งานวิจัยนี้ได้ศึกษาและนำเสนอวิธีคัดแยก และประมาณขนาดของมะม่วงน้ำดอกไม้ด้วยรูปภาพกับเทคนิคปัญญาประดิษฐ์ โดยแบ่งงานวิจัยนี้ออกเป็น 3 ส่วน ได้แก่ ส่วนที่ 1 การประมาณขนาดของมะม่วงน้ำดอกไม้ เพื่อใช้ในการปรับการฉายรังสีให้เหมาะสมและลดต้นทุนการผลิต โดยใช้เทคนิคการประมวลผลภาพ การมองเห็นด้วยคอมพิวเตอร์และการถดถอยเชิงพหุคูณ ซึ่งผลลัพธ์ที่ได้ คือ โมเดลสามารถประมาณขนาดทั้งความกว้าง ความยาว และความสูงได้ โดยมีความถูกต้อง 90.0% ในส่วนที่ 2 การคัดแยกไซส์ของมะม่วงน้ำดอกไม้ เป็นการคัดแยกขนาดเพื่อเพิ่มมูลค่าโดยการคัดแยกไซส์สำหรับการส่งออกจะแบ่งออกเป็น 6 ไซส์ คือ 2S, S, M, L, 2L และ 3L โดยใช้เทคนิคโครงข่ายประสาทเทียม (ANN) ซึ่งผลที่ได้คือ ค่าความแม่นยำของการฝึกฝนโมเดลอยู่ที่ 79.87% และความถูกต้องของการทดสอบอยู่ที่ 87.0% และในส่วนที่ 3 การคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ ซึ่งแบ่งมะม่วงออกเป็น 2 ประเภทคือ มะม่วงดี และมะม่วงเสียหรือมะม่วงที่มีรอยตำหนิแม้เพียงเล็กน้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ผลลัพธ์หลังจากการฝึกฝนโมเดลมีความถูกต้องที่ 96.11% และค่าความถูกต้องของการทดสอบอยู่ที่ 93.0% ซึ่งผลการทดสอบจากงานวิจัยนี้คาดว่าโมเดลจะสามารถพัฒนาการส่งออกมะม่วงน้ำดอกไม้โดยใช้เทคนิคปัญญาประดิษฐ์ได้เป็นอย่างดี เพื่อยกระดับคุณภาพผลิตภัณฑ์ทางการเกษตรสำหรับการส่งออก และประยุกต์ใช้กับผลิตภัณฑ์อื่นได้

สาขาวิชา วิศวกรรมเมคคาทรอนิกส์

ปีการศึกษา 2567

ลายมือชื่อนักศึกษา.....ไอริณ

ลายมือชื่ออาจารย์ที่ปรึกษา.....

IRIN WANTHONG : ESTIMATING FRUIT DIMENSION AND CLASSIFICATION SIZE
USING ARTIFICIAL INTELLIGENCE TECHNIQUES.

THESIS ADVISOR : ASSOC. PROF. JIRAPHON SRISERTPHOL, Ph.D., 95 PP.

Keywords: Artificial Intelligence/Computer Vision/Artificial Neural Network/Image
Processing/Mangoes

The export of Nam Dok Mai mangoes, one of Thailand's agricultural products, can generate export value of more than three billion baht per year. In exporting Nam Dok Mai mangoes to foreign countries, irradiation is necessary to delay ripening during transport and prevent pests' spread. Additionally, the Nam Dok Mai mangoes must be of good quality. This research studied and presented methods for sorting and estimating the size of Nam Dok Mai mangoes using images and artificial intelligence techniques. This research is divided into three parts. Part 1 focuses on estimating the size of Nam Dok Mai mangoes to optimize radiation treatment and reduce production costs, using image processing techniques, computer vision, and multiple regression. The results show that the model can estimate the dimensions of width, length, and height with an accuracy of 90.0%. Part 2 involves sorting the sizes of Nam Dok Mai mangoes to enhance value by categorizing them for export into six sizes: 2S, S, M, L, 2L, and 3L, using artificial neural network (ANN) techniques. The outcome indicates that the training accuracy of the model is 79.87%, while the testing accuracy is 87.0%. And part 3, the quality sorting of Nam Dok Mai mangoes is divided into two categories: good mangoes and bad mangoes, or mangoes with even slight blemishes, using convolutional neural network (CNN) techniques. After training the model, the results showed an accuracy of 96.11%, and the testing accuracy was 93.0%. The findings from this research suggest that the model could significantly enhance the export of Nam Dok Mai mangoes using artificial intelligence techniques, thereby improving the quality of agricultural products for export and potentially applying it to other products as well.

School of Mechatronics Engineering
Academic Year 2024

Student's Signature.....

Advisor's Signature.....

Irin
Sutpol J

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงตามวัตถุประสงค์ทุกประการ ผู้วิจัยขอขอบพระคุณบุคคลต่าง ๆ ที่คอยช่วยเหลือ ให้คำปรึกษา และแนะนำอย่างดียิ่ง ทั้งด้านวิชาการ และด้านการดำเนินงานวิจัย ดังนี้

ขอขอบพระคุณ รองศาสตราจารย์ ดร.จิระพล ศรีเสริฐผล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้ประสิทธิ์ประสาทวิชาความรู้วิชาการทั้งในด้านทฤษฎีและการปฏิบัติงาน และคอยให้คำแนะนำในการทำงานวิจัย อีกทั้งยังให้โอกาสในการเข้าร่วมกิจกรรมในด้านที่ส่งเสริมวิชาการต่างๆ และยังเป็นแบบอย่างที่ดีในการดำรงชีวิต ผู้วิจัยขอขอบคุณท่านเป็นอย่างสูง และจะนำเอาวิชาความรู้ไปประยุกต์ใช้กับการทำงานในภายภาคหน้าต่อไป

ขอขอบคุณบุคคลดังต่อไปนี้ที่ให้ความช่วยเหลือในด้านต่าง ๆ ในระหว่างการศึกษาและการทำงานวิจัย ซึ่งผู้วิจัยรู้สึกทราบบ้างบางอย่าง และขอจดจำไว้ตลอดไป

ขอขอบคุณ สถาบันวิจัยแสงซินโครตรอน (องค์การมหาชน) ที่อำนวยความสะดวกเกี่ยวกับอุปกรณ์และสถานที่ในการเก็บข้อมูลและทดสอบงานวิจัยในครั้งนี้

ขอขอบคุณ เจ้าหน้าที่ประจำสำนักวิชาวิศวกรรมศาสตร์ทุก ๆ ท่าน ที่อำนวยความสะดวกในด้านงานเอกสารต่างๆ ตลอดจนให้คำปรึกษาแก่ผู้วิจัยด้วยดีเสมอมา

ขอขอบคุณพี่ ๆ น้อง ๆ ในกลุ่มวิจัย System and Control Engineering Laboratory ที่คอยให้ความช่วยเหลือ ให้คำปรึกษา ชี้แนะแนวทางในด้านการวิชาการและด้านต่าง ๆ

ขอขอบคุณ คุณสมบุญทรัพย์ รอดพร ที่ให้คำแนะนำเกี่ยวกับข้อมูลเครื่องฉายรังสี จากสถาบันวิจัยแสงซินโครตรอน (องค์การมหาชน) และคอยให้ความช่วยเหลือในเรื่องต่างๆ

ขอขอบคุณ คุณณัฐชัย โปธิ ที่คอยช่วยเหลือจัดเตรียมอุปกรณ์ และการทำอุปกรณ์ในการเก็บข้อมูลและทดสอบ และให้คำปรึกษาสำหรับการทำงานวิจัยในครั้งนี้

ท้ายที่สุดขอกราบขอบพระคุณคุณพ่อสนั่น คุณแม่ณวิน และคุณณลิตา ที่คอยให้กำลังใจ ให้โอกาสทางการศึกษา ให้ความรักความอบอุ่น และคอยสนับสนุนในทุก ๆ ด้าน จนทำให้ผู้วิจัยประสบความสำเร็จในชีวิตตลอดมา

ไอริน วรรณทอง

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ซ
บทที่	
1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	3
1.3 ขอบเขตของการวิจัย.....	3
1.4 ระเบียบวิธีวิจัย.....	4
1.5 สถานที่ทำงานวิจัย.....	4
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	5
2 ทฤษฎีและหลักการที่เกี่ยวข้องกับงานวิจัย.....	6
2.1 มะม่วง (Mangifera Indica L.).....	6
2.2 อาหารฉายรังสี (Irradiation foods).....	10
2.3 การมองเห็นด้วยคอมพิวเตอร์ (Computer Vision).....	16
2.3.1 กล้องเว็บแคม (Webcam).....	16
2.3.2 การตรวจจับวัตถุ (Object Detection).....	17
2.3.3 การประมวลผลภาพ (Image Processing).....	18
2.3.4 Canny Edge Detector.....	18
2.3.5 Binary Image.....	19
2.4 การเรียนรู้ของเครื่อง (Machine Learning).....	20
2.4.1 การวิเคราะห์การถดถอยเชิงเส้น (Linear Regression).....	20
2.5 การเรียนรู้เชิงลึก (Deep Learning).....	21

สารบัญ (ต่อ)

หน้า

2.5.1	Artificial Neural Network (ANN)	22
2.5.2	Convolutional Neural Network (CNN)	23
2.6	การประเมินผล (Model Assessment)	31
2.6.1	Confusion Matrix	31
2.6.2	Precision	32
2.6.3	Recall	32
2.6.4	F1-score	32
2.6.5	Accuracy	32
2.7	ปริทัศน์และวรรณกรรมที่เกี่ยวข้อง	32
3	วิธีการดำเนินงานวิจัย	36
3.1	จำนวนข้อมูลของมะม่วงน้ำดอกไม้	37
3.2	การเก็บข้อมูล (Data Acquisition)	37
3.3	วิธีการทดลองงานวิจัย	41
3.3.1	จำนวนชุดข้อมูล (Datasets)	41
3.3.2	การประมาณขนาดมะม่วงน้ำดอกไม้	43
3.3.3	การตัดแยกไซส์มะม่วงน้ำดอกไม้	48
3.3.4	การตัดแยกคุณภาพมะม่วงน้ำดอกไม้	50
4	ผลการวิจัยและอภิปรายผล	52
4.1	ผลการทดสอบการประมาณขนาดของมะม่วงน้ำดอกไม้	53
4.2	ผลการทดสอบการตัดแยกไซส์ของมะม่วงน้ำดอกไม้	57
4.3	ผลการทดสอบการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้	62
5	สรุปผลการวิจัย	68
5.1	สรุปผลการวิจัย	68
5.2	ข้อเสนอแนะ	69
	รายการอ้างอิง	70
	ภาคผนวก	
	ภาคผนวก ก. ตารางข้อมูลดิบจากการวัดขนาดและชั่งน้ำหนักมะม่วงน้ำดอกไม้	72

สารบัญ (ต่อ)

หน้า

ภาคผนวก ข. ตารางบันทึกผลการทดสอบโมเดลการประมาณขนาด การคัดแยกไซส์ และการคัดแยกคุณภาพ	75
ภาคผนวก ค. รูปภาพผลการทดสอบโมเดลและโปรแกรม	80
ภาคผนวก ง. บทความที่ได้รับการตีพิมพ์เผยแพร่	85
ประวัติผู้เขียน	95



สารบัญตาราง

ตารางที่		หน้า
3.1	Datasets สำหรับฝึกฝนโมเดล.....	42
4.1	ผลการทดสอบการประมาณขนาดของมะม่วงน้ำดอกไม้.....	53
4.2	ผลการทดสอบการฝึกฝนการตัดแยกไซส์ของมะม่วงน้ำดอกไม้.....	58
4.3	ผลการทดสอบการตัดแยกไซส์ของมะม่วงน้ำดอกไม้ด้วยชุดข้อมูล Unseen Data	60
4.4	การเปลี่ยนแปลงน้ำหนักของมะม่วงน้ำดอกไม้	61
4.5	ผลการทดสอบการฝึกฝนการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้.....	63
4.6	ผลการทดสอบการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้ด้วยชุดข้อมูล Unseen Data	66
ก.1	ข้อมูลดิบจากการวัดขนาดและชั่งน้ำหนักมะม่วงน้ำดอกไม้	73
ข.1	ผลการทดสอบโมเดลการประมาณขนาด การตัดแยกไซส์ และการตัดแยกคุณภาพ.....	76

สารบัญรูป

รูปที่		หน้า
1.1	มะม่วงน้ำดอกไม้พันธุ์สีทองสำหรับส่งออก	1
1.2	เครื่องเร่งอนุภาคแนวตรงต้นแบบพลังงาน 6 MeV สำหรับอบรังสีผลไม้	2
1.3	การคัดแยกไซส์มะม่วงน้ำดอกไม้	3
2.1	มะม่วงน้ำดอกไม้สีทองผลดิบและผลสุก	7
2.2	การห่อผลมะม่วงน้ำดอกไม้	8
2.3	ตัวอย่างลักษณะของโรคและแมลงศัตรูพืชของมะม่วง	9
2.4	ตัวอย่างอาหารฉายรังสี	11
2.5	เครื่องหมาย Radura บนผลิตภัณฑ์อาหารฉายรังสี	12
2.6	กล้องเว็บแคมยี่ห้อ Logitech รุ่น Brio 4K	17
2.7	การแยกวัตถุด้วยการเรียนรู้เชิงลึก	18
2.8	การหาขอบวัตถุด้วยวิธี Canny โดยกำหนดค่าเกณฑ์ที่แตกต่างกัน	19
2.9	ค่าพิกเซลของรูปภาพไบนารี	19
2.10	โครงสร้างของนิเวศวิทยาและการเรียนรู้เชิงลึก	22
2.11	โครงสร้างของเทคนิค Deep Learning	22
2.12	โครงสร้างของโครงข่ายประสาทเทียมคอนโวลูชัน	23
2.13	ฟังก์ชันการกระตุ้น (Activation Function)	25
2.14	การปรับ Hyperparameter สำหรับ Artificial Neural Networks (ANN)	26
2.15	ความสัมพันธ์ระหว่าง Training loss และ Validation loss	27
2.16	การเปรียบเทียบการเกิดปัญหา Underfitting และ Overfitting	28
2.17	การเพิ่มจำนวนข้อมูล (Data Augmentation)	29
2.18	การสุ่มปิดใช้งาน Neurons (Dropout)	30
2.19	เมทริกซ์ความสับสน (Confusion Matrix)	31
3.1	แผนภาพวิธีการดำเนินงานวิจัย	36
3.2	การวัดขนาดและชั่งน้ำหนักของมะม่วงน้ำดอกไม้	38
3.3	ชุดสายพานทดสอบและอุปกรณ์วัดความสว่าง (ลักซ์มิเตอร์)	39

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.4	ภาพที่ได้จากกล้องเว็บแคม ที่มีขนาด 640 x 480 พิกเซล.....39
3.5	ตำแหน่งรูปภาพที่ถูกทำการครอบตัด (Cropping) ขนาด 480 x 280 พิกเซล 40
3.6	ภาพที่ถูกทำการครอบตัด (Cropping) และภาพที่ถูกแปลงเป็นภาพขาว-ดำ (Binary)..... 41
3.7	การเพิ่มจำนวนข้อมูลโดยวิธีการปรับความสว่าง (Brightness)..... 42
3.8	แผนภาพวิธีการดำเนินงานการประมาณขนาดของมะม่วงน้ำดอกไม้ 44
3.9	ตัวอย่างการใช้เทคนิคตรวจจับขอบด้วยแคณี่และการค้นหาขอบเขต (Contour)..... 44
3.10	กราฟแสดงผลค่าความกว้างของมะม่วงแต่ละไซส์ 45
3.11	แผนภาพเงื่อนไขการตัดสินใจการประมาณความสูง 47
3.12	แผนภาพวิธีการดำเนินงานการคัดแยกไซส์มะม่วงน้ำดอกไม้ 48
3.13	แผนภาพวิธีการดำเนินงานการคัดแยกคุณภาพมะม่วงน้ำดอกไม้..... 50
4.1	ตัวอย่างผลการทดสอบโมเดลการประมาณขนาด คัดไซส์และคัดแยกคุณภาพ 52
4.2	ตัวอย่างการเปลี่ยนตำแหน่งการวางวัตถุที่ส่งผลต่อการวัดขนาด 54
4.3	ตัวอย่างการปรับความสว่างที่ส่งผลต่อการวัดขนาด 56
4.4	Confusion Matrix ของการ Train Model ANN สำหรับการคัดแยกไซส์ 57
4.5	กราฟความสัมพันธ์ระหว่าง Train Loss กับ Validation Loss ของโมเดล ANN 58
4.6	กราฟความสัมพันธ์ระหว่าง Train Accuracy กับ Validation Accuracy ของโมเดล ANN..... 59
4.7	Confusion Matrix ของการ Testing Model ANN สำหรับการคัดแยกไซส์ 60
4.8	Confusion Matrix ของการ Train Model CNN สำหรับการคัดแยกคุณภาพ 63
4.9	กราฟความสัมพันธ์ระหว่าง Train Loss กับ Validation Loss ของโมเดล CNN 64
4.10	กราฟความสัมพันธ์ระหว่าง Train Accuracy กับ Validation Accuracy ของโมเดล CNN..... 64
4.11	Confusion Matrix ของการ Testing Model CNN สำหรับการคัดแยกคุณภาพ 65
4.12	ตัวอย่างการทำนายผิดในคลาสของมะม่วงเสียที่เป็น False Negative..... 66

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ผลิตภัณฑ์ทางการเกษตรของไทยที่มีมูลค่าการส่งออกไปยังต่างประเทศ ซึ่งประกอบด้วย ผลิตภัณฑ์ทางการเกษตรหลากหลายชนิด ได้แก่ ผลไม้ เครื่องเทศ ข้าว อาหารแปรรูปอื่น ๆ และ เครื่องจักรสานหัตถกรรม เป็นต้น ซึ่งมะม่วงเป็นผลิตภัณฑ์ทางการเกษตรในกลุ่มผลไม้ ปัจจุบัน ประเทศไทยเป็นผู้ส่งออกมะม่วง เป็นอันดับ 2 ของเอเชีย และอันดับ 7 ของโลก โดยตลาดส่งออกที่สำคัญ คือ จีน ญี่ปุ่น เกาหลีใต้ เวียดนาม ลาว อินเดีย ออสเตรเลีย สหรัฐอเมริกา และสหภาพยุโรป เป็นต้น ซึ่งสายพันธุ์มะม่วงที่ไทยมีศักยภาพในการส่งออกและเป็นที่ยอมรับสำหรับผู้บริโภค ในปัจจุบันมี ทั้งหมด 7 สายพันธุ์ ได้แก่ มะม่วงน้ำดอกไม้สีทอง มะม่วงพันธุ์หนังกกลางวัน มะม่วงแรด มะม่วง พิมเสนแดง มะม่วงมหาชนก มะม่วงโชคอนันต์ และมะม่วงเขียวเสวย ทำให้มูลค่าการส่งออกมะม่วง ไทยไปยังทั่วโลกซึ่งปี 2565 เป็นมูลค่า 3,016.24 ล้านบาท และการส่งออกในปี 2566 เป็นมูลค่า 3,236.16 ล้านบาท ในรูปที่ 1.1 แสดงมะม่วงน้ำดอกไม้พันธุ์สีทองสำหรับส่งออกต่างประเทศ




รูปที่ 1.1 มะม่วงน้ำดอกไม้พันธุ์สีทองสำหรับส่งออก

(ที่มา: <https://tinyurl.com/22ptxybw> , <https://tinyurl.com/2ytwrwy>)

ในการส่งออกมะม่วงหรือผลไม้บางชนิดของไทยมีการใช้กรรมวิธีการฉายรังสี เพื่อเป็นการ ปฏิบัติตามกฎหมายของประเทศผู้นำเข้าและส่งออก ซึ่งวัตถุประสงค์ของการฉายรังสี ได้แก่ ยับยั้งการงอก และยืดอายุระหว่างการเก็บรักษาหรือการขนส่ง ชะลอการสุกของผักและผลไม้ ควบคุมการแพร่พันธุ์ ของแมลง ลดปริมาณจุลินทรีย์และกำจัดจุลินทรีย์ก่อเกิดโรค และลดปริมาณปรสิต ซึ่งรังสีที่นำมาใช้

ฉายอาหารนั้นมี 3 ชนิด ได้แก่ รังสีแกมมา รังสีอิเล็กตรอน และรังสีเอกซ์ ซึ่งในปัจจุบันการฉายรังสีนิยมใช้รังสีแกมมา ซึ่งเป็นกัมมันตภาพรังสี มีต้นทุนที่ต่ำ เนื่องจากมีครึ่งชีวิตที่ยาวนาน โดยมีการปลดปล่อยรังสีออกมาทุกทิศทางตลอดเวลา จึงเหมาะกับวัตถุที่มีขนาดใหญ่ วัตถุที่มีขนาดใหญ่จะใช้เวลาและพลังงานในการฉายรังสีที่มากขึ้น ซึ่งส่งผลกระทบต่อต้นทุนการผลิต และการเป็นกัมมันตภาพรังสีอาจส่งผลกระทบต่อมนุษย์และสิ่งแวดล้อมได้ ปัจจุบันสถาบันวิจัยแสงซินโครตรอน (องค์การมหาชน) ได้พัฒนาโครงการสร้างเครื่องเร่งอนุภาคแนวตรงต้นแบบพลังงาน 6 MeV ดังแสดงในรูปที่ 1.2 เพื่อผลิตรังสีเอกซ์ในการฉายแสงผลไม้สดสำหรับปลอดเชื้อที่อาจทำให้เกิดโรค เชลลการเน่าเสียและลดสภาพหลังการเก็บเกี่ยว และยับยั้งการงอกของพืชมีหัวระหว่างการเก็บรักษา โดยฉายผลไม้ด้วยรังสีเอกซ์ที่ปริมาณรังสีสูงสุด 1 กิโลเกรย์ (kGy) ซึ่งรังสีเอกซ์นั้นได้มาจากการใช้เครื่องเร่งอนุภาคแนวตรง (Linear Accelerator) เร่งลำอิเล็กตรอนเข้าชนเป้าโลหะหนักจนเกิดรังสีเอกซ์ ซึ่งมีต้นทุนที่ค่อนข้างสูงกว่าการใช้รังสีแกมมา ซึ่งหากมีการฉายรังสีเฉพาะบริเวณที่ตรวจพบวัตถุและสามารถฉายรังสีในปริมาณที่เหมาะสมได้ จะช่วยพัฒนาโครงการสร้างเครื่องเร่งอนุภาคแนวตรงต้นแบบพลังงาน 6 MeV เพื่ออบรังสีผลไม้ได้ ดังนั้น การนำเทคโนโลยีปัญญาประดิษฐ์เข้ามาช่วยในการปรับการฉายรังสีให้เหมาะสม ได้แก่ การประมาณขนาดของวัตถุที่จะนำมาฉายรังสี ก็จะสามารถช่วยลดต้นทุนและการใช้พลังงานอย่างคุ้มค่าในกระบวนการได้



รูปที่ 1.2 เครื่องเร่งอนุภาคแนวตรงต้นแบบพลังงาน 6 MeV สำหรับอบรังสีผลไม้

(ที่มา: <https://tinyurl.com/24o88js9>)

การคัดแยกไซส์มะม่วงน้ำดอกไม้สำหรับการส่งออก ในปัจจุบันได้มีการคัดแยกไซส์ด้วยมนุษย์ โดยการชั่งน้ำหนัก และระบบการผลิตแบบอัตโนมัติโดยการติดตั้งโหลดเซลล์ (Loadcell) ดังแสดงในรูปที่ 1.3 หากการคัดแยกไซส์ทำได้ด้วยกล้องเว็บแคมโดยใช้เทคนิคปัญญาประดิษฐ์ ก็จะช่วยเพิ่ม

ความเร็วในกระบวนการผลิตได้ ซึ่งการคัดแยกไซส์ได้ถูกต้องตามเกณฑ์จะช่วยเพิ่มกำไรเนื่องจากปัจจัยเรื่องราคา โดยนอกจากเรื่องราคาแล้วคุณภาพและมาตรฐานในการส่งออกถือเป็นสิ่งสำคัญ โดยมะม่วงที่มีคุณภาพ คือ ตรงตามสายพันธุ์ ไม่มีกลิ่นหรือรสชาติที่ผิดปกติ ไม่มีรอยชำหรือเน่าเสียที่ทำให้ไม่เหมาะสมต่อการบริโภค ไม่มีศัตรูพืชที่กระทบต่อคุณภาพของเนื้อมะม่วง และมาตรฐานของมะม่วง คือ การจัดเตรียม การบรรจุหีบห่อ และการติดฉลาก เป็นต้น



รูปที่ 1.3 การคัดแยกไซส์มะม่วงน้ำดอกไม้

(ที่มา: https://mediatank.doae.go.th/medias/file_upload/12-2022/3-1751705114510091.pdf)

1.2 วัตถุประสงค์

1.2.1 เพื่อประยุกต์ใช้เทคนิคปัญญาประดิษฐ์ในการประมาณขนาด (Dimension) กว้าง ยาว สูง ของมะม่วงน้ำดอกไม้

1.2.2 เพื่อประยุกต์ใช้เทคนิคปัญญาประดิษฐ์ในการคัดแยกไซส์ (2S, S, M, L, 2L, 3L) ของมะม่วงน้ำดอกไม้

1.2.3 เพื่อประยุกต์ใช้เทคนิคปัญญาประดิษฐ์ในการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ (มะม่วงดีและมะม่วงเสียที่มีรอยตำหนิ)

1.3 ขอบเขตของงานวิจัย

1.3.1 สร้างโมเดลหรือโปรแกรมในการประมาณขนาด (กว้าง ยาว สูง) ของมะม่วงน้ำดอกไม้

1.3.2 สร้างโมเดลหรือโปรแกรมในการคัดแยกไซส์ (2S, S, M, L, 2L, 3L) ของมะม่วงน้ำดอกไม้

- 1.3.3 สร้างโมเดลคัดแยกคุณภาพมะม่วงน้ำดอกไม้ ซึ่งแยกระหว่างมะม่วงดีและมะม่วงเสียที่มีรอยตำหนิ
- 1.3.4 ใช้มะม่วงน้ำดอกไม้ในการทดลองและทดสอบ
- 1.3.5 ใช้กล้องเว็บแคมที่มีความละเอียดไม่ต่ำกว่า 640 x 480 พิกเซล ในการทดสอบและถ่ายภาพเก็บข้อมูลสำหรับการเทรนโมเดล (Datasets)
- 1.3.6 ในการทดสอบและถ่ายภาพเก็บข้อมูล Datasets จะติดตั้งกล้องเว็บแคมห่างจากพื้นของสายพานเป็นระยะ 55.5 เซนติเมตร
- 1.3.7 ติดตั้งหลอดไฟ Dimmable LED จำนวน 2 หลอด ที่ความสูงเดียวกับการติดตั้งกล้องเว็บแคม
- 1.3.8 การถ่ายภาพเก็บข้อมูล Datasets ที่ความสว่าง 2 เงื่อนไข ได้แก่ เงื่อนไขที่ 1 ที่ความสว่างห้องปกติ อยู่ในช่วง 430 - 450 ลักซ์ และเงื่อนไขที่ 2 เพิ่มความสว่างอยู่ในช่วง 1000 - 1020 ลักซ์
- 1.3.9 ชุดสายพานในการถ่ายภาพและเก็บข้อมูล จากสถาบันวิจัยแสงซินโครตรอน
- 1.3.10 วัดขนาดและเก็บข้อมูล กว้าง ยาว สูง ของมะม่วงด้วยเวอร์เนียร์เนียคาลิปเปอร์
- 1.3.11 เก็บข้อมูลน้ำหนักของมะม่วงด้วยเครื่องชั่งน้ำหนักแบบดิจิทัล

1.4 ระเบียบวิธีวิจัย

- 1.4.1 ศึกษางานวิจัยที่และทฤษฎีเกี่ยวข้อง
- 1.4.2 ออกแบบการทดสอบและเลือกโมเดลหรือเทคนิคปัญญาประดิษฐ์
- 1.4.3 เก็บข้อมูลรูปภาพหรือวิดีโอ สำหรับการฝึกฝนโมเดล (Datasets)
- 1.4.4 ฝึกฝนโมเดล
- 1.4.5 ทดสอบโมเดลกับข้อมูลชุดทดสอบ (Unseen Data) เพื่อประเมินประสิทธิภาพ และทำการปรับปรุงแก้ไขเพื่อให้โมเดลมีความถูกต้อง ความแม่นยำ และมีประสิทธิภาพดีที่สุด
- 1.4.6 แก้ไขและปรับปรุงโมเดลกับชุดทดสอบ
- 1.4.7 วิเคราะห์ข้อมูลและผลลัพธ์ที่ได้
- 1.4.8 สรุปและอภิปรายผล
- 1.4.9 จัดทำเอกสารและรายงานการวิจัย

1.5 สถานที่ทำงานวิจัย

มหาวิทยาลัยเทคโนโลยีสุรนารี ตำบลสุรนารี อำเภอเมือง จังหวัดนครราชสีมา 30000 และสถาบันวิจัยแสงซินโครตรอน (องค์การมหาชน)

1.6 ประโยชน์ที่คาดว่าจะได้รับ

- 1.6.1 สามารถควบคุมคุณภาพสำหรับการส่งออกผลิตภัณฑ์ทางการเกษตรได้
- 1.6.2 ลดต้นทุนการผลิตในกระบวนการฉายรังสี จากการลดระยะเวลาและลดพลังงานในการฉายรังสี
- 1.6.3 เพิ่มมูลค่าของผลิตภัณฑ์ทางการเกษตร จากการคัดแยกไซส์และการฉายรังสี
- 1.6.4 สามารถประยุกต์ใช้เทคโนโลยีที่พัฒนาขึ้น ในการคัดแยกคุณภาพ ขนาด และฉายรังสี เพื่อยกระดับคุณภาพผลิตภัณฑ์ทางการเกษตรสำหรับการส่งออก และประยุกต์ใช้กับผลิตภัณฑ์อื่นได้



บทที่ 2

ทฤษฎีและหลักการที่เกี่ยวข้องกับงานวิจัย

ในบทนี้จะนำเสนอทฤษฎีและหลักการที่เกี่ยวข้องในการศึกษาและการพัฒนาโปรแกรมหรือโมเดลเพื่อการประมาณขนาด การตัดแยกไซส์ และการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้ด้วยเทคนิคปัญญาประดิษฐ์ ซึ่งมีการใช้เทคนิคต่าง ๆ เข้ามาประยุกต์ร่วมกัน โดยมีรายละเอียด ดังนี้

- 2.1 มะม่วง (Mangifera Indica L.)
- 2.2 อาหารฉายรังสี (Irradiation foods)
- 2.3 การมองเห็นด้วยคอมพิวเตอร์ (Computer Vision)
- 2.4 การเรียนรู้ของเครื่อง (Machine Learning)
- 2.5 การเรียนรู้เชิงลึก (Deep Learning)
- 2.6 การประเมินผล (Model Assessment)

2.1 มะม่วง (Mangifera Indica L.)

มะม่วง (ชื่อวิทยาศาสตร์ : Mangifera Indica L.) เป็นไม้ยืนต้นและเป็นผลไม้เมืองร้อนที่จัดอยู่ในวงศ์ ANACARDIACEAE มีถิ่นกำเนิดมาจากแถบประเทศอินเดีย บังคลาเทศ และทางแถบตะวันตกเฉียงเหนือของพม่า โดยสายพันธุ์ของมะม่วงทั่วโลกมีมากกว่า 1,000 สายพันธุ์ ซึ่งมีความแตกต่างกันทั้งรูปร่าง ขนาด น้ำหนัก สีผิว กลิ่น เนื้อสัมผัส รสชาติ เป็นต้น สามารถรับประทานได้ทั้งผลดิบและสุก มีประโยชน์ในด้านคุณค่าทางอาหาร ซึ่งประกอบด้วยสารอาหารสำคัญ เช่น คาร์โบไฮเดรต โปรตีน น้ำตาล ใยอาหาร วิตามินเอ วิตามินบี และเบต้าแคโรทีน ซึ่งมีส่วนช่วยในการบำรุงสายตา ช่วยในเรื่องของระบบย่อยอาหารและการขับถ่าย ดูแลผิวพรรณ บำรุงสายตา ควบคุมความดันโลหิต ช่วยป้องกันโรคหัวใจ และลดระดับคอเลสเตอรอล เป็นต้น

มะม่วงน้ำดอกไม้ไม่มีถิ่นกำเนิดในประเทศไทยเป็นมะม่วงพันธุ์ท้องถิ่น แสดงดังในรูปที่ 2.1 ซึ่งสายพันธุ์ที่ได้รับความนิยมมาก ได้แก่ มะม่วงน้ำดอกไม้สีทอง และมะม่วงน้ำดอกไม้เบอร์ 4 ซึ่งมะม่วงน้ำดอกไม้สีทองเป็นมะม่วงที่กลายพันธุ์มาจากมะม่วงน้ำดอกไม้พระประแดง เปลือกมีความหนากว่ามะม่วงน้ำดอกไม้พันธุ์เบอร์ 4 สามารถทนโรคและแมลงได้ดี ผลดิบมีสีเขียวนวล เนื้อผลมีสีขาว มีรสเปรี้ยว ผลแก่ที่อยู่บนต้นจะมีสีเหลืองอมครีม คล้ายกับผลมะม่วงสุก เมื่อผลมะม่วงสุกจัดจะมีสีเหลืองทอง เนื้อละเอียด มีรสหวาน ดังนั้น มะม่วงน้ำดอกไม้สีทอง และมะม่วงน้ำดอกไม้เบอร์ 4 จึงเป็นสายพันธุ์ที่ได้รับความนิยมในการรับประทานผลสุก



รูปที่ 2.1 มะม่วงน้ำดอกไม้สีทองผลดิบและผลสุก (ที่มา: <https://depositphotos.com/th/photo/barracuda-mango-tree-organic-farm-thailand-272045178.html>)

การเพาะปลูกและขยายพันธุ์ของมะม่วงน้ำดอกไม้จะนิยมเป็นวิธีการทาบกิ่ง การติดตา และเสียบยอดเนื่องจากช่วยลดโอกาสในการกลายพันธุ์จากการเพาะเมล็ด ลำต้นและรากแก้วที่แข็งแรงจากการเลือกต้นตอที่ดี การปลูกมะม่วงน้ำดอกไม้จะปลูกในช่วงต้นของฤดูฝน (พฤษภาคม-กรกฎาคม) ซึ่งระยะเวลาในการติดผลประมาณ 3-4 ปี หลังจากการปลูก ปัจจุบันนิยมปลูกกระยะชิดโดยมีการควบคุมทรงพุ่มให้มีประมาณ 2.5-3 เมตร มีระยะห่างระหว่างต้นประมาณ 4 x 4 เมตร หรือ 4 x 6 เมตร เพื่ออำนวยความสะดวกในการปฏิบัติงาน การดูแลรักษา การจัดทรงพุ่มและการตัดแต่งกิ่ง โดยเฉพาะสายพันธุ์ที่ต้องมีการห่อผล การให้น้ำเป็นปัจจัยหลักในการผลิตมะม่วงให้ได้คุณภาพ ซึ่งจะควบคุมน้ำไม่ให้มีน้ำท่วมขังและต้องไม่ขาดน้ำ โดยการให้น้ำจะแบ่งออกเป็น 3 ช่วงได้แก่ การให้น้ำหลังตัดแต่งกิ่งโดยใช้ปุ๋ยเคมีร่วมกับปุ๋ยอินทรีย์ สูตร 15-15-15 หรือ 16-16-16 การให้น้ำช่วงก่อนออกดอกจะแบ่งเป็นการให้น้ำทางดินและทางใบ การให้น้ำทางดินจะเป็นปุ๋ยที่มีโพแทสเซียม (K) สูง แต่มีไนโตรเจน (N) ต่ำ การให้น้ำทางใบจะเป็นปุ๋ยที่มีฟอสเฟต (PO_4^{3-}) สูง และการให้น้ำระยะติดผลจะเริ่มจากมะม่วงเริ่มติดผลจนถึงอายุ 12 สัปดาห์ โดยใช้ปุ๋ยเคมีสูตร 13-13-21 หรือ 14-14-21 จนถึงช่วงก่อนเก็บเกี่ยวจะมีการให้น้ำสูตร 13-0-46 ประมาณ 2 ครั้ง โดยเว้นระยะ 1 สัปดาห์ จะช่วยให้อายุของมะม่วงดีขึ้น

การแต่งผลและการห่อผล แสดงดังในรูปที่ 2.2 จะเริ่มในช่วงหลังจากดอกบาน 45-60 วัน ทำการตัดการตัดแต่งผลที่เปี้ยว และมีตำหนิจากโรคหรือแมลงออก โดยตัดให้เหลือผลที่สมบูรณ์ไว้ช่อละ 1 ผล จากนั้นจุ่มหรือพ่นสารเคมีสำหรับป้องกันศัตรูพืช รอให้แห้งและทำการห่อผล เพื่อป้องกันแมลง การห่อผลสำหรับมะม่วงน้ำดอกไม้จะใช้ถุงคาร์บอนด้านนอกเป็นสีน้ำตาล ด้านในเป็นสีดำ ซึ่งจะช่วยให้มะม่วงมีสีผิวที่สดใส สวยงาม โดยมะม่วงน้ำดอกไม้จะมีอายุการเก็บเกี่ยวผลแก่อยู่ที่ 105-120 วัน

หลังดอกบาน (ขึ้นกับปัจจัยและสภาพแวดล้อมในแปลงเพาะปลูก) แต่มะม่วงน้ำดอกไม้เพื่อการส่งออกจะเก็บเกี่ยวประมาณ 98 วัน โดยนับหลังดอกบาน



รูปที่ 2.2 การห่อผลมะม่วงน้ำดอกไม้ (ที่มา: https://cowboyfarm.mju.ac.th/wtms_news_Detail.aspx?nID=27288&lang=th-TH)

เมื่อป้องกันแมลงที่จะทำให้มะม่วงเกิดความเสียหายด้วยการห่อผลแล้ว การปลูกมะม่วงยังมีปัญหาโรคและแมลงศัตรูพืชของมะม่วงที่ส่งผลกระทบต่อการเจริญเติบโต แสดงดังในรูปที่ 2.3 ทำให้ผลผลิตเสียหาย ซึ่งเป็นข้อจำกัดในการส่งออก โรคของมะม่วงเป็นอาการผิดปกติที่เกิดขึ้นกับส่วนต่าง ๆ เช่น ใบ ดอก ผล ได้แก่ โรคแอนแทรคโนส โรคราแป้ง โรคช็อคดำ โรคเปลือกแตกยางไหล โรคสะเกบ โรคกิ่งแห้งหรือยางไหล และโรคขั้วผลเน่า ส่วนแมลงศัตรูพืชของมะม่วงมีหลายชนิด ซึ่งแมลงจะทำลาย ใบ กิ่ง ดอก ผล ซึ่งมีทั้งแมลงปากกัด ปากดูด หนอนชนิดต่าง ๆ ซึ่งจะพบได้ตลอดทั้งฤดูการปลูก แมลงศัตรูพืชที่สำคัญ เช่น แมลงวันผลไม้มะม่วง เพลี้ยจักจั่นมะม่วง แมลงกินใบ เพลี้ยแป้ง หนอนผีเสื้อเจาะผลมะม่วง ตัวงาเจาะเมล็ดมะม่วง เป็นต้น



โรคแอนแทรกโนส



โรคราแป้ง



โรคราดำ



แมลงวันผลไม้มะม่วง



เพลี้ยแป้ง



ด้วงเจาะเมล็ดมะม่วง

รูปที่ 2.3 ตัวอย่างลักษณะของโรคและแมลงศัตรูพืชของมะม่วง (ที่มา: https://mediatank.doae.go.th/medias/file_upload/12-2022/3-1751705114510091.pdf)

ในปัจจุบันพบการปลูกมะม่วงน้ำดอกไม้ทุกภาคของประเทศไทย โดยมีพื้นที่ขึ้นทะเบียนเกษตรกรผู้ปลูกมะม่วงทั่วประเทศจำนวน 599,370 ไร่ ซึ่งในปี 2566 มีผลผลิตมะม่วงเชิงพาณิชย์รวม 1.34 ล้านตัน แบ่งเป็นภาคเหนือ ร้อยละ 50 ภาคกลาง ร้อยละ 35 และภาคตะวันออกร้อยละ 15 ซึ่งผลผลิตดังกล่าวทั้งบริโภคในประเทศและส่งออกทั่วโลก โดยจากสถิติการส่งออกในปี 2566 มะม่วงไทยมีการส่งออกทั่วโลกมากถึง 112,047 เมตริกตัน คิดเป็นมูลค่า 3,236.16 ล้านบาท มีมูลค่าเพิ่มขึ้นจากปี 2565 ถึง 219.92 ล้านบาท (3,016.24 ล้านบาท) โดยตลาดส่งออกมะม่วงสดที่สำคัญของไทยคือ มาเลเซีย เกาหลีใต้ เวียดนาม ญี่ปุ่น ฮองกง สิงคโปร์ จีน รัสเซีย ลาว เมียนมา สหภาพยุโรป และมะม่วงกระป๋องมีตลาดส่งออกที่สำคัญอยู่ที่ญี่ปุ่น สหรัฐอเมริกา สหราชอาณาจักร ออสเตรเลีย ฝรั่งเศส เยอรมนี เป็นต้น

การส่งออกมะม่วงน้ำดอกไม้ หรือผลิตภัณฑ์ทางการเกษตรอื่น ๆ ของไทย ไปยังต่างประเทศจำเป็นต้องปฏิบัติตามกฎของประเทศผู้นำเข้าและส่งออก โดยพิจารณาตามข้อกำหนดและกฎหมายของประเทศผู้นำเข้า ซึ่งอาจมีข้อบังคับเฉพาะเกี่ยวกับการฉลากเพื่อควบคุมศัตรูพืชและสิ่งปนเปื้อนอื่น ๆ ประเทศไทยมีกฎหมายเกี่ยวข้องกับการส่งออกสินค้าเกษตร ได้แก่ พระราชบัญญัติอาหาร พ.ศ. ๒๕๒๒ กฎหมายนี้ควบคุมความปลอดภัยทางอาหารของสินค้าเกษตรที่ผลิตหรือจำหน่ายในประเทศไทย รวมถึงการส่งออกไปยังต่างประเทศ พระราชบัญญัติการส่งออกและนำเข้าพืช พ.ศ. 2507 กฎหมายนี้กำหนดข้อบังคับเกี่ยวกับการส่งออกและนำเข้าพืช รวมถึงข้อกำหนดในการควบคุมศัตรูพืช

ซึ่งอาจครอบคลุมถึงการฉายรังสีในกรณีที่มีความจำเป็นเพื่อปฏิบัติตามข้อกำหนดของประเทศผู้นำเข้า และมีเกณฑ์มาตรฐานอาหารฉายรังสี (CODEX STAN 106-1983) มาตรฐานนี้ใช้กับอาหารที่ผ่านกระบวนการฉายรังสีภายใต้ข้อกำหนดด้านสุขอนามัยและมาตรฐานอาหาร

2.2 อาหารฉายรังสี (Irradiation foods)

อาหารฉายรังสี (Irradiation foods) คือ อาหารที่ผ่านกรรมวิธีการฉายรังสี เพื่อบรรลุมวัตถุประสงค์ในการฉายรังสี ซึ่งวัตถุประสงค์ของการฉายรังสี ได้แก่ เพื่อฆ่าจุลินทรีย์ที่ทำให้เกิดโรค ช่วยยืดอายุการเก็บรักษาโดยช่วยชะลอการเน่าเสียของผลไม้ ช่วยชะลอการสุกของผลไม้ ช่วยยับยั้งการงอกระหว่างการเก็บรักษา ทำลายและยับยั้งการแพร่พันธุ์ของแมลง และช่วยลดปริมาณปรสิต ซึ่งการฉายรังสีอาหารได้รับการยอมรับจากประเทศต่าง ๆ ทั่วโลกกว่า 40 ประเทศ เช่น สหรัฐอเมริกา ฝรั่งเศส แคนาดา จีน ฟิลิปปินส์ แอฟริกาใต้ ปากีสถาน และไทย เป็นต้น อาหารที่ผ่านการฉายรังสีแล้ว ต้องระบุวัตถุประสงค์ของการฉายรังสี วัน เดือน ปี ที่ทำการฉายรังสีด้วย ในประเทศไทย สำนักงานคณะกรรมการอาหารและยา (อย.) เป็นหน่วยงานที่ทำหน้าที่ควบคุมและกำกับดูแลอาหารฉายรังสี โดยชนิดของรังสีที่อนุญาตให้ใช้ในกระบวนการฉายรังสีต้องได้จากแหล่งของรังสีที่มีแหล่งกำเนิด ดังนี้

1. รังสีแกมมา มีต้นกำเนิดจากเครื่องฉายรังสีที่มีโคบอลต์-60 (^{60}Co) หรือซีเซียม-137 (^{137}Cs)
2. รังสีเอกซ์ มีต้นกำเนิดจากเครื่องผลิตรังสีเอกซ์ ที่ทำงานด้วยระดับพลังงานที่ต่ำกว่าหรือเท่ากับ 5 ล้านอิเล็กตรอนโวลต์
3. รังสีอิเล็กตรอน มีต้นกำเนิดจากเครื่องเร่งอนุภาคอิเล็กตรอน ที่ทำงานด้วยระดับพลังงานที่ต่ำกว่าหรือเท่ากับ 10 ล้านอิเล็กตรอนโวลต์

ปัจจุบันกฎหมายอาหารฉายรังสีจะกำหนดวัตถุประสงค์ของการฉายรังสีอาหาร แทนการกำหนดชนิดของอาหารที่อนุญาตให้ฉายรังสี ซึ่งวัตถุประสงค์ของการฉายรังสีอาหาร ได้แก่ เพื่อฆ่าเชื้อจุลินทรีย์ที่ทำให้เกิดโรค ช่วยยืดอายุการเก็บรักษาโดยช่วยชะลอการเน่าเสียของผลไม้ ช่วยชะลอการสุกของผลไม้ระหว่างการเก็บรักษาหรือการขนส่ง ช่วยลดปริมาณปรสิต และทำลายและยับยั้งการแพร่พันธุ์ของแมลง เป็นต้น อาหารที่นำมาฉายรังสี เช่น ผัก ผลไม้ เนื้อสัตว์ อาหารแปรรูปอื่น ๆ แสดงดังในรูปที่ 2.4 ซึ่งจะมีปริมาณรังสีที่ใช้แตกต่างกันตามวัตถุประสงค์



รูปที่ 2.4 ตัวอย่างอาหารฉายรังสี (ที่มา: <https://tinyurl.com/2bnm97k8>)

การฉายรังสีอาหารโดยใช้ปริมาณรังสีที่แตกต่างกันตามวัตถุประสงค์ เช่น ฉายรังสีแฮม ปริมาณ 2 กิโลเกรย์ เพื่อกำจัดเชื้อโรคซัลโมเนลลาที่ทำให้เกิดโรคท้องร่วง การยับยั้งการงอกหอมหัวใหญ่ โดยฉายรังสีปริมาณ 0.09 กิโลเกรย์ ร่วมกับเก็บในห้องเย็นจะเก็บได้นานกว่า 5 เดือนโดยไม่งอก ในทางกฎหมายกำหนดว่า การฉายรังสีอาหาร ต้องมีปริมาณรังสีต่ำสุดที่ทำให้บรรลุวัตถุประสงค์ของการฉายรังสี และมีปริมาณรังสีสูงสุดอยู่ในระดับที่ปลอดภัยต่อผู้บริโภค มีคุณค่าทางโภชนาการ และยังมีรสชาติที่คงเดิมไม่ผิดเพี้ยนเป็นที่ต้องการของผู้บริโภค

ปริมาณรังสีดูดกลืน (Radiation absorbed dose) คือ ปริมาณพลังงานที่อาหารดูดกลืนไว้ ต่อหนึ่งหน่วยน้ำหนัก มีหน่วยเป็นเกรย์ และปริมาณรังสีจะต้องเป็นไปตามวัตถุประสงค์ของการฉายรังสี ซึ่งการฉายรังสีในอาหาร ได้รับการพิสูจน์แล้วว่าปลอดภัยต่อผู้บริโภค โดยคณะกรรมการอาหารและยาของสหรัฐอเมริกา ซึ่งอาหารสดที่มีการฉายรังสีไม่เกิน 1 กิโลเกรย์ อาหารแห้งที่มีการฉายรังสีไม่เกิน 30 กิโลเกรย์ และอาหารอื่นๆ ที่ผ่านการฉายรังสีปริมาณเฉลี่ยไม่เกิน 10 กิโลเกรย์ จะไม่ก่อให้เกิดโทษอันตราย และไม่ก่อเกิดปัญหาทางโภชนาการและจุลชีววิทยา โดยอาหารที่ผ่านการฉายรังสีแล้วจะต้องแสดงฉลากอาหารฉายรังสี ที่มีข้อความว่า “ผ่านการฉายรังสีแล้ว” และมีเครื่องหมาย Radura รูปที่ 2.5 แสดงเครื่องหมาย Radura บนผลิตภัณฑ์อาหารฉายรังสี



รูปที่ 2.5 เครื่องหมาย Radura บนผลิตภัณฑ์อาหารฉายรังสี (ที่มา: <https://www.mhesi.go.th/index.php/all-media/infographic/7216-650405general.html>)

โดยการฉายรังสีนั้น ปัจจุบันใช้รังสีแกมมา ที่มีต้นกำเนิดจากเครื่องฉายรังสีที่มีโคบอลต์-60 (^{60}Co) หรือซีเซียม-137 (^{137}Cs) ซึ่งเป็นกัมมันตภาพรังสี เนื่องจากมีต้นทุนที่ต่ำและมีอำนาจในการทะลุทะลวงสูง เหมาะสำหรับการฉายรังสีในกรณีที่มีวัตถุหรือสินค้าปริมาณมาก ๆ หรือมีขนาดใหญ่ โดยลักษณะการฉายรังสีในปัจจุบันเป็นการกระจายทุกทิศทาง และปลดปล่อยอยู่ตลอดเวลา ต้องทำอยู่ในห้องที่มีผนังหนา

ในการทำงานงานวิจัยได้มีการใช้เครื่องฉายรังสีจากสถาบันวิจัยแสงซินโครตรอน (องค์การมหาชน) ซึ่งสถาบันวิจัยแสงซินโครตรอนได้พัฒนาเทคโนโลยีเครื่องเร่งอนุภาคแนวตรงสำหรับประยุกต์ใช้ด้านการเกษตรเพื่อช่วยชะลอการเน่าเสียของผักและผลไม้ โดยการฉายรังสีเอกซ์ฆ่าเชื้อจุลินทรีย์ รังสีเอกซ์ถูกผลิตจากการเร่งอิเล็กตรอนพลังงานสูงให้ชนเป้าโลหะหนัก พลังงานของรังสีเอกซ์จึงสูงพอสำหรับทำลายเซลล์ของเชื้อจุลินทรีย์และเชื้อโรคต่าง ๆ ซึ่งลักษณะการฉายรังสีจะเป็นการฉายตลอดเวลา และฉายเต็มพื้นที่ถึงแม้วัตถุจะมีขนาดเล็กก็ตาม นั่นหมายถึงการสูญเสียพลังงานโดยสูญเปล่าและส่งผลกระทบต่อต้นทุนการผลิตที่สูงขึ้นตามไปด้วย

การคำนวณปริมาณรังสีให้เหมาะสมกับวัตถุหรือสินค้า ขนาดของวัตถุจะส่งผลกระทบต่อปริมาณรังสี วัตถุที่มีขนาดใหญ่จะใช้ปริมาณรังสีมาก และวัตถุขนาดเล็กจะใช้ปริมาณรังสีน้อย ซึ่งจะส่งผลกระทบต่อพลังงาน ระยะเวลาในการฉายรังสีและต้นทุนในการผลิต โดยมีสมการที่เกี่ยวข้องดังนี้

สมการคำนวณปริมาณรังสีสำหรับพื้นผิว (Dose Surface) โดยขึ้นกับความสูง (Depth) หรือความหนาของวัตถุ

$$D_d = D_{sf} e^{-\mu_m \rho D} \quad (2.1)$$

สมการคำนวณความเร็วของสายพาน โดยขึ้นกับความกว้าง (Width) ของวัตถุ

$$D_{sf} = n_c \left[\frac{\mu_m P}{vW} \right] \quad (2.2)$$

สมการคำนวณเวลาที่ใช้ในการฉายรังสี โดยขึ้นกับความยาว (Length) ของวัตถุ

$$t = \frac{L}{v} \quad (2.3)$$

สมการคำนวณพลังงานในการฉายรังสี

$$E = P \times t \quad (2.4)$$

โดยที่

D_{sf} = Surface dose (kGy)

D_d = Depth dose (kGy)

μ_m = Mass absorption coefficient (cm^2/kg)

v = Speed conveyor (cm/s)

ρ = Object density (kg/cm^3)

d = Depth (cm)

P = Electron Beam Power (kW)

n_c = The X-ray conversion efficiency

E = X-ray Energy (MeV)

$n_c = E/60$

t = Time for irradiation

W = Object Width (cm)

L = Object Length (cm)

D = Object Depth (cm)

ตัวอย่างในการคำนวณปริมาณการฉายรังสี

โดยกำหนดปริมาณโดสของการฉายรังสี (Depth dose) $D_d = 0.4$ kGy ค่าความหนาแน่นของวัตถุที่ฉายรังสี โดยจะใช้ค่าความหนาแน่นเฉลี่ยของมะม่วงน้ำดอกไม้จากชุดข้อมูลสำหรับเตรียมเป็น Datasets โดยมีค่า $\rho = 0.489$ kg/cm³ และกำหนดค่าประสิทธิภาพของเครื่องฉายรังสี ที่สถาบันวิจัยแสงซินโครตรอน มีดังนี้ $n_c = 0.085$, $\mu_m = 0.03 \times 10^3$ cm²/kg และ $P = 0.8721$ kW

กรณีที่ 1 มะม่วงไซส์ 2L 1 ลูก มีขนาด กว้าง 8 เซนติเมตร ยาว 15 เซนติเมตร สูง 7 เซนติเมตร

$$D_d = D_{sf} e^{-\mu_m \rho D}$$

$$0.4 = D_{sf} e^{-(0.03 \times 10^3)(0.489 \times 10^{-4})(7)}$$

$$D_{sf} = 0.443 \text{ kGy}$$

คำนวณหาความเร็วของสายพาน (Speed conveyer)

$$D_{sf} = n_c \left[\frac{\mu_m P}{vW} \right]$$

$$0.443 = 0.085 \left[\frac{(0.03 \times 10^3)(0.8721)}{v \times 8} \right]$$

$$v = 0.627 \text{ cm/s}$$

คำนวณระยะเวลาที่ใช้ในการฉายรังสี

$$t = \frac{L}{v}$$

$$t = \frac{16}{0.627}$$

$$t = 25.5 \text{ sec}$$

คำนวณพลังงานที่ใช้ในการฉายรังสี

$$E = P \times t$$

$$E = 0.8721 \times 25.5$$

$$E = 22.24 \text{ kJ}$$

ตั้งนี้ วัสดุขนาด 8 x 16 x 7 เซนติเมตร ใช้ระยะเวลาในการฉายรังสี 25.5 วินาที และใช้พลังงานในการฉายรังสี 22.24 กิโลจูล หากคำนวณเป็นค่าไฟในการฉายรังสีจากพลังงานที่ได้ โดยคิดค่าไฟหน่วยละ 4 บาท/kWh จะเสียค่าใช้จ่าย 0.0000247 บาท ต่อการฉายรังสีมะม่วงไซส์ 2L 1 ลูก

กรณีที่ 2 มะม่วงไซส์ M 1 ลูก มีขนาด กว้าง 7 เซนติเมตร ยาว 14 เซนติเมตร สูง 5 เซนติเมตร

$$D_d = D_{sf} e^{-\mu_m \rho D}$$

$$0.4 = D_{sf} e^{-(0.03 \times 10^3)(4.89 \times 10^{-4})(5)}$$

$$D_{sf} = 0.430 \text{ kGy}$$

คำนวณหาความเร็วของสายพาน (Speed conveyer)

$$D_{sf} = n_c \left[\frac{\mu_m P}{vW} \right]$$

$$0.430 = 0.085 \left[\frac{(0.03 \times 10^3)(0.8721)}{v \times 7} \right]$$

$$v = 0.739 \text{ cm/s}$$

คำนวณระยะเวลาที่ใช้ในการฉายรังสี

$$t = \frac{L}{v}$$

$$t = \frac{14}{0.739}$$

$$t = 19 \text{ sec}$$

คำนวณพลังงานที่ใช้ในการฉายรังสี

$$E = P \times t$$

$$E = 0.8721 \times 19$$

$$E = 16.57 \text{ kJ}$$

ดังนั้น วัสดุขนาด $7 \times 14 \times 6$ เซนติเมตร ใช้ระยะเวลาในการฉายรังสี 19 วินาที และใช้พลังงานในการฉายรังสี 16.57 กิโลจูล หากคำนวณเป็นค่าไฟในการฉายรังสีจากพลังงานที่ได้ โดยคิดค่าไฟหน่วยละ 4 บาท/kWh จะเสียค่าใช้จ่าย 0.0000184 บาท ต่อการฉายรังสีมะม่วงไซส์ M 1 ลูก

จากการเปรียบเทียบการคำนวณด้วยวัตถุที่มีขนาดที่แตกต่างกัน โดยใช้วัตถุเป็นมะม่วงน้ำดอกไม้ในกรณีที่ 1 มะม่วงน้ำดอกไม้ไซส์ 2L 1 ลูก มีขนาด กว้าง 8 เซนติเมตร ยาว 15 เซนติเมตร สูง 7 เซนติเมตร และกรณีที่ 2 มะม่วงไซส์ M 1 ลูก มีขนาด กว้าง 7 เซนติเมตร ยาว 14 เซนติเมตร สูง 5 เซนติเมตร ซึ่งจะเห็นความแตกต่างกันโดยที่ความสูงของวัตถุส่งผลต่อปริมาณโดสในการฉายรังสี ส่วนความกว้างและความยาวของวัตถุส่งผลต่อระยะเวลาในการฉายรังสี เมื่อวัตถุมีขนาดใหญ่จะใช้ระยะเวลานานมากขึ้นและมีการคำนวณการปรับความเร็วของสายพานให้เหมาะสมที่จะทำให้ฉายรังสีได้อย่างทั่วถึง ไม่ช้าและไม่เร็วเกินไปจนทำให้วัตถุที่นำมาฉายรังสีเกิดความเสียหายได้ เมื่อมีการปรับความเร็วและระยะเวลาให้เหมาะสมแล้ว จะเห็นว่ามีการคำนวณพลังงานที่ใช้ในการฉายรังสี ค่าใช้จ่าย (ค่าไฟ) สำหรับการฉายรังสีต่อวัตถุหนึ่งชิ้น ซึ่งการใช้พลังงานที่สูงจะส่งผลต่อต้นทุนโดยตรง

ซึ่งถ้าหากมีการนำเทคโนโลยีสมัยใหม่ในปัจจุบัน เช่น เทคนิคปัญญาประดิษฐ์ การเรียนรู้ของเครื่อง การมองเห็นด้วยคอมพิวเตอร์ เข้ามาประยุกต์ใช้ในการฉายรังสี เพื่อทำการหาตรวจวัดขนาดของวัตถุที่จะเข้าไปฉายรังสีและสามารถหาขนาดการฉายรังสีที่เหมาะสมที่สุดได้ เนื่องจากในพื้นที่เสี่ยงไม่สามารถให้มนุษย์เข้าไปทำงานในพื้นที่นั้นได้

2.3 การมองเห็นด้วยคอมพิวเตอร์

การมองเห็นด้วยคอมพิวเตอร์ (Computer Vision) คือ เทคโนโลยีที่ใช้ในการรับรู้และมองเห็นภาพ โดยสามารถอธิบายภาพนั้นได้อย่างถูกต้องและมีประสิทธิภาพ การมองเห็นด้วยคอมพิวเตอร์จะใช้เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence) ที่มีความเกี่ยวเนื่องกับการประมวลผลภาพ (Image Processing) เพื่อเลียนแบบความสามารถของมนุษย์ โดยมุ่งเน้นไปในส่วนของการรับรู้ การมองเห็นและการจำแนกวัตถุจากภาพหรือวิดีโอ การมองเห็นด้วยคอมพิวเตอร์มีบทบาทสำคัญในหลายสาขามีการใช้งานที่หลากหลาย เช่น การจดจำใบหน้า การตรวจสอบคุณภาพสินค้าในโรงงานผลิตสินค้า การติดตามตำแหน่งมือ ระบบนำทางอัตโนมัติในรถยนต์ การวิเคราะห์ข้อมูลทางการแพทย์ เป็นต้น ในการที่จะทำให้คอมพิวเตอร์สามารถมองเห็นได้ สามารถทำได้ผ่านอุปกรณ์ที่เรียกว่า กล้อง ซึ่งเป็นที่สำคัญในการรับข้อมูลภาพ

2.3.1 กล้องเว็บแคม (Webcam)

กล้องเว็บแคม (Webcam) คือ กล้องดิจิทัลขนาดเล็กที่ถูกออกแบบมาเพื่อใช้งานร่วมกับคอมพิวเตอร์ โดยสามารถเชื่อมต่อผ่านพอร์ต USB กล้องเว็บแคมมีความสามารถในการถ่ายภาพนิ่งและบันทึกวิดีโอ รวมถึงสตรีมภาพและวิดีโอแบบเรียลไทม์ผ่านอินเทอร์เน็ตหรือเก็บ


บันทึกภาพได้ ซึ่งเมื่อนำมาใช้ในงานคอมพิวเตอร์วิชั่นหรือการมองเห็นด้วยคอมพิวเตอร์กล้องเว็บแคม จะทำหน้าที่เป็นเซ็นเซอร์สำหรับจับภาพจากสภาพแวดล้อมและแปลงภาพเหล่านั้นให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถประมวลผลได้ ซึ่งกล้องเว็บแคมที่ใช้ในงานวิจัยนี้เป็นกล้องเว็บแคม ยี่ห้อ Logitech รุ่น Brio 4K แสดงดังในรูปที่ 2.6 ซึ่งมีความละเอียด 720p 1080p และ 4K มี FPS (Frame per Second) 30 60 และ 90



รูปที่ 2.6 กล้องเว็บแคมนี่ห้อ Logitech รุ่น Brio 4K (ที่มา: <https://tinyurl.com/2ddtmqgd>)

2.3.2 การตรวจจับวัตถุ (Object Detection)

การตรวจจับวัตถุเป็นส่วนหนึ่งของคอมพิวเตอร์วิชั่น เป็นกระบวนการที่ใช้ในการระบุวัตถุภายในภาพหรือวิดีโอและประมวลผลเพื่อหาตำแหน่งและขนาดของวัตถุนั้น ซึ่งสามารถระบุวัตถุหลายอย่างในภาพเดียว แสดงดังในรูปที่ 2.7 ในปัจจุบันการตรวจจับวัตถุมีไลบรารีหรือแอปพลิเคชันสำเร็จรูปที่พร้อมใช้งาน ได้แก่ OpenCV (Open Source Computer Vision Library) และ YOLO (you only look once) เป็นต้น ซึ่งในการตรวจจับวัตถุจะแสดงผลออกมาในลักษณะที่เป็นกรอบสี่เหลี่ยมครอบวัตถุ เรียกว่า Bounding Box ซึ่งจะมีการระบุทั้งป้ายกำกับ (Label) และตำแหน่งของวัตถุที่อยู่ในรูปภาพหรือวิดีโอได้ด้วย



รูปที่ 2.7 การแยกวัตถุด้วยการเรียนรู้เชิงลึก (ที่มา: ElGendy, M. (2020). Deep Learning for Vision Systems [1])

2.3.3 การประมวลผลภาพ (Image Processing)

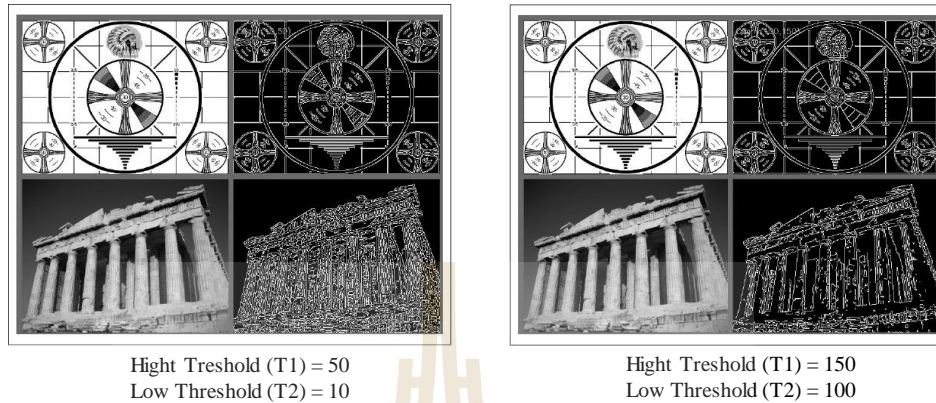
การประมวลผลภาพ (Image Processing) คือ กระบวนการจัดการและวิเคราะห์รูปภาพให้เป็นข้อมูลในแบบดิจิทัลโดยใช้คอมพิวเตอร์ เพื่อให้ได้ข้อมูลภาพที่ต้องการในการนำไปใช้ประมวลผลในกระบวนการถัดไป ซึ่งเทคนิคในการประมวลผลภาพมีหลายวิธี เช่น การกรองภาพหรือการกำจัดสัญญาณรบกวนออกจากภาพ (Image Filters) การซ้อนทับภาพ (Image Registration) การแบ่งส่วนภาพ (Image Segmentation) การหาขอบภาพในวัตถุ (Edge Detection)

การหาขอบภาพ (Edge Detection) คือ การหาเส้นขอบของวัตถุที่อยู่ในภาพ โดยทำให้ขอบเขตของภาพมีความเด่นชัดขึ้นมา ซึ่งจะตรวจสอบว่าเส้นขอบลากผ่านหรือใกล้เคียงกับจุดใด โดยที่ Edge คือ เส้นที่แยกวัตถุออกจากพื้นหลังหรือแยกวัตถุสองชิ้นออกจากกัน หรือการเปลี่ยนแปลงของค่า Intensity (ความเข้มแสง) ซึ่งหาได้จากกระบวนการ Derivative ซึ่งเกิดจากความแตกต่างของความเข้มแสงระหว่างพิกเซลที่อยู่ใกล้เคียงกัน หากความเข้มแสงแตกต่างมากขอบภาพก็จะชัดมาก การหาขอบเขตของภาพนั้นมีด้วยกันหลายวิธี เช่น Sobel Edge Detector, Prewitt Edge Detector, Roberts Edge Detector, Laplacian of a Gaussian Detector และ Canny Edge Detector

2.3.4 Canny Edge Detector

Canny edge detector หรือ Canny Edge Detection (แคนนี่) เป็นการหาเส้นรอบวัตถุที่อยู่ในภาพขาวดำ โดยที่มีเกณฑ์สองระดับ คือ เกณฑ์สูง (High Threshold: T1) และเกณฑ์ต่ำ (Low Threshold: T2) เมื่อขอบภาพเกิดจากความแตกต่างของความเข้มแสงจากจุดหนึ่งไปยังอีก


จุดหนึ่ง หากค่ามีความต่างมากก็จะทำให้เห็นขอบภาพได้ชัดเจน รูปที่ 2.8 แสดงการหาขอบด้วยวิธี Canny โดยกำหนดค่าเกณฑ์ (Threshold) ที่แตกต่างกัน



รูปที่ 2.8 การหาขอบวัตถุด้วยวิธี Canny โดยกำหนดค่าเกณฑ์ที่แตกต่างกัน (ที่มา: Bradski, G., & Kaehler, A. (2008). Learning OpenCV. O'Reilly Media, Inc [2])

2.3.4 Binary Images

ภาพไบนารี (Binary Image) คือ การแปลงภาพให้อยู่ในลักษณะที่มีค่าสี 2 กลุ่ม ได้แก่ สีขาว และสีดำ ซึ่งสีขาวจะแสดงค่าเป็น 0 และสีดำแสดงค่าเป็น 1 ดังแสดงในรูปที่ 2.9 โดยการแปลงภาพสีหรือภาพเทา (Grayscale) ให้เป็นภาพไบนารีจะเรียกว่า Thresholding โดยการกำหนดเกณฑ์หรือค่า Threshold หนึ่งค่า เพื่อแยกภาพสองกลุ่ม คือ พิกเซลที่มีค่าความสว่างมากกว่าหรือน้อยกว่าเกณฑ์ที่กำหนด จะถูกแทนที่ด้วย 0 หรือ 1 ตามลำดับ ภาพไบนารีมีการใช้งานในหลากหลายด้านเช่น การประมวลผลภาพ การแยกวัตถุออกจากพื้นหลัง เป็นต้น



รูปที่ 2.9 ค่าพิกเซลของรูปภาพไบนารี (ที่มา: <http://matlab.izmiran.ru/help/toolbox/images/intro4.html>)

2.4 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) คือ การทำให้ระบบคอมพิวเตอร์สามารถเรียนรู้ได้ด้วยตนเองจากข้อมูลและสภาพแวดล้อมที่ได้รับจากการเรียนรู้ของระบบ โดยที่ไม่จำเป็นต้องใช้มนุษย์ในควบคุมและเขียนโปรแกรม ซึ่ง Machine Learning เป็นเทคนิคที่ถูกใช้สำหรับการแก้ปัญหาที่มีความซับซ้อน โดยหลักการของ Machine Learning แบ่งเป็น 3 ประเภทตามรูปแบบการเรียนรู้ ได้แก่ Supervised Learning Unsupervised Learning และ Reinforcement Learning

1) Supervised Learning คือ การเรียนรู้แบบมีคณสอน ในเทคนิคทาง Machine Learning หากจะทำการแยกประเภทของรูปภาพ หมายถึงการนำรูปภาพ (Input data) และผลเฉลยใส่เข้าไปในโมเดล

2) Unsupervised Learning คือ การเรียนรู้แบบไม่มีคณสอน การนำ Input data ใส่เข้าไปในโมเดล Machine Learning โดยไม่จำเป็นต้องใส่ผลเฉลย ซึ่งโมเดลจะทำการแบ่งกลุ่มหรือจัดกลุ่มซึ่งจะเป็นการข้อมูลว่าในแต่ละกลุ่มนั้นมีความสัมพันธ์กันอย่างไร แต่ไม่สามารถแยกประเภทได้

3) Reinforcement Learning คือ การเรียนรู้แบบสุ่ม หรือการเรียนรู้แบบลองผิดลองถูก โดยที่โมเดลจะเรียนรู้วิธีการแก้ปัญหาจากการดูและสังเกตสิ่งแวดล้อมรอบตัว

ซึ่ง Machine Learning ทั้ง 3 ประเภท ในแต่ละประเภทมีลักษณะและวัตถุประสงค์ที่แตกต่างกัน ดังนั้น จึงมีฟังก์ชันที่แตกต่างกันออกไป เช่น Linear Regression Clustering K-means เป็นต้น

2.4.1 การวิเคราะห์การถดถอยเชิงเส้น (Linear Regression)

การวิเคราะห์การถดถอยเชิงเส้น (Linear Regression) เป็นการหาความสัมพันธ์ระหว่างตัวแปรกับข้อมูล หรือเรียกว่าการหาค่าสหสัมพันธ์ (Correlation) โดยที่ความสัมพันธ์ของข้อมูลจะแสดงออกมาในรูปแบบของการเรียงกันเป็นเส้นตรงหรือใกล้เคียง หรือ Linear Regression เป็นการนำเอาข้อมูลมาพลอตกราฟเพื่อให้ได้ค่า x และ y ซึ่งค่าดังกล่าวก็คือเป็นส่วน Data และ Output เพื่อให้คอมพิวเตอร์หาสมการออกมา และสมการที่ได้จะถูกเก็บไว้ทำนายผลลัพธ์เมื่อมีข้อมูลใหม่เข้ามา ซึ่ง Linear Regression เป็น Machine Learning ที่จัดอยู่ในประเภท Supervise Learning ซึ่งจะกล่าวถึงประเภทของ Linear Regression 2 ประเภท ได้แก่ Simple Linear Regression และ Multiple Linear Regression ดังนี้

1) Simple Linear Regression

Simple Linear Regression คือ การวิเคราะห์การถดถอยเชิงเส้นอย่างง่ายใช้สำหรับการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอิสระ (Independent variable) 1 ตัวและตัวแปรตาม (Dependent variable) 1 ตัว มีสมการดัง 2.3

$$Y \approx \beta_0 + \beta_1 x \quad (2.5)$$


2) Multiple Linear Regression

Multiple Linear Regression คือ การวิเคราะห์การถดถอยเชิงเส้นแบบพหุคูณ ใช้สำหรับการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอิสระ (Independent variable) หลายตัวและตัวแปรตาม (Dependent variable) 1 ตัว มีสมการดัง 2.4


$$Y \approx \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_i x_i + \varepsilon \quad (2.6)$$

2.5 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (Deep learning) หมายถึง เทคนิคในการสร้างปัญญาประดิษฐ์โดยใช้โครงข่ายประสาทเทียมหรือข่ายงานประสาทเทียมหลาย ๆ ชั้นเหมือนแบบจำลองอันเรียบง่ายของระบบประสาทของมนุษย์ ซึ่งการเรียนรู้เชิงลึกเป็นส่วนย่อยของการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้ของเครื่องเป็นส่วนย่อยของปัญญาประดิษฐ์ (Artificial Intelligence) โดยในปัจจุบันมีการนำเทคนิคการเรียนรู้เชิงลึกมาประยุกต์ใช้หลายด้าน เช่น การพยากรณ์อากาศ การตรวจจับใบหน้าระบุเอกลักษณ์ การสแกนลายนิ้วมือ ระบบควบคุมความเร็วในรถยนต์ ระบบเตือนเมื่อรถออกนอกเลน การวินิจฉัยจากภาพถ่ายทางการแพทย์ เช่น ภาพเอ็กซเรย์ ภาพอัลตราซาวด์ เป็นต้น การเรียนรู้เชิงลึก (Deep learning) เปรียบเสมือนการจำลองกลไกการเรียนรู้ในสิ่งมีชีวิตทางชีววิทยา คือ ระบบประสาทของมนุษย์ ที่ประกอบด้วยเซลล์ที่เรียกว่าเซลล์ประสาทหรือนิวรอน (Neuron) นิวรอนเหล่านี้ถูกเชื่อมต่อกันด้วยแกนประสาท (Axon) และปลายประสาท (Dendrites) และพื้นที่เชื่อมต่อระหว่างแกนประสาทและปลายประสาทเรียกว่าซินแนปส์ (Synapse) ความแข็งแรงของการเชื่อมต่อซินแนปส์มักเปลี่ยนแปลงตามการกระตุ้นจากสิ่งต่าง ๆ ภายนอก การเปลี่ยนแปลงนี้ คือ วิธีที่การเรียนรู้เกิดขึ้นในสิ่งมีชีวิต โดยกลไกชีววิทยานี้ถูกจำลองในโครงข่ายประสาทเทียมที่ประกอบด้วยหน่วยคำนวณที่เรียกว่านิวรอน (Neuron) โดยที่หน่วยคำนวณเชื่อมต่อกันผ่านน้ำหนัก (Weight) น้ำหนักในโครงข่ายประสาทเทียมทำหน้าที่เช่นเดียวกับความแข็งแรงของการเชื่อมต่อซินแนปส์ โดยทุกรายการนำเข้า (Input) ไปยังนิวรอนถูกปรับขนาดด้วยน้ำหนักซึ่งมีผลต่อฟังก์ชันที่คำนวณที่หน่วยนั้น ๆ รูปที่ 2.10 แสดงโครงสร้างของนิวรอนในทางชีววิทยาและการเรียนรู้เชิงลึก



Biological neural network




Artificial neural network

รูปที่ 2.10 โครงสร้างของนิวรอนในทางชีววิทยาและการเรียนรู้เชิงลึก (ที่มา: Aggarwal, C. C. (2018). Neural Networks and Deep Learning: A Textbook. [3])

2.5.1 Artificial Neural Network (ANN)

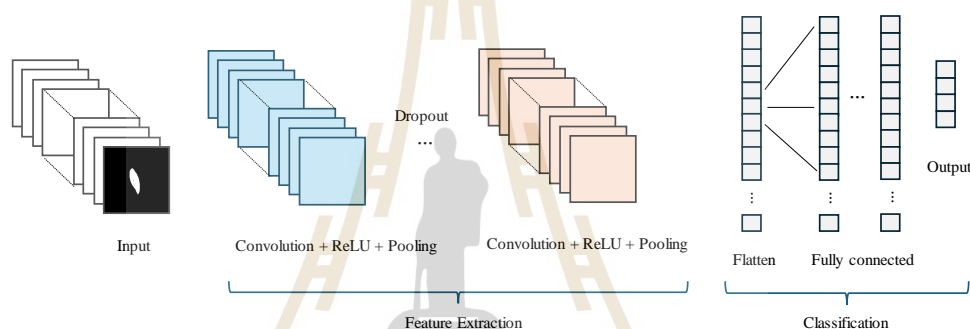
โครงข่ายประสาทเทียม (Artificial Neural Network : ANN) คือ โมเดลทางคณิตศาสตร์หรือโมเดลทางคอมพิวเตอร์สำหรับประมวลผล ซึ่งจากรูปที่ 2.9 Artificial neural network จะเห็นว่าแต่ละ Neuron ประกอบด้วย Input และ Output โดยจำลองให้ Input แต่ละอันมี Weight เป็นตัวกำหนดน้ำหนักของ Input วิธีการทำงานของ ANN คือ เมื่อมี input เข้ามายังโครงข่ายประสาทเทียม จะนำ Input มาทำการคูณกับค่า Weight ของแต่ละขา ผลที่ได้จาก Input ทุก ๆ ขาของ Neuron จะเอามารวมกันแล้วก็เอามาเทียบกับ Threshold ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า Threshold แล้ว Neuron ก็จะส่ง Output ออกไป Output นี้ก็จะถูกส่งไปยัง Input ของ Neuron อื่น ๆ ที่เชื่อมกันในโครงข่ายประสาทเทียม Network และถ้าค่าน้อยกว่า Threshold ก็จะไม่เกิด Output จากที่กล่าวมาข้างต้น การที่นำค่า Weight แต่ละตัวมาคูณกับ Input จะทำให้เกิดชั้นที่เรียกว่า Hidden Layer ซึ่งที่การที่มี Hidden Layer มากกว่า 2 ชั้น จะเรียกว่า Deep Learning รูปที่ 2.11 แสดงโครงสร้างของ Deep Learning



รูปที่ 2.11 โครงสร้างของเทคนิค Deep Learning

2.5.2 Convolutional Neural Network (CNN)

โครงข่ายประสาทเทียมคอนโวลูชัน (CNN) เป็นโครงข่ายประสาทเทียมที่ได้รับความนิยมในการใช้ Input เป็นรูปภาพ ซึ่งจะให้ความแม่นยำสูง โดยโครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน แสดงดังในรูปที่ 2.12 โครงข่ายประสาทเทียมแบบคอนโวลูชันมักจะถูกนำมาใช้ในการประมวลผลภาพ เช่น การจำแนกรูปภาพ (Image Classification) และการตรวจจับวัตถุ (Object detection) โดยในการประมวลผลภาพสำหรับ CNN โมเดลจะทำการสกัดคุณลักษณะที่โดดเด่นของรูปภาพออกมา หรือที่เรียกว่า Feature Extraction จึงทำให้โมเดล CNN สามารถแยกของสองสิ่งออกจากกันได้ โดยจะนำ CNN ไปใช้เพื่อการจำแนกรูปภาพหรือรู้จำรูปแบบภาพต่าง ๆ ได้แก่ ใบหน้าคน (Faces) ภาววัตถุ (Objects) ฉากหลัง (Scenes) จำแนกวิดีโอ ข้อความ และเสียง เป็นต้น



รูปที่ 2.12 โครงสร้างของโครงข่ายประสาทเทียมคอนโวลูชัน

จากโครงสร้างของ CNN ในรูปที่ 2.12 ประกอบไปด้วยโครงสร้างชั้นนำเข้า (Input Layer) ทำการรับข้อมูล จากนั้นจะผ่านไปสู่อันดับที่ 2 เป็นชั้น Convolution ที่ 1 (C1) โดยเป็นการทำ Feature Map หรือ Feature Extraction และผ่านชั้นที่ 2 เรียกว่า Subsampling ที่ 1 (S2) คือ การย่อขนาดซึ่งอาจจะมีหลายวิธีการ เช่น Max Pooling และ Average Pooling และจากนั้นผ่านเข้าสู่ชั้น Convolution และ Subsampling ที่อยู่ถัดมา ซึ่งจำนวนชั้นของ Convolution และ Subsampling ขึ้นอยู่กับจำนวน Input Layer และปัจจัยอื่น ๆ จากนั้นผ่านเข้าสู่ชั้น Fully Connected Layer (Dense) โดยที่ชั้นนี้จะรับข้อมูลมาจาก Convolution และ Subsampling ชั้นก่อนหน้าและจะเชื่อมต่อกับทุก Neuron ในชั้นถัดไป จากนั้นเข้าสู่ชั้นส่งออก (Output Layer) ซึ่งจะต้องมีจำนวน Neuron หรือจำนวน Output ตามจำนวนคลาสที่ต้องการจำแนก ดังนั้น การทำงานของ CNN นี้เริ่มจากการสกัดคุณลักษณะผ่านชั้น Convolution และ Subsampling ต่อเนื่องกัน และนำคุณลักษณะที่ได้มาทำการประมวลผลในชั้นเชื่อมต่อเต็มเพื่อสร้างความสัมพันธ์ที่ซับซ้อน

มากขึ้น และสุดท้ายใช้ชั้นส่งออกเพื่อทำการจำแนกข้อมูลแบ่งออกเป็นคลาสต่าง ๆ ตามจำนวน Output ที่ต้องการ

การออกแบบ Convolutional Neural Networks (CNN) เป็นกระบวนการที่ครอบคลุมหลายขั้นตอน โดยมีจุดประสงค์เพื่อให้โมเดลสามารถเรียนรู้คุณลักษณะจากรูปภาพได้ดี ซึ่งโครงข่ายประสาทแบบคอนโวลูชัน (CNN) มีส่วนประกอบที่สำคัญ ดังนี้

1) Fully connected layer

Fully connected layers หรือ Dense layers คือ โครงข่ายประสาทเทียมในโมเดลการเรียนรู้เชิงลึก โดยทุกนิวรอน (Neuron) หรือ Node ใน Layers นั้นจะมีการเชื่อมต่อกับทุก ๆ Neuron ในชั้นก่อนหน้าและชั้นถัดไป โดยที่น้ำหนัก (Weight) จะถูกปรับให้เรียนรู้โดยอัลกอริทึมการเรียนรู้เชิงลึก

2) Activation function

ฟังก์ชันการกระตุ้น (Activation function) คือ ฟังก์ชันที่แปลงผลลัพธ์จากการคำนวณผลรวมของน้ำหนัก (Weight) ที่เชื่อมกันแต่ละ Neuron ของ Fully Connected Layers ให้เป็นรูปแบบที่ไม่เชิงเส้น (Nonlinear) เพื่อให้โมเดลมีความสามารถในการเรียนรู้ความซับซ้อนได้ ซึ่งการเลือกใช้ Activation function ขึ้นอยู่กับลักษณะของงานและความเหมาะสมในการแก้ปัญหา นั้น ๆ ซึ่ง Activation function ที่ใช้งานบ่อย เช่น ReLU (Rectified Linear Unit) และ SoftMax function เป็นต้น โดยฟังก์ชันการกระตุ้นแต่ละตัว จะมีลักษณะการใช้งานที่แตกต่างกันตาม Output ที่ต้องการ เช่น ReLU (Rectified Linear Unit) คือ ฟังก์ชันเส้นตรงที่ถูกปรับแก้ (Rectified) มักใช้เป็นฟังก์ชัน Activation ใน Hidden layers เพื่อเปลี่ยนแปลง Output จาก Neurons ก่อนที่จะส่งต่อไปยัง Layer ถัดไปคุณสมบัติที่โดดเด่นของ ReLU คือ ความง่ายในการคำนวณ หรือ SoftMax function เป็นฟังก์ชัน Activation สำหรับการจำแนกประเภท (Classification) ในปัญหาที่มีหลายคลาส (Multiclass Classification) มักถูกใช้ใน Output Layer โดยจะคำนวณความน่าจะเป็นของแต่ละคลาสออกมาเป็นผลลัพธ์ โดยค่า output จะเป็นชุดของค่าความน่าจะเป็นที่มีผลรวมเท่ากับหนึ่ง

ReLU (Rectified Linear Unit) คือ ฟังก์ชันเส้นตรงที่ถูกปรับแก้ (Rectified) มักใช้เป็นฟังก์ชัน Activation ใน Hidden layers เพื่อเปลี่ยนแปลง Output จาก Neurons ก่อนที่จะส่งต่อไปยัง Layer ถัดไปคุณสมบัติที่โดดเด่นของ ReLU คือ ความง่ายในการคำนวณและช่วยในการแก้ปัญหา Vanishing Gradient ซึ่ง ReLU ทำงานโดยที่ถ้า Input เป็นค่าบวกหรือเท่ากับศูนย์ จะคืนค่ามันเอง แต่ถ้า Input เป็นค่าลบ จะทำการคืนค่าเป็นศูนย์ สามารถเขียนแสดงเป็นสมการได้ดังสมการที่ 2.7 - 2.8 ดังนี้


$$f(x) = \max(0, x) \quad (2.7)$$

$$\text{ReLU}(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (2.8)$$

SoftMax function เป็นฟังก์ชันการกระตุ้น สำหรับการจำแนกคลาสหรือประเภท (Classification) ในปัญหาที่มีหลายคลาส (Multiclass Classification) มักถูกใช้ใน Output Layer โดยจะคำนวณความน่าจะเป็นของแต่ละคลาสออกมาเป็นผลลัพธ์ โดยค่า Output จะเป็นชุดของความน่าจะเป็นที่มีผลรวมเท่ากับ 1 สามารถเขียนสมการได้ดังสมการที่ 2.9

$$\sigma(x_j) = \frac{e^{x_j}}{\sum_i e^{x_j}} \quad (2.9)$$

จากฟังก์ชันการกระตุ้น ReLU และ SoftMax สามารถแสดง Output ของฟังก์ชัน ได้ดังรูปที่ 2.3 แสดงฟังก์ชันการกระตุ้นของ ReLU และ SoftMax



รูปที่ 2.13 ฟังก์ชันการกระตุ้น (Activation Function) (ที่มา: ElGendy, M. (2020). Deep Learning for Vision Systems [4])

3) Hyperparameter

ไฮเปอร์พารามิเตอร์ (Hyperparameter) คือ พารามิเตอร์ที่กำหนดค่าล่วงหน้า ก่อนที่กระบวนการเรียนรู้ของโมเดลจะเริ่มต้นทำการฝึกฝนและเรียนรู้ ซึ่งจะใช้กับโมเดลการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ทำหน้าที่เป็นค่าควบคุมในการฝึกอบรมและการออกแบบโมเดล โดยการตั้งค่าอย่างถูกต้องสามารถช่วยให้โมเดลเรียนรู้ได้ดีขึ้น และมีความสามารถในการทำนายที่แม่นยำ ซึ่งมีค่าต่าง ๆ เช่น Learning Rate, Batch Size และ Number of Epochs เป็นต้น ซึ่งค่าดังกล่าวมานี้จะทำการอัปเดตน้ำหนัก (Update weight) และ ไบอัส (Bias) ของโมเดลในแต่ละขั้นตอนของการฝึก ดังแสดงในรูปที่ 2.14 โดยสามารถปรับค่าขึ้นหรือ

ลงได้ เมื่อต้องการปรับความแม่นยำของโมเดลให้สูงขึ้น แต่การปรับค่าไฮเปอร์พารามิเตอร์เหล่านี้ ส่งผลกระทบต่อความเร็วในการประมวลผลของคอมพิวเตอร์ ซึ่งอาจทำให้ใช้เวลาในการฝึกฝนโมเดล นานเกินไปได้

Learning Rate

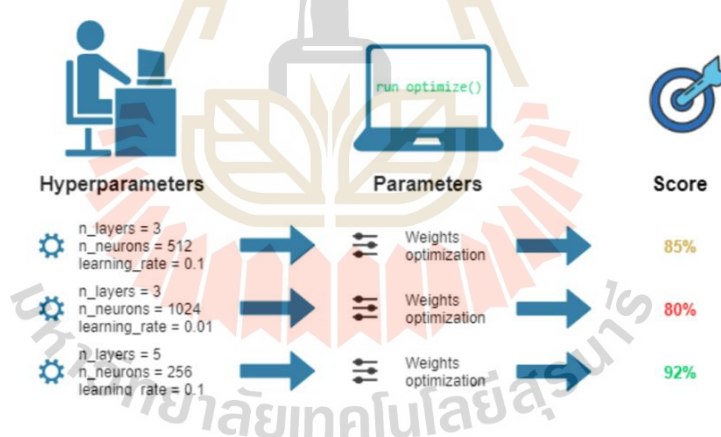
อัตราการเรียนรู้ (Learning Rate) คือ ค่าที่ใช้ในการปรับระดับความเร็วการเรียนรู้ของ Neural Network หากมีค่าสูงโมเดลจะเรียนรู้ได้เร็ว และถ้าหากมีค่าต่ำการเรียนรู้ก็จะช้า ซึ่งค่า Learning Rate ที่มักนิยมใช้เป็นค่าเริ่มต้น คือ 0.001

Batch Size

Batch Size คือ การแบ่งออกเป็นแบตช์เล็ก ๆ (Batch) เมื่อมีการใช้ข้อมูลในการฝึกฝนเป็นจำนวนมาก ซึ่งจำนวนข้อมูลในแต่ละ Batch จะเป็นตัวอย่างที่ผ่านเข้าไปในโมเดลก่อนที่ Optimizer จะทำการคำนวณค่า Gradient และปรับค่าพารามิเตอร์ของโมเดล

Number of Epochs


Number of Epochs หรือ Epochs คือ จำนวนรอบของการฝึกฝนโมเดล โดยรอบของการฝึกฝน (Epoch) จะทำให้ Loss ลดลง และ Accuracy เพิ่มขึ้น



รูปที่ 2.14 การปรับ Hyperparameter สำหรับ Artificial Neural Networks (ANN) (ที่มา: <https://bdi.or.th/big-data-101/machine-learning-model-hyperparameter-optimization/>)

4) Loss function

Loss function คือ ฟังก์ชันที่รับ Input เข้ามาและแสดง Output ออกมาเป็นตัวเลข 1 ตัว ถ้าหาก Loss function มีค่าน้อยหรือเข้าใกล้ศูนย์ แสดงว่าสิ่งที่โมเดลทำนายใกล้เคียงหรือคล้ายกับค่าจริง (Labels) รูปที่ 2.15 แสดงความสัมพันธ์ของ Loss function จะแสดง Training loss และ Validation Loss



รูปที่ 2.15 ความสัมพันธ์ระหว่าง Training loss และ Validation loss

จากภาพที่ 2.15 เป็นการ Training model เมื่อมีการเพิ่มหรือการ Update weight (Iteration) Training loss และ Validation loss จะลดลง ตัวอย่างของ Loss function ที่นิยมนำมาใช้แก้ปัญหา มีอยู่หลายวิธี ยกตัวอย่างดังนี้

Mean Squared Error (MSE)

Mean Squared Error (MSE) เป็น Loss function ที่มักจะใช้ในการแก้ปัญหา Regression ที่ต้องการให้ผลลัพธ์เป็นค่าจริง เช่น การประเมินราคาบ้านหรือที่ดิน เป็นต้น ซึ่งผลลัพธ์ที่เป็นค่าจริง คือ ผลลัพธ์ที่เป็นตัวเลขต่อเนื่อง ไม่ใช่การนำมาเปรียบเทียบหมวดหมู่หรือคลาส โดย MSE จะถูกยกกำลังสองและเฉลี่ยจากจำนวนข้อมูลจุด แสดงดังสมการ 2.10

$$E(W, b) = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (2.10)$$

Mean Absolute Error (MAE)

Mean Absolute Error (MAE) มีลักษณะเหมือนกับ Mean Squared Error (MSE) แต่สำหรับ MAE จะใช้เฉลี่ยค่าความผิดพลาดแบบสัมบูรณ์ (ค่าที่ไม่สนใจเครื่องหมายบวกหรือลบ) ระหว่างค่าทำนายและค่าจริง แสดงดังสมการที่ 2.11


$$E(W, b) = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (2.11)$$

Cross-Entropy Loss

Cross-Entropy เป็น Loss function ที่ใช้สำหรับปัญหา Classification โดยปัญหา Binary Classification จะใช้ Binary Cross-Entropy และสำหรับปัญหา Multiclass Classification จะใช้ Categorical Cross-Entropy โดยที่ทำการวัดความแตกต่างระหว่างการแจกแจงความน่าจะเป็นของคลาสที่ทำนายกับค่าจริง โดยเขียนเป็นสมการความสัมพันธ์ได้ แสดงดังสมการที่ 2.12

$$E(W, b) = \sum_{i=1}^n \sum_{j=1}^m \hat{y}_{ij} \log(p_{ij}) \quad (2.12)$$

การเลือก Loss Function ที่เหมาะสมเป็นปัจจัยสำคัญในการฝึกฝนโมเดล Machine Learning หรือ Deep Learning เนื่องจาก Loss Function ทำหน้าที่เป็นตัววัดความผิดพลาดระหว่างการทำนายของโมเดลกับค่าจริง หากเลือก Loss Function ที่ไม่เหมาะสม อาจทำให้โมเดลเกิดปัญหา Overfitting หรือ Underfitting ได้ แสดงดังในรูปที่ 2.16 โดย Overfitting เกิดขึ้นเมื่อโมเดลเรียนรู้รายละเอียดและ Noise ในข้อมูลฝึกมากเกินไป จนไม่สามารถทำนายได้เมื่อเจอข้อมูลใหม่ เปรียบเสมือนเป็นการจดจำข้อมูลแทนที่จะเป็นการเรียนรู้ ส่วน Underfitting เกิดขึ้นเมื่อโมเดลไม่สามารถเรียนรู้รูปแบบพื้นฐานจากข้อมูลฝึกได้เพียงพอ ทำให้ผลการทำนายไม่แม่นยำทั้งกับข้อมูลฝึกและข้อมูลใหม่ ดังนั้น การเลือก Loss Function ควรพิจารณาจากลักษณะของข้อมูลและประเภทของปัญหาที่ต้องการแก้ไข รวมถึงการใช้เทคนิค Regularization เพื่อป้องกัน Overfitting และทำให้โมเดลทำงานได้ดีบนข้อมูลที่ไม่เคยเห็นมาก่อน



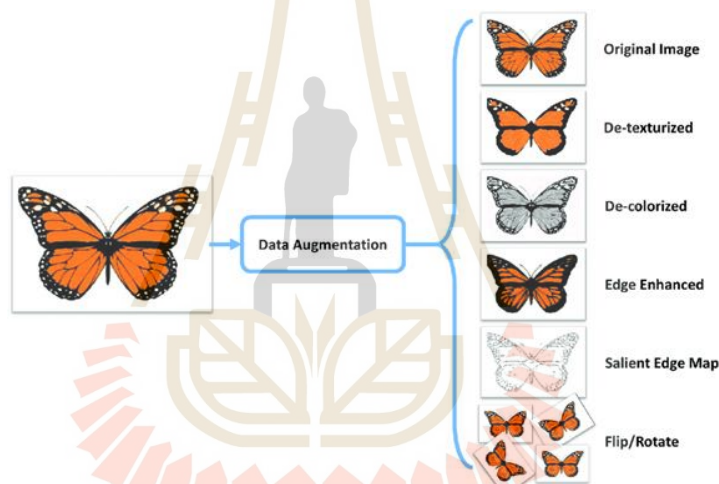
รูปที่ 2.16 การเปรียบเทียบการเกิดปัญหา Underfitting และ Overfitting Underfitting (ซ้าย) Just right (กลาง) และ Overfitting (ขวา) (ที่มา: ElGendy, M. (2020). Deep Learning for Vision Systems [4])

5) Overfitting

Overfitting เกิดขึ้นเมื่อโมเดล Deep Learning ทำการเรียนรู้ข้อมูลฝึกอบรม (Training data) ได้ดีเกินไป ทำให้เปลี่ยนจากการเรียนรู้เป็นการจดจำคำตอบ ส่งผลให้โมเดลมีประสิทธิภาพที่สูงมากเมื่อทดสอบโมเดลกับ Training data และจะประสิทธิภาพต่ำ เมื่อใช้กับข้อมูลใหม่ หรือข้อมูลชุดทดสอบ (Test data) ซึ่งการแก้ปัญหา Overfitting มีวิธีการ ดังนี้

5.1) การเพิ่มจำนวนข้อมูล (Data Augmentation)

Data Augmentation คือ การเพิ่มจำนวนข้อมูล แสดงดังในรูปที่ 2.17 โดยนำข้อมูลที่มีอยู่แล้วมา Recycle หรือกลับมาใช้ซ้ำ ซึ่งเป็นที่นิยมสำหรับรูปภาพ โดยวิธีการ ได้แก่ ย่อ ขยาย หมุนซ้าย หมุนขวา Flip ซ้าย ขวา บน ล่าง ตัดมุมภาพ ปรับสีเข้ม ปรับสีอ่อน ปรับแสงมืด-สว่าง ปรับ Contrast ปรับ Perspective เบลอภาพ เป็นต้น




รูปที่ 2.17 การเพิ่มจำนวนข้อมูล (Data Augmentation) (ที่มา: ElGendy, M. (2020). Deep Learning for Vision Systems [4])

5.2) Regularization

Regularization เป็นวิธีที่มีประสิทธิภาพ ในการปรับปรุงความสามารถของโมเดลในการทำนายข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่ง Regularization ทำงานโดยการเพิ่ม Penalty term เข้าไปใน Loss function ซึ่งคำนวณจากน้ำหนัก (Weight) ของโมเดล โดยการลดค่าของน้ำหนัก (Weight) ลง โมเดลจะถูกบังคับให้เรียนรู้ข้อมูลในรูปแบบที่เรียบง่ายกว่า ทำให้ Generalize ได้ดีขึ้นเมื่อใช้กับข้อมูลใหม่ ซึ่งมี 2 ฟังก์ชันในการเลือกใช้ คือ L1 Regularization (Lasso Regression) และ L2 Regularization (Ridge Regression)

5.3) Dropout

Dropout คือ การสุ่มปิดใช้งาน Neurons บางตัว หรือเรียกว่าการ Deactivate แสดงดังในรูปที่ 2.18 ซึ่งหมายความว่าในแต่ละรอบการ Training หรือแต่ละ Iteration จะมี Neurons ที่ไม่ได้ถูก Update weight หรือ Bias โดยโมเดลจะถูกฝึก (Training) ให้สามารถทำงานได้ดีแม้ว่าจะมีการปิดการใช้งานบางส่วนของโมเดล ส่งผลให้โมเดลมีความสามารถในการทำนาย (Generalize) ได้ดีขึ้นเมื่อใช้กับข้อมูลนอกเหนือจากข้อมูลฝึกอบรม (Training data)



รูปที่ 2.18 การสุ่มปิดใช้งาน Neurons (Dropout) (ที่มา: ElGendy, M. (2020). Deep Learning for Vision Systems [4])

5.4) Early Stop

Early stop คือ การหยุดการฝึกเมื่อ Performance บนข้อมูล Validation ไม่ปรับปรุงเพิ่มเติมเพื่อป้องกันการ Overfitting โดยสามารถดู Performance จากกราฟ Loss สำหรับ Training และ Validation หากค่า Loss ของชุดข้อมูล validation หยดลดลงหรือเริ่มเพิ่มขึ้นเมื่อเทียบกับค่า Loss ของชุดข้อมูลฝึกอบรมที่ยังคงลดลงหรือคงที่ ซึ่งอาจเป็นสัญญาณของการ overfitting และเป็นจุดที่เหมาะสมในการใช้ Early Stopping โดยตรวจสอบได้จากค่า Performance ของ Model Assessment ได้แก่ กราฟ Accuracy และ F1-Score เป็นต้น

6) Underfitting

Underfitting เกิดขึ้นเมื่อโมเดลไม่สามารถจับคู่ หรือเรียนรู้ความซับซ้อนในชุดข้อมูลฝึกอบรมได้เพียงพอ ซึ่งอาจเกิดจากโมเดลที่มีความซับซ้อนน้อยเกินไปสำหรับปัญหาที่กำลังแก้ไข หรือไม่มีการฝึกอบรมที่เพียงพอ ผลลัพธ์ คือ โมเดลจะแสดงประสิทธิภาพที่ไม่ดีทั้งบนข้อมูลฝึกอบรม (Training data) และข้อมูลทดสอบ (Test data) โดยวิธีการแก้ปัญหา Underfitting คือ เพิ่มความซับซ้อนของโมเดล การปรับปรุงคุณภาพของข้อมูล การปรับพารามิเตอร์ในการ Training เช่น อัตราการเรียนรู้ (Learning rate) จำนวนรอบการเรียนรู้ (Epoch) และลดการใช้ Regularization เป็นต้น

2.6 การประเมินผล (Model Assessment)

การประเมินผลสำหรับวิธีการ Image Classification และ Object Detection จะใช้เมตริกการประเมินผล (Evaluation Matrix) เป็นเครื่องมือในการวัดและเปรียบเทียบประสิทธิภาพของโมเดล หรือใช้สำหรับการวิเคราะห์ข้อมูล การเลือก Evaluation Matrix ต้องเลือกให้เหมาะสมกับโมเดล ซึ่งมีหลายวิธีการ ดังนี้

2.6.1 Confusion Matrix

เมตริกซ์ความสับสน (Confusion Matrix) เป็นเมตริกสำหรับการวัดประสิทธิภาพของโมเดล Image Classification ซึ่งแสดงการทำนายที่ถูกต้องและไม่ถูกต้องในทุกคลาส โดย Confusion Matrix ประกอบไปด้วย 4 ส่วน แสดงดังในรูปที่ 2.19 ได้แก่ True Positives (TP), True Negative (TN), False Positive (FP) และ False Negative (FN)

N		Predicted	
		No	Yes
Actual	No	True Negative (TN)	False Positive (FP)
	Yes	False Negative (FN)	True Positive (TP)

รูปที่ 2.19 เมตริกซ์ความสับสน (Confusion Matrix) (ที่มา: ElGendy, M. (2020). Deep Learning for Vision Systems [4])

- 1) True Positives (TP) คือ สิ่งที่ไม่เดลทำนาย ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีที่ทำนายว่า จริง และสิ่งที่เกิดขึ้นก็คือ จริง
- 2) True Negatives (TN) คือ สิ่งที่ไม่เดลทำนาย ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีที่ทำนายว่า ไม่จริง และสิ่งที่เกิดขึ้นก็คือ ไม่จริง
- 3) False Positives (FP) คือ สิ่งที่ไม่เดลทำนาย ไม่ตรงกับสิ่งที่เกิดขึ้น ในกรณีที่ทำนายว่า จริง และสิ่งที่เกิดขึ้นก็คือ ไม่จริง
- 4) False Negatives (FN) คือ สิ่งที่ไม่เดลทำนาย ไม่ตรงกับสิ่งที่เกิดขึ้น ในกรณีที่ทำนายว่า ไม่จริง และสิ่งที่เกิดขึ้นก็คือ จริง

2.6.2 Precision

Precision คือ อัตราส่วนของการทำนายที่ถูกต้องต่อการทำนายทั้งหมดที่เป็นบวก (True Positive และ False Positive) สามารถคำนวณได้ดังสมการ 2.13

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2.13)$$

2.6.3 Recall

Recall คือ อัตราส่วนของการทำนายที่ถูกต้องต่อการทำนายทั้งหมด (True Positive และ False Negative) สามารถคำนวณได้ดังสมการ 2.14

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2.14)$$

2.6.4 F1-score

F1-score เป็นเมตริกอีกประเภทหนึ่งที่ใช้ในการประเมินคุณภาพของโมเดล Image Classification ซึ่ง F1-score สามารถใช้เมื่อข้อมูลมีความไม่สมดุลระหว่างคลาส หรือเมื่อมีค่า Precision และค่า Recall เท่ากัน สามารถคำนวณได้ดังสมการ 2.15

$$\text{F1-score} = 2 \times \left(\frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \quad (2.15)$$

2.6.5 Accuracy

Accuracy คือ ค่าความแม่นยำจากการทำนายของโมเดล สามารถคำนวณได้ดังสมการ 2.16

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (2.16)$$

2.7 ปรัชน์วรรณกรรม และงานวิจัยที่เกี่ยวข้อง

Shah K. A. และคณะ (2010) ได้วิจารณ์และรวบรวมข้อมูลที่เกี่ยวข้องกับงานวิจัยเกี่ยวกับต้นมะม่วงและ สรรพคุณต่างที่ได้จากส่วนต่าง ๆ ของมะม่วง โดยมะม่วง (ชื่อวิทยาศาสตร์ : *Mangifera Indica*) เป็นสมุนไพรทางการแพทย์อายุรเวชและระบบการแพทย์พื้นบ้านมาเป็นเวลากว่า 4000 ปี

ซึ่งสรรพคุณของมะม่วง คือ มีสารต้านอนุมูลอิสระ จึงมีคุณสมบัติที่ช่วยในการต้านเบาหวาน บำรุงหัวใจ และลดความดันโลหิต เป็นต้น ส่วน ราก เปลือก ใบ และเมล็ดแก่น ที่นำไปสกัดเพื่อรักษาโรค เช่น อาการท้องเสีย และโรคเบาหวาน [1] Sitah F. Alanazi (2023) ทำการทดลองฉายรังสีเอกซ์ในการควบคุมเชื้อแบคทีเรียในอาหาร 1 ชนิด ทั้งของแข็ง ของเหลว ที่ติดเชื้อแบคทีเรียทดลอง โดยมีการใช้ระดับพลังงานที่แตกต่างกันในการฉายรังสีเอกซ์ทั้งหมด 3 ครั้ง เพื่อหาปริมาณรังสีที่เหมาะสมที่สามารถกำจัดเชื้อแบคทีเรียได้โดยไม่ทำลายคุณภาพของอาหาร ผลการทดลองพบว่ารังสีเอกซ์มีประสิทธิภาพในการลดจำนวนเชื้อแบคทีเรียในอาหารโดยทั่วไป โดยไม่มีผลกระทบต่อสารอาหารในอาหาร เช่น น้ำตาล โปรตีน ไขมัน และวิตามินซี การฉายรังสีที่ปริมาณ 1.5 และ 2.0 กิโลกรัมเรย์ต่อวินาที สามารถยับยั้งการเจริญของเชื้อแบคทีเรียได้ทั้งหมดในอาหารที่ทดลอง [2] Yeong-Seok Yoon และคณะ (2020) ได้ประเมินคุณภาพของสตรอว์เบอร์รีเกาหลี สายพันธุ์ Maehyang หลังการฉายรังสีเอกซ์ โดยใช้ปริมาณรังสีตั้งแต่ 0-1 กิโลเกรย์ ซึ่งผลการทดสอบพบว่าปริมาณที่น้อยกว่า 1 กิโลเกรย์ ส่งผลให้มีการลดจำนวนจุลินทรีย์ แบคทีเรีย และเชื้อรา โดยลดลงตามปริมาณรังสีที่ใช้และตลอดระยะเวลาเก็บรักษา เพิ่มปริมาณสารประกอบฟีนอลิกและสารต้านอนุมูลอิสระตามระยะเวลา และหลังการฉายรังสีสตรอว์เบอร์รีมีน้ำหนักลดลง ความแน่นลดลง แต่จะมีน้ำหนักและความหนาแน่นคงที่หลังจากสามวัน มีการชะลอการเปลี่ยนแปลงสีที่ไม่พึงประสงค์ ช่วยยืดอายุการเก็บรักษาได้ ดังนั้น การฉายรังสีเอกซ์ให้กับสตรอว์เบอร์รีหรือผลไม้ เป็นวิธีการที่มีประสิทธิภาพในการเก็บรักษา เพื่อชะลอการเน่าและการเปลี่ยนแปลงทางกายภาพเคมีที่เป็นลบ การศึกษานี้ยืนยันความเป็นไปได้ของการใช้การฉายรังสีเอกซ์เป็นทางเลือกในการเก็บรักษาตามหลักคุณลักษณะสำหรับการค้าสตรอว์เบอร์รีสดหรือผลไม้ระหว่างประเทศ [3] จากการเทคโนโลยีการฉายรังสีอาหาร มะม่วงน้ำดอกไม้เป็นหนึ่งในผลไม้ที่ถูกฉายรังสีเพื่อการส่งออกด้วย ในการส่งออกของมะม่วงในปัจจุบัน จึงทำให้ในอุตสาหกรรมได้มีการนำเทคโนโลยีต่าง ๆ เข้ามาประยุกต์ใช้ โดย Katrin Utaia และคณะ (2014) ได้เสนอวิธีการหามวลหรือน้ำหนักของมะม่วงน้ำดอกไม้ เพื่อคัดแยกและจัดเกรดขนาดของมะม่วงด้วยน้ำหนัก โดยใช้เทคนิคการประมวลผลภาพ (Image Processing) และโครงข่ายประสาทเทียม (ANN) โดยมีการติดตั้งกล้องทั้งด้านบนและด้านข้างสำหรับถ่ายภาพ เพื่อให้ได้ขนาดในด้านกว้าง ยาว และสูงของมะม่วงน้ำดอกไม้ ซึ่งมีการทดสอบทั้งหมด 7 วิธี โดยใช้ชุดข้อมูลอินพุตที่แตกต่างกัน ซึ่งพบว่าวิธีการที่ 4 ที่มีอินพุต 2 ค่า ได้แก่ พื้นที่ และความสูง ที่ถูกสกัดคุณลักษณะที่สำคัญออกมาด้วยภาพพื้นที่ของมะม่วงที่ถูกแปลงด้วย Binary Algorithm มีค่าความแม่นยำสูงสุดที่ 96.72% [4] ซึ่งนอกจากโครงข่ายประสาทเทียมหรือการเรียนรู้เชิงลึกแล้ว ยังมีการนำเสนอวิธีการวัดขนาดวัตถุด้วยวิธีการใหม่ ได้แก่ S.Anjanayya และคณะ (2023) นำเสนอวิธีการวัดขนาดวัตถุโดยใช้คอมพิวเตอร์วิชั่น (OpenCV) ซึ่งใช้วิธีการอ้างอิงจากวัตถุที่รู้ขนาดเพื่อให้ได้การประมาณที่แม่นยำ โดยมีกระบวนการก่อนการประมวลผลภาพที่ใช้ Gray-scale Thresholding Gaussian Filtering เพื่อลดสัญญาณรบกวนของรูปภาพ และใช้วิเคราะห์รูปภาพด้วยการตรวจจับ

ขอบ Canny Edge Detection ก่อนเข้าสู่กระบวนการทางเรขาคณิตร่วมกับพารามิเตอร์กล้องในเพื่อกำหนดขอบเขตและใช้ OpenCV เป็นฟังก์ชันในการจัดการภาพวัตถุซึ่งจะได้ขนาดวัตถุออกมา คือ ความกว้าง และความยาว ซึ่งผลลัพธ์การทดสอบโดยใช้รูปภาพแบบเรียลไทม์มีค่าความแม่นยำของโมเดลอยู่ที่ 97% ซึ่งผลลัพธ์ที่ได้อาจจะแตกต่างกันออกไปตามอินพุต [5] นอกจากนี้ Preeti Topno และคณะ (2019) ได้นำเสนอการลดสัญญาณรบกวนของรูปภาพจากการตรวจจับขอบ (Edge Detection) โดยนำรูปภาพอินพุตไปทำการตรวจจับขอบ 4 วิธีการ ได้แก่ Roberts, Sobel, Prewitt และ Canny จากนั้นลดสัญญาณรบกวนของรูปภาพด้วยวิธีการ Median filter (การกรองด้วยค่ามัธยฐาน) พบว่าวิธีการ Canny ได้ผลดีที่สุด เส้นขอบมีความชัดเจน และ Noise ลดลง โดยที่ไม่สูญเสียรายละเอียดสำคัญของภาพ ซึ่งวัดจากค่า PSNR (Peak Signal to Noise Ratio) ที่มีค่าเพิ่มขึ้น จึงบ่งบอกถึงความใกล้เคียงกับภาพต้นฉบับมากขึ้น [6] จะเห็นว่าเทคนิคการตรวจจับขอบหรือ Edge Detection เมื่อนำมาปรับใช้กับเทคโนโลยีปัญญาประดิษฐ์และคอมพิวเตอร์วิชั่นแล้วยังมีการนำอุปกรณ์ภายนอกเข้ามาใช้ร่วมด้วย โดย Sahil Khadane และคณะ (2022) ได้มีการใช้เทคนิคการตรวจจับขอบ (Edge Detection) ร่วมกับคอมพิวเตอร์วิชั่น (OpenCV) เพื่อตรวจจับและระบุขนาดวัตถุที่อยู่ในภาพ โดยใช้ Raspberry Pi และ Pi Camera เพื่อจับภาพวัตถุและประมวลผล ซึ่งผลค่าความแม่นยำของระบบในการวัดขนาดอยู่ที่ประมาณ 94% ซึ่งการทดลองนี้สามารถเป็นต้นแบบพัฒนาการทำงานของระบบ IoT และการตรวจจับวัตถุอัตโนมัติที่ต้องการความแม่นยำสูงในอุตสาหกรรมได้ [7] Nguyen Duc Thong และคณะ (2019) ได้นำเสนอระบบการคัดเกรดมะม่วงอัตโนมัติที่ใช้วิธีการประมวลผลภาพ (Image Processing) และโครงข่ายประสาทเทียม (ANN) ซึ่งใช้กล้อง CCD cameras จำนวน 2 ตัวในการติดตั้งบนและด้านข้าง เพื่อทำการถ่ายภาพ ในการคำนวณหาขนาด และคัดแยกมะม่วงด้วยสี และตำหนักที่เปลือกมะม่วง จากนั้นชั่งน้ำหนักจาก Loadcell ที่ได้มีการติดตั้งเข้ากับชุดสายพาน ถ้าหากตรวจพบตำหนักที่เปลือกมะม่วงจะทำการคัดออกทันที และข้อมูลที่ได้จากการชั่งน้ำหนักด้วย Load cell และถ่ายภาพ ได้แก่ ขนาด (กว้าง ยาว และสูง) จะถูกนำมาแทนเป็นโมเดลการถดถอยเชิงเส้นหรือ Linear Regression เพื่อได้ชุดสมการในการทำนายหาน้ำหนักมะม่วง ซึ่งผลการทดสอบระบบนี้สามารถจำแนกมะม่วงได้อย่างมีประสิทธิภาพด้วยความแม่นยำสูง และช่วยลดการใช้แรงงานในการจำแนกประเภทด้วยมือ [8] Thanh-Nghi Doan และคณะ (2023) ได้นำเสนอระบบการคัดเกรดมะม่วงอัตโนมัติที่ใช้วิธีการประมวลผลภาพ (Image Processing) และการเรียนรู้ของเครื่อง (Machine Learning) เช่นเดียวกัน เพื่อลดความต้องการใช้แรงงานและส่งเสริมการผลิตที่มีประสิทธิภาพ โดยแบ่งมะม่วงออกเป็น 3 เกรด เกรดที่ 1 มีคุณภาพดี ไม่มีรอยตำหนิหรือตำหนักและมีน้ำหนักมากกว่า 620 กรัม เกรดที่ 2 เกรดปานกลางมีหนักอยู่ระหว่าง 500-620 กรัม และเกรดที่ 3 มีรอยตำหนิ ผิวไม่สวยและมีน้ำหนักน้อยกว่า 500 กรัม ซึ่งจากการทดสอบมีค่าความแม่นยำโดยรวมอยู่ที่ 88% [9] และในประเทศอินเดียถือเป็นถิ่นกำเนิดของมะม่วงที่สำคัญ Sourav Bagchi และคณะ (2023) จึงได้เสนอการใช้เทคนิคการเรียนรู้ของเครื่อง (Machine


Learning) ในการจำแนกและตรวจสอบคุณภาพของมะม่วงอินเดียอต์โนมัต ซึ่งประกอบไปด้วยวิธีการประมวลผลภาพ (Image Processing) และคอมพิวเตอร์วิชั่น ใช้โดยวิเคราะห์ภาพด้วยเทคนิค Local Binary Pattern (LBP) จากนั้น Classify แบบ Random Forest และใช้ SVM สำหรับการจำแนกคุณภาพ โดยจากการทดสอบได้โมเดลและบรรลุนัดสูงประสงค์ คือ เพื่อจำแนกและประเมินคุณภาพของมะม่วง โดยเฉพาะในการตรวจจับจุดดำหรือตำหนิบนผิวมะม่วงที่บ่งบอกถึงโรคหรือการเน่าเสีย (โรคแอนแทรกโนส) ซึ่งนวัตกรรมนี้ช่วยให้เกิดการเกษตรสมารทและการปฏิวัติอุตสาหกรรมในอนาคตได้ [10] ซึ่งจะเห็นได้ว่าจากอดีตจนถึงปัจจุบันได้มีการนำเทคโนโลยีปัญญา ประดิษฐ์ ซึ่งได้แก่ การเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก โครงข่ายประสาทเทียม การประมวลผลภาพ คอมพิวเตอร์วิชั่น เข้ามาประยุกต์ใช้กับอุตสาหกรรมมากขึ้น เนื่องจากเป็นวิธีการที่ลดต้นทุนการผลิต และลดความผิดพลาดจากมนุษย์ได้ดีที่สุด

จากทฤษฎีและปรัทัศน์วรรณกรรมเกี่ยวกับการใช้เทคนิคปัญญาประดิษฐ์ การพัฒนาเทคโนโลยีทาง ด้านอุตสาหกรรมเกษตรที่กล่าวถึงข้างต้น สามารถนำเทคนิคต่าง ๆ การประเมินผล การประเมินประสิทธิภาพของโมเดล ไปใช้ในการประมาณขนาด การตัดแยกไซส์ และการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้สำหรับการส่งออกและการฉายรังสีได้อย่างมีประสิทธิภาพ เทคนิคปัญญาประดิษฐ์เหล่านี้สามารถนำไปปรับใช้ได้หลายบริบท โดยการประยุกต์ใช้อย่างถูกต้องและเหมาะสมจะช่วยเพิ่มคุณภาพ ประสิทธิภาพ และลดข้อผิดพลาดในการประเมินคุณภาพซึ่งเป็นประโยชน์อย่างยิ่งต่อการปรับปรุงกระบวนการผลิตและการส่งออกที่ตรงตามมาตรฐานสากล ซึ่งกระบวนการและวิธีการดำเนินงานในการสร้างโมเดลหรือโปรแกรมจะอยู่ในบทถัดไป

บทที่ 3

วิธีการดำเนินงานวิจัย

ในบทนี้จะนำเสนอกระบวนการและขั้นตอนวิธีการดำเนินงานวิจัย อุปกรณ์ และเครื่องมือ สำหรับใช้ในการเก็บรวบรวมข้อมูลและวิเคราะห์ข้อมูล มีการออกแบบการเก็บข้อมูลสำหรับการฝึกฝนโมเดลโดยใช้เทคนิคปัญญาประดิษฐ์ต่าง ๆ จากทฤษฎีที่ได้กล่าวถึงในบทที่ 2 โดยมีวิธีการดำเนินงาน แสดงในรูปที่ 3.1 แบ่งออกเป็น 2 ขั้นตอนหลัก คือ การเตรียมชุดข้อมูล เก็บข้อมูล (Datasets) และการฝึกฝนและทดสอบโมเดล โดยการฝึกฝนและการทดสอบโมเดลหรือโปรแกรมนั้น ในงานวิจัยนี้แบ่งออกเป็น 3 ส่วน ได้แก่ ส่วนที่ 1 การประมาณขนาด (กว้าง ยาว สูง) ของมะม่วงน้ำดอกไม้ ส่วนที่ 2 การตัดแยกไซส์มะม่วงน้ำดอกไม้ (2S, S, M, L, 2L, 3L) และส่วนที่ 3 การตัดแยกคุณภาพ (ดี-เสีย) ของมะม่วงน้ำดอกไม้



รูปที่ 3.1 แผนภาพวิธีการดำเนินงานวิจัย

จากรูปที่ 3.1 แสดงขั้นตอนและแผนภาพวิธีการดำเนินงานที่ได้ใช้เทคนิคปัญญาประดิษฐ์ (Artificial Intelligence) โดยใช้ชุดข้อมูลของมะม่วงน้ำดอกไม้พันธุ์สีทองเป็นฐานข้อมูล (Datasets) สำหรับการประมวลผล ซึ่งชุดข้อมูลดังกล่าวประกอบด้วยจำนวนมะม่วงน้ำดอกไม้แต่ละไซส์ ดังนี้

3.1 จำนวนข้อมูลของมะม่วงน้ำดอกไม้

ในการทดลองใช้มะม่วงน้ำดอกไม้พันธุ์สีทองจำนวนทั้งหมด 61 ลูก ประกอบด้วยมะม่วงน้ำดอกไม้ทั้งหมด 6 ไซส์ ได้แก่ ไซส์ 2S จำนวน 12 ลูก ไซส์ S จำนวน 19 ลูก ไซส์ M จำนวน 12 ลูก ไซส์ L จำนวน 7 ลูก ไซส์ 2L จำนวน 6 ลูก และไซส์ 3L จำนวน 5 ลูก โดยมาตรฐานในการส่งออกมะม่วงน้ำดอกไม้จะใช้วิธีการชั่งน้ำหนักซึ่งสามารถแบ่งตามช่วงน้ำหนักได้ ดังนี้

Size 2S	ขนาดน้ำหนัก 225 - 249 กรัม
Size S	ขนาดน้ำหนัก 250 - 279 กรัม
Size M	ขนาดน้ำหนัก 280 - 329 กรัม
Size L	ขนาดน้ำหนัก 330 - 379 กรัม
Size 2L	ขนาดน้ำหนัก 380 - 449 กรัม
Size 3L	ขนาดน้ำหนักมากกว่า 450 กรัม

จากที่กล่าวมาข้างต้นนั้นได้มีการบันทึกข้อมูลของมะม่วงน้ำดอกไม้ โดยบันทึกน้ำหนัก ไซส์ และขนาด (กว้าง ยาว สูง) เพื่อนำไปสู่การสร้างชุดข้อมูล (Datasets) สำหรับฝึกฝนโมเดลด้วยเทคนิคปัญญาประดิษฐ์ของมะม่วงน้ำดอกไม้ โดยการสร้างชุดข้อมูลนั้นมีอุปกรณ์ในการเก็บข้อมูลวิธีการเก็บข้อมูล (Data Acquisition) สำหรับการฝึกฝนและทดสอบโมเดล ดังนี้

3.2 การเก็บข้อมูล (Data Acquisition)

การใช้เทคนิคปัญญาประดิษฐ์เพื่อประมาณขนาด คัดแยกไซส์ และคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ ในการเก็บข้อมูลสำหรับทดลองและทดสอบจึงจำเป็นต้องครอบคลุมทั้งหมดเพื่อให้บรรลุตามวัตถุประสงค์ของวิจัย ดังนั้น จึงมีการบันทึกข้อมูล ได้แก่ ขนาด (กว้าง ยาว สูง) น้ำหนัก ไซส์ และมีการถ่ายภาพในแต่ละมุมมองที่แตกต่างกัน เพื่อให้ได้จำนวนชุดข้อมูลที่มีความหลากหลาย มีอุปกรณ์สำหรับการเก็บข้อมูล ดังนี้

อุปกรณ์การเก็บข้อมูลสำหรับฝึกฝนโมเดลประกอบด้วย 6 ข้อ ดังนี้

- 1) กล้องเว็บแคม รุ่น Logitech Brio 4K
- 2) ลักซ์มิเตอร์
- 3) หลอดไฟแบบปรับความสว่างได้ (Dimmable LED)
- 4) เวอร์เนียร์คาลิเปอร์

- 5) เครื่องชั่งน้ำหนักดิจิทัล
- 6) ชุดสายพานทดสอบ (Conveyer)

จากนั้นนำมะม่วงน้ำดอกไม้มาทำการวัดขนาด ชั่งน้ำหนักเพื่อระบุไซส์ และจัดบันทึกข้อมูลแสดงดังในรูปที่ 3.2 ซึ่งเก็บข้อมูลในช่วงฤดูกาลของมะม่วงน้ำดอกไม้ (มีนาคม-เมษายน) โดยจัดซื้อมะม่วงน้ำดอกไม้ ณ ตลาดวงเวียนประตู่ 1 (มทส.) มหาวิทยาลัยเทคโนโลยีสุรนารี และตลาดเทิดไท้ ตาลคู๋ จังหวัดนครราชสีมา



รูปที่ 3.2 การวัดขนาดและชั่งน้ำหนักของมะม่วงน้ำดอกไม้


การบันทึกขนาดและน้ำหนักมะม่วงน้ำดอกไม้จะใช้เวอร์เนียร์เนยคาลิปเปอร์ในการวัดขนาด จากรูปที่ 3.2 เป็นการวัดขนาดในด้านกว้าง ยาว และสูง ซึ่งจะวัดบริเวณจุดที่มีขนาดกว้างมากที่สุด ยาวมากที่สุด และสูงมากที่สุดในแต่ละด้าน และชั่งน้ำหนักด้วยเครื่องชั่งน้ำหนักแบบดิจิทัล ซึ่งอุปกรณ์ทั้งเวอร์เนียร์คาลิปเปอร์ และเครื่องชั่งน้ำหนักแบบดิจิทัลได้ทำการสอบเทียบ (Calibration) ด้วยการวัดขนาดและชั่งน้ำหนักกับวัตถุที่ทราบน้ำหนักและขนาดที่ถูกต้องแล้ว เมื่อทำการวัดขนาดและชั่งน้ำหนักเสร็จแล้ว ทำการบันทึกผลข้อมูล

การถ่ายภาพสำหรับเป็นชุดข้อมูลสำหรับฝึกฝน (Datasets) ได้ทำการติดกล้องเว็บแคมมีระยะห่างจากพื้นสายพานอยู่ที่ 55.5 เซนติเมตร และที่บริเวณชุดทดสอบได้มีการติดหลอด LED จำนวน 2 หลอด ดังแสดงในรูปที่ 3.3 ซึ่งเป็นลักษณะแบบปรับความสว่างได้ (Dimmable LED) สำหรับถ่ายภาพ Datasets 2 เงื่อนไข ได้แก่ เงื่อนไขที่ 1 ถ่ายภาพโดยใช้แสงสว่างจากภายในห้องปกติที่ช่วงความสว่าง 430-450 ลักซ์ และเงื่อนไขที่ 2 เปิดหลอด Dimmable LED ใช้ความสว่างที่ช่วง 1000-1020 ลักซ์




รูปที่ 3.3 ชุดสายพานทดสอบและอุปกรณ์วัดความสว่าง (ลักซ์มิเตอร์)

ภาพถ่ายที่ได้จากการใช้กล้องเว็บแคมจะมีความละเอียดอยู่ที่ 640 x 480 พิกเซล ดังแสดงในรูปที่ 3.4 ซึ่งถือเป็นมาตรฐานที่ได้รับการยอมรับอย่างแพร่หลายสำหรับการใช้งานทั่วไปกับกล้องเว็บแคม ความละเอียดนี้เพียงพอสำหรับการบันทึกรายละเอียดพื้นฐานของภาพ เช่น รอยตำหนิที่สามารถมองเห็นได้ด้วยตาเปล่า (Visualization) ทำให้สามารถนำรูปภาพได้อย่างมีประสิทธิภาพ



รูปที่ 3.4 ภาพที่ได้จากกล้องเว็บแคม ที่มีขนาด 640 x 480 พิกเซล

จากนั้นนำรูปภาพเข้าสู่กระบวนการเตรียมรูปภาพก่อนนำไปใช้งานหรือประมวลผลภาพเบื้องต้น (Image Preprocessing) ได้แก่ การครอบตัด (Cropping) ซึ่งทำการตัดขอบส่วนของภาพที่ไม่จำเป็นออกโฟกัสเฉพาะพื้นที่สำคัญ โดยจะรูปภาพที่มีขนาด 480 x 280 พิกเซล รูปที่ 3.5 แสดงภาพที่ถูกทำการครอบตัด



รูปที่ 3.5 ตำแหน่งรูปภาพที่ถูกทำการครอบตัด (Cropping) ขนาด 480 x 280 พิกเซล

จากรูปภาพที่ 3.5 การครอบตัดภาพให้เหลือขนาด 480 x 280 พิกเซลนั้น ถูกเลือกเป็นพื้นที่สำคัญสำหรับการวางวัตถุเพื่อลดความคลาดเคลื่อนที่อาจเกิดขึ้นระหว่างการถ่ายภาพเพื่อการวัดขนาดของวัตถุ เนื่องจากตำแหน่งการวางวัตถุในพื้นที่นี้ช่วยลดผลกระทบจากมุมกล้องที่อาจสร้างความผิดเพี้ยนของภาพ (Distortion) นอกจากนี้ แสงและความสว่างที่ส่องมาถึงวัตถุเมื่อวางในตำแหน่งต่าง ๆ ยังส่งผลต่อการมองเห็นรายละเอียดและตำแหน่งของวัตถุอย่างชัดเจน ด้วยเหตุนี้ การกำหนดพื้นที่สนใจในการถ่ายภาพที่ 480 x 280 พิกเซล จึงเป็นการเลือกตำแหน่งที่เหมาะสมที่สุดเพื่อให้สามารถวัดขนาดวัตถุได้อย่างแม่นยำและสม่ำเสมอ ลดปัญหาที่อาจเกิดจากความผิดเพี้ยนของภาพและการกระจายของแสงในภาพถ่าย นอกจากนี้ยังทำให้ได้ภาพพื้นหลัง (Background) ที่เป็นฉากด้านหลังเฉพาะสายพาน (Belt Conveyor) ทำให้ได้เป็นชุดข้อมูลที่มีเปรียบเสมือนชุดการฉายรังสีจริง เนื่องจากลักษณะงานในด้านการฉายรังสีจะใช้ชุดสายพานในการลำเลียงวัตถุหรือสิ่งของ และหลังจากนั้นทำการแปลงภาพจากภาพสีต้นฉบับให้เป็นภาพขาว-ดำ โดยใช้ Binary Algorithm ดังแสดงในรูปที่ 3.6 ซึ่งเป็นส่วนหนึ่งของขั้นตอนการประมวลผลภาพเบื้องต้น (Image Preprocessing) การแปลงนี้มีวัตถุประสงค์เพื่อเพิ่มความคมชัดของภาพ โดยทำให้สามารถโฟกัสที่รายละเอียดสำคัญของวัตถุได้ชัดเจนยิ่งขึ้น การแปลงเป็นภาพขาว-ดำช่วยลดความซับซ้อนของข้อมูลภาพ ทำให้สามารถระบุขอบเขตและรูปร่างของวัตถุได้แม่นยำขึ้น ซึ่งเป็นขั้นตอนที่สำคัญในการวิเคราะห์และประมวลผลภาพถ่ายเพื่อการวัดขนาดและตรวจสอบคุณภาพของวัตถุ



รูปที่ 3.6 ภาพที่ถูกทำการครอบตัด (Cropping) และภาพที่ถูกแปลงเป็นภาพขาว-ดำ (Binary)


3.3 วิธีการทดลองงานวิจัย

การออกแบบการทดลองงานวิจัยนี้แบ่งการทดสอบออกเป็น 3 ส่วน ตามวัตถุประสงค์ของงานวิจัย ได้แก่ การประมาณขนาด การคัดแยกไซส์ และการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ ซึ่งได้มีการใช้เทคนิคปัญญาประดิษฐ์ที่แตกต่างกัน ได้แก่ การประมาณขนาดใช้เทคนิคการประมวลผลภาพ (Image Processing) และเทคนิคการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression) การคัดแยกไซส์จะเทคนิคการเรียนรู้เชิงลึกด้วยวิธีการโครงข่ายประสาทเทียม (Artificial Neural Network : ANN) และการคัดแยกคุณภาพใช้เทคนิคการเรียนรู้เชิงลึกด้วยวิธีการโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network : CNN) โดยจากจำนวนข้อมูลของมะม่วงน้ำดอกไม้ในหัวข้อที่ 3.1 ได้มีการคัดเลือกจำนวนข้อมูลและเตรียมข้อมูลสำหรับเข้าสู่กระบวนการฝึกฝนโมเดลด้วยเทคนิคปัญญาประดิษฐ์ ดังนี้

3.3.1 จำนวนชุดข้อมูล (Datasets)

จำนวนชุดข้อมูล (Datasets) ในการฝึกฝนโมเดลได้เลือกมาจากมะม่วงน้ำดอกไม้พันธุ์สีทองทั้ง 61 ลูก ซึ่งเป็นรูปภาพที่ผ่านกระบวนการประมวลผลภาพเบื้องต้นในข้อที่ 3.2 มาแล้ว ซึ่งเป็นจำนวนชุดข้อมูลออกเป็น 2 ส่วนหลัก ๆ คือ ชุดข้อมูลสำหรับฝึกฝน (Training sets) และชุดข้อมูลสำหรับการทดสอบโมเดลที่ถูกฝึกฝนมาแล้วเป็นชุดข้อมูลที่ไม่เคยเห็นมาก่อน (Unseen Data) โดยแบ่งเป็นข้อมูลสำหรับฝึกฝน (Training sets) ออกเป็น 3 ส่วน ได้แก่ Training 70% Testing 15% และ Validation 15%

โดยในชุดข้อมูลสำหรับฝึกฝน (Training 70%) ประกอบด้วย รูปภาพมะม่วงดีและมะม่วงเสียอย่างละ 420 รูปภาพ จากนั้นนำรูปภาพมาทำการเพิ่มจำนวนข้อมูล (Data Augmentation) โดยการปรับความสว่าง $\pm 5\%$ รวมทั้งสิ้น 2520 รูปภาพ รูปที่ 3.7 แสดงการเพิ่มจำนวนข้อมูลโดยวิธีการปรับความสว่าง



รูปที่ 3.7 การเพิ่มจำนวนข้อมูลโดยวิธีการปรับความสว่าง (Brightness)

ชุดข้อมูลสำหรับทดสอบ (Testing 15%) และชุดข้อมูลสำหรับตรวจสอบผล (Validation 15%) ประกอบด้วย รูปภาพมะม่วงดีและมะม่วงเสียอย่างละ 90 รูปภาพ และ Unseen Data ประกอบด้วย รูปภาพมะม่วงดีและมะม่วงเสียอย่างละ 50 รูปภาพ ดังตารางที่ 3.1 แสดงจำนวนชุดข้อมูล Datasets สำหรับฝึกฝนโมเดล

ตารางที่ 3.1 Datasets สำหรับฝึกฝนโมเดล

ชนิดของมะม่วง	Datasets			
	Train (70%)	Test (15%)	Validation (15%)	Unseen Data
มะม่วงน้ำดอกไม้ดี	1260	90	90	50
มะม่วงน้ำดอกไม้เสีย	1260	90	90	50
รวม	2520	180	180	100


จากตารางที่ 3.1 ในการทดลองทั้ง 3 ส่วน ตามวัตถุประสงค์ ได้แก่ การประมาณขนาด การคัดไซส์ การคัดแยกคุณภาพ จะใช้ชุดข้อมูล Unseen Data ชุดเดียวกันทั้งหมดจำนวน 100 รูปภาพ ซึ่งประกอบไปด้วยภาพของมะม่วงน้ำดอกไม้แต่ละไซส์ ดังนี้

- Size 2S จำนวน 31 รูปภาพ
- Size S จำนวน 32 รูปภาพ
- Size M จำนวน 11 รูปภาพ
- Size L จำนวน 13 รูปภาพ
- Size 2L จำนวน 8 รูปภาพ
- Size 3L จำนวน 5 รูปภาพ

ซึ่งทั้งหมดนี้ประกอบด้วยรูปภาพที่เป็นมะม่วงดี 50 รูปภาพ และมะม่วงเสีย 50 รูปภาพ โดยการใช้ Unseen Data ชุดเดียวกันสำหรับการทดสอบโมเดลเป็นวิธีการที่ช่วยเพิ่มความน่าเชื่อถือของผลการทดลอง และช่วยให้สรุปผลได้อย่างถูกต้องและแม่นยำยิ่งขึ้น


3.3.2 การประมาณขนาดมะม่วงน้ำดอกไม้

การประมาณขนาดของมะม่วงน้ำดอกไม้ (กว้าง ยาว สูง) มีการใช้เทคนิคการประมวลผลภาพ (Image Processing) และการมองเห็นด้วยคอมพิวเตอร์ การประมาณขนาดความกว้างกับความยาว และใช้เทคนิคการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression) ในการประมาณขนาดความสูง ดังแสดงในรูปที่ 3.8 แผนภาพวิธีการดำเนินงานการประมาณขนาดของมะม่วงน้ำดอกไม้ ซึ่งจะเห็นว่ามีการแบ่งการประมาณขนาดออกเป็น 2 ส่วน คือ การประมาณความกว้างกับความยาวและการประมาณความสูง ซึ่งเมื่อได้ความกว้างและความยาวจากเทคนิคการประมวลผลภาพและการมองเห็นด้วยคอมพิวเตอร์ด้วยการใช้ Library OpenCV (Open Source Computer Vision Library) ซึ่งเป็นที่นิยมในการใช้ประมวลผลภาพหรือวิดีโอ โดยทำการตรวจจับวัตถุและใช้เทคนิคการประมวลผลภาพ คือ พีเจอร์ในการค้นหาขอบเขต (Contours) และการตรวจจับขอบวัตถุด้วยวิธีการ Canny Edge Detection โดยวิธีการตรวจจับขอบด้วยเทคนิคแคนนี่มีการกำหนดค่า Threshold ที่ขอบเขตล่าง คือ 140 ขอบเขตบน คือ 255 ทำการวัดขนาดโดยการตีกรอบสี่เหลี่ยมล้อมรอบวัตถุ จากนั้นจะสามารถประมาณขนาดความกว้าง (Width) และความยาว (Length) ออกมาได้หน่วยพิกเซล จากนั้นทำการแปลงหน่วยจากพิกเซลเป็นหน่วยเซนติเมตรโดยการนำค่าในหน่วยพิกเซลมาคูณกับอัตราส่วนสเกล (Scale Factor) ในงานวิจัยนี้จากชุดข้อมูลของมะม่วงทำให้ได้อัตราส่วนสเกลของความกว้างคือ 0.105 และอัตราส่วนสเกลของความยาวคือ 0.110



รูปที่ 3.8 แผนภาพวิธีการดำเนินการประมาณขนาดของมะม่วงน้ำดอกไม้

จากแผนภาพวิธีการดำเนินการประมาณขนาดของมะม่วงน้ำดอกไม้ ในส่วนของการประมาณขนาดความกว้างและความยาว ด้วยการใช้เทคนิคตรวจจับขอบด้วยแคณนี่และการค้นหาขอบเขต (Contour) ได้ผลลัพธ์ ดังแสดงในรูปที่ 3.9



รูปที่ 3.9 ตัวอย่างการใช้เทคนิคตรวจจับขอบด้วยแคณนี่และการค้นหาขอบเขต (Contour)

ในส่วนของการประมาณความสูง (Depth) ของมะม่วงน้ำดอกไม้ ด้วยเทคนิคการถดถอยเชิงพหุคูณ (Multiple Linear Regression) โดยใช้ตัวแปรอิสระ (Input) คือ ความกว้าง (Width) และความยาว (Length) ในหน่วยเซนติเมตร และตัวแปรตาม (Output) คือ ความสูง (Depth) ซึ่งจากข้อมูลได้มีการแบ่งไซส์ของมะม่วงน้ำดอกไม้ในการฝึกฝนโมเดลการถดถอยเชิงพหุคูณ ดังนั้น จึงได้รูปแบบสมการออกมาทั้งหมด 6 สมการ ดังนี้

$$\text{Size 2S : Depth} = -0.076 + (0.815 \times \text{Width}) + (0.04 \times \text{Length})$$

$$\text{Size S : Depth} = 7.117 + (0.21 \times \text{Width}) - (0.19 \times \text{Length})$$


$$\text{Size M : Depth} = 6.465 + (0.155 \times \text{Width}) - (0.097 \times \text{Length})$$

$$\text{Size L : Depth} = 8.685 - (0.467 \times \text{Width}) + (0.074 \times \text{Length})$$

$$\text{Size 2L : Depth} = 8.685 - (0.467 \times \text{Width}) + (0.074 \times \text{Length})$$

$$\text{Size 3L : Depth} = 9.01 - (1.756 \times \text{Width}) + (0.754 \times \text{Length})$$

ในกระบวนการวิเคราะห์ข้อมูล ได้มีการกำหนดคำสั่งเงื่อนไขโดยอ้างอิงจากความกว้างของมะม่วงน้ำดอกไม้ ซึ่งแบ่งช่วงจากข้อมูลจริงที่ได้จากการวัดความกว้างของมะม่วง โดยการใช้การพล็อตกราฟเพื่อหาค่าต่ำสุด (Minimum) ค่าสูงสุด (Maximum) และค่าเฉลี่ย (Mean) ของความกว้างของมะม่วงแต่ละไซส์ได้อย่างชัดเจน แสดงดังในรูปที่ 3.10 โดยแสดงให้เห็นถึงช่วงค่าที่มะม่วงในแต่ละขนาดมีความกว้างที่คล้ายคลึงกัน การวิเคราะห์บริเวณที่มีการซ้อนทับนี้มีความสำคัญในการกำหนดขอบเขตและปรับแต่งคำสั่งเงื่อนไขให้แม่นยำยิ่งขึ้น



รูปที่ 3.10 กราฟแสดงผลค่าความกว้างของมะม่วงแต่ละไซส์

จากกราฟแสดงผลค่าความกว้างของมะม่วงแต่ละไซส์สามารถแบ่งช่วงความกว้างออกเป็น 6 เงื่อนไข ดังนี้

Size 2S : $5.000 \leq \text{Width} \leq 6.400$

Size S : $6.401 \leq \text{Width} \leq 6.800$

Size M : $6.801 \leq \text{Width} \leq 7.170$


Size L : $7.171 \leq \text{Width} \leq 7.690$

Size 2L : $7.691 \leq \text{Width} \leq 8.060$

Size 3L : $8.061 \leq \text{Width} \leq 11.000$

ซึ่งจากช่วงของความกว้างของมะม่วงน้ำดอกไม้ทั้ง 6 เงื่อนไขและสมการที่ได้จากการเทรนโมเดลการถดถอยเชิงพหุคูณทั้ง 6 สมการ สามารถนำมาเขียนเป็นแผนภาพกระบวนการตัดสินใจการประมาณความสูง (Depth) ได้ รูปที่ 3.11 แสดงแผนภาพเงื่อนไขการตัดสินใจการประมาณความสูง





รูปที่ 3.11 แผนภาพเงื่อนไขการตัดสินใจการประมาณความสูง

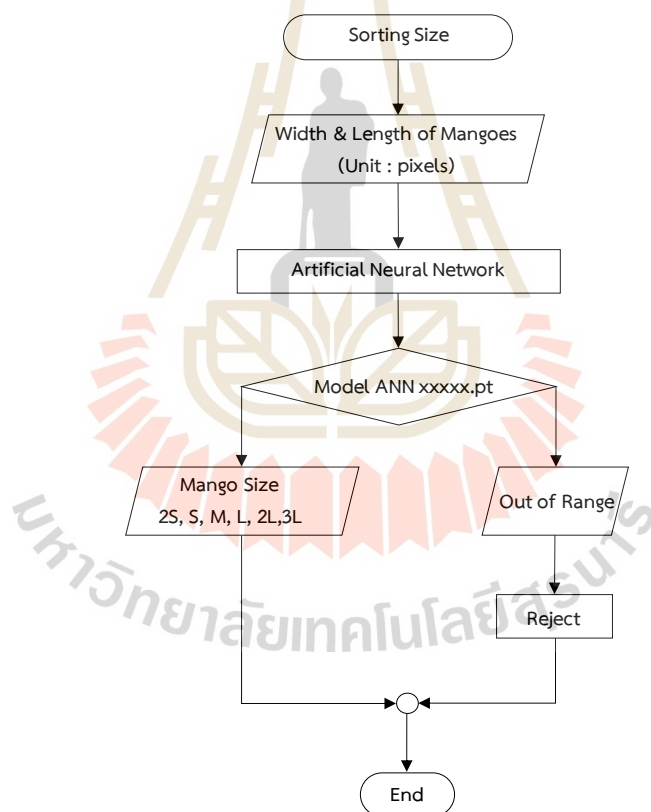
เมื่อได้ช่วงของความกว้างแล้วจึงมีการกำหนดเงื่อนไขร่วมกับสมการที่ได้จากโมเดลการถดถอยเชิงพหุคูณ (Multiple Linear Regression) เพื่อทำการเลือกสมการในการคำนวณหา

ความสูง ดังนั้น เมื่อทำครบขั้นตอนี้แล้ว จะได้ขนาดของมะม่วงน้ำดอกไม้ ได้แก่ ความกว้าง (Width) ความยาว (Length) และความสูง (Depth) ที่สามารถนำไปใช้ประโยชน์กับการฉายรังสีได้

โดยเมื่อมีการประมาณขนาดความกว้างและความยาวในหน่วยพิกเซลแล้ว จึงมีการใช้ประโยชน์จากผลลัพธ์ที่ได้นี้ได้ใน การสร้างโมเดลสำหรับคัดแยกไซส์ของมะม่วงน้ำ โดยการใช้การฝึกฝนโมเดลด้วยขนาดความกว้างและความยาวในหน่วยพิกเซล โดยใช้กล้องเว็บแคมและเทคนิคปัญญาประดิษฐ์ ซึ่งมีวิธีการและขั้นตอนในการคัดแยกไซส์ ดังนี้

3.3.3 การคัดแยกไซส์มะม่วงน้ำดอกไม้

การคัดแยกไซส์ของมะม่วงน้ำดอกไม้ แบ่งออกเป็น 6 ไซส์ ได้แก่ 2S, S, M, L, 2L และ 3L โดยใช้เทคนิคโครงข่ายปัญญาประดิษฐ์ (Artificial Neural Network : ANN) ใช้ชุดข้อมูลในการฝึกฝนโมเดล รูปที่ 3.12 แสดงแผนภาพวิธีการดำเนินงานการคัดแยกไซส์มะม่วงน้ำดอกไม้



รูปที่ 3.12 แผนภาพวิธีการดำเนินงานการคัดแยกไซส์มะม่วงน้ำดอกไม้

การคัดแยกไซส์ของมะม่วงน้ำดอกไม้ แบ่งออกเป็น 6 ไซส์ ได้แก่ 2S, S, M, L, 2L และ 3L โดยใช้เทคนิคโครงข่ายปัญญาประดิษฐ์ (Artificial Neural Network : ANN) ใช้ชุดข้อมูลใน

การฝึกฝนโมเดล ที่แสดงดังตารางที่ 3.2 ซึ่งมีการแปลงข้อมูลจากรูปภาพเป็นตัวเลขความกว้างและความยาวในหน่วยพิกเซล ด้วยเทคนิคการประมวลผลภาพ (Image Processing) ดังข้อที่ 3.3.2 การประมาณขนาดของมะม่วงน้ำดอกไม้ และเนื่องจากมีภาพมะม่วงเสียที่เกิดความเสียหายบริเวณขอบเมื่อนำข้อมูลความกว้างและความยาวในหน่วยพิกเซลมาทำการพิจารณาพบว่าจะทำให้โมเดลมีความค่าคลาดเคลื่อนที่สูง ดังนั้นจึงมีการคัดเลือกข้อมูล ทำให้ข้อมูลสำหรับ ANN model มีทั้งสิ้น 2184 ข้อมูล โดยมาจากการนำรูปภาพสำหรับชุด Train ดังตารางที่ 3.2 จำนวน 2520 รูปภาพ ไปผ่านกระบวนการนับพิกเซลความกว้างและความยาวด้วยเทคนิคคอมพิวเตอร์วิชัน (Computer Vision) โดยใช้ Library OpenCV และแบ่งชุดข้อมูลออกเป็น Train 70% Test 15% และ Validation 15% โดยประกอบด้วยจำนวนข้อมูล ดังนี้

จำนวนข้อมูล Train 70%

Size SS จำนวน 421 ข้อมูล

Size S จำนวน 519 ข้อมูล

Size M จำนวน 236 ข้อมูล

Size L จำนวน 185 ข้อมูล

Size 2L จำนวน 88 ข้อมูล

Size 3L จำนวน 79 ข้อมูล

จำนวนข้อมูล Test 15%

Size SS จำนวน 78 ข้อมูล

Size S จำนวน 114 ข้อมูล

Size M จำนวน 55 ข้อมูล

Size L จำนวน 35 ข้อมูล

Size 2L จำนวน 29 ข้อมูล

Size 3L จำนวน 17 ข้อมูล

จำนวนข้อมูล Validation 15%

Size SS จำนวน 85 ข้อมูล

Size S จำนวน 108 ข้อมูล

Size M จำนวน 63 ข้อมูล

Size L จำนวน 31 ข้อมูล

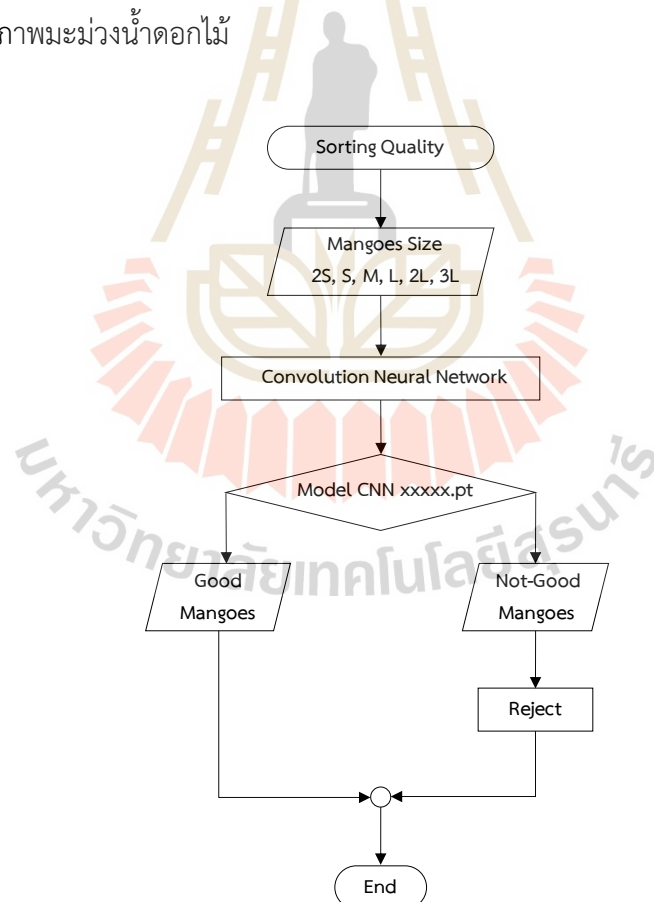
Size 2L จำนวน 17 ข้อมูล

Size 3L จำนวน 24 ข้อมูล

จากนั้นฝึกฝนโมเดลด้วยเทคนิค ANN (Artificial Neural Network) โดยการใช้การสกัดฟีเจอร์จากการนับจำนวนพิกเซลของความกว้างและความยาวด้วยเทคนิคเดียวกับการประมาณขนาด ซึ่งได้แก่ การประมวลผลภาพและโปรแกรมการมองเห็นด้วยคอมพิวเตอร์ (OpenCV) ดังนั้น จากขั้นตอนนี้ได้ไซส์ของมะม่วงน้ำดอกไม้ได้อย่างถูกต้อง เพื่อประโยชน์ในด้านคุณภาพและราคาของสินค้า ซึ่งนอกจากการคัดแยกไซส์ได้ถูกต้องแล้ว การคัดแยกคุณภาพสำหรับมะม่วงที่มีตำหนิและไม่มีตำหนิก็สามารถเพิ่มมูลค่าของสินค้าได้เช่นเดียวกัน ดังนั้น เมื่อทำการคัดแยกไซส์เรียบร้อยแล้ว จึงทำการคัดแยกคุณภาพโดยใช้กล้องเว็บแคมและเทคนิคปัญญาประดิษฐ์ ซึ่งมีขั้นตอนและกระบวนการ ดังนี้

3.3.4 การคัดแยกคุณภาพมะม่วงน้ำดอกไม้

การคัดแยกคุณภาพของมะม่วงน้ำดอกไม้จะใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network : CNN) ซึ่งมีความแม่นยำสูงเมื่อมีการใช้รูปภาพ โดยการใช้รูปภาพมะม่วงน้ำดอกไม้ที่ถูกแปลงภาพ จากภาพสีให้เป็นขาว-ดำ เพื่อให้สามารถคัดแยกมะม่วงดีและมะม่วงเสียได้ โดยมีวิธีการ รูปที่ 3.13 แสดงแผนภาพวิธีการดำเนินงานการคัดแยกคุณภาพมะม่วงน้ำดอกไม้



รูปที่ 3.13 แผนภาพวิธีการดำเนินงานการคัดแยกคุณภาพมะม่วงน้ำดอกไม้

ในการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้แบ่งมะม่วงออกเป็น 2 ประเภทหลัก ได้แก่ มะม่วงดีและมะม่วงเสีย โดยมีเกณฑ์การพิจารณา ดังนี้

มะม่วงดี หมายถึง มะม่วงที่มีคุณภาพสูง ซึ่งจะต้องมีผิวเปลือกที่เรียบเนียน สีสดใส และไม่มีตำหนิที่สามารถมองเห็นได้ด้วยตาเปล่า เช่น รอยขีด รอยแผล หรือจุดดำที่อาจเกิดจากโรคแอนแทรกโนส มะม่วงเหล่านี้ถือว่าเป็นมะม่วงที่สมบูรณ์ พร้อมสำหรับการจำหน่ายและบริโภค

มะม่วงเสีย หมายถึง มะม่วงที่มีตำหนิซึ่งสามารถมองเห็นได้ด้วยตาเปล่า รอยขีด รอยแผล หรือจุดดำที่บ่งบอกถึงการเริ่มต้นของโรคแอนแทรกโนส มะม่วงที่จัดอยู่ในกลุ่มนี้จะไม่สามารถนำไปจำหน่ายเป็นมะม่วงเกรดพรีเมียมหรือส่งออกได้ เนื่องจากคุณภาพไม่ตรงตามเกณฑ์ที่กำหนด


โดยในการคัดแยกคุณภาพของมะม่วง ใช้เทคนิคโครงข่ายปัญญาประดิษฐ์แบบคอนโวลูชัน (CNN) ซึ่งเป็นเทคนิคที่มีประสิทธิภาพสูงในการวิเคราะห์และจำแนกรูปภาพ ซึ่งใช้ชุดข้อมูลในการฝึกฝนโมเดลและทดสอบด้วยชุดข้อมูล Unseen Data ที่แสดงดังตารางที่ 3.2 ซึ่งมีการแปลงภาพจากภาพสีให้เป็นภาพขาว-ดำ และใช้การสกัดพีเจอร์จากการมีพิกเซลสีดำบนพื้นที่สีขาวของลูกมะม่วง

จากวิธีการดำเนินงานและการออกแบบการทดสอบข้างต้น ได้นำจำนวนชุดข้อมูล (Datasets) ที่ได้จากการเก็บข้อมูลโดยการถ่ายภาพ จากนั้นทำการตัดขอบภาพ ให้มีขนาดภาพ 480 x 280 พิกเซล และทำการแปลงภาพสีให้เป็นขาว-ดำ ด้วยการใช้ Binary Algorithm โดยจำนวนชุดข้อมูล (Datasets) แสดงดังตารางที่ 3.1 มาใช้เป็นชุดข้อมูลในการฝึกฝนโมเดลทั้ง 3 ส่วน โดยส่วนที่ 1 คือ การประมาณขนาดมะม่วงน้ำดอกไม้ ได้แก่ ความกว้าง (Width) และความยาว (Length) จะใช้เทคนิคการประมวลผลภาพ (Image Processing) และการมองเห็นด้วยคอมพิวเตอร์โดยใช้ Library OpenCV และการประมาณขนาดความสูง (Depth) ด้วยเทคนิคการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression) ในส่วนที่ 2 การคัดแยกไซส์มะม่วงน้ำดอกไม้ ซึ่งมะม่วงน้ำดอกไม้สำหรับการส่งออกจะแบ่งออกเป็น 6 ไซส์ คือ 2S, S, M, L, 2L และ 3L โดยใช้เทคนิคการเรียนรู้เชิงลึกโครงข่ายประสาทเทียม (ANN) และส่วนที่ 3 การคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ซึ่งคัดแยกมะม่วงดีและมะม่วงเสียที่มีรอยตำหนิ โดยใช้เทคนิคการเรียนรู้เชิงลึกโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เมื่อทำการฝึกฝนโมเดลแล้วจะนำโมเดลมาทำการทดสอบด้วยข้อมูลชุดทดสอบ Unseen Data ชุดเดียวกันทั้ง 3 ส่วน ซึ่งผลการฝึกฝน การทดสอบ และประเมินประสิทธิภาพของโมเดลจะนำเสนอในบทถัดไป

บทที่ 4

ผลการวิจัยและอภิปรายผล

ในบทนี้จะกล่าวถึงผลการวิจัยและการอภิปรายผล ซึ่งจะแสดงผลการทดลองและทดสอบในรูปแบบของรูปภาพ กราฟความสัมพันธ์ และตาราง โดยในงานวิจัยนี้ได้มีการทดสอบโดยแบ่งออกเป็น 3 ส่วน ได้แก่ การประมาณขนาด (กว้าง ยาว สูง) การตัดแยกไซส์ (2S, S, M, L, 2L, 3L) และการตัดแยกคุณภาพ (ดี-เสีย) ของมะม่วงน้ำดอกไม้ ซึ่งได้มีการใช้เทคนิคปัญญาประดิษฐ์หลากหลายเทคนิคเข้ามาประยุกต์ใช้เพื่อให้ได้โมเดลที่มีความแม่นยำ โดยหลังจากการฝึกฝนโมเดลเสร็จจะมีการนำโมเดลในการประมาณขนาด การตัดแยกไซส์ และการตัดแยกคุณภาพ มาทดสอบด้วยชุดข้อมูลชุดเดียวกัน คือ ชุดข้อมูลที่ไม่เคยเห็นมาก่อน (Unseen Data) รูปที่ 4.1 แสดงตัวอย่างผลการทดสอบโมเดลการประมาณขนาด คัดไซส์และตัดแยกคุณภาพด้วย Unseen Data



รูปที่ 4.1 ตัวอย่างผลการทดสอบโมเดลการประมาณขนาด คัดไซส์และตัดแยกคุณภาพ

จากผลการทดลองข้างต้นได้แสดงตารางบันทึกผลการทดสอบในภาคผนวก ข. ซึ่งแสดงถึงผลการทดสอบโมเดลการประมาณขนาด การตัดแยกไซส์ และการตัดแยกคุณภาพ ที่เปรียบเทียบระหว่างผลเฉลยและผลการทำนายจากโมเดล โดยผลการทดสอบโมเดลทั้ง 3 ส่วน ด้วยชุดทดสอบ Unseen Data ทำการวิเคราะห์และอภิปรายผลได้ ดังนี้

4.1 ผลการทดสอบการประมาณขนาดของมะม่วงน้ำดอกไม้

การประมาณขนาดของมะม่วงน้ำดอกไม้เป็นส่วนที่ 1 ของงานวิจัยนี้ โดยการประมาณความกว้างและความยาวจะใช้เทคนิคการมองเห็นด้วยคอมพิวเตอร์ (Computer Vision) และการประมวลผลภาพ (Image Processing) และการประมาณความสูง ใช้เทคนิคการเรียนรู้ของเครื่องด้วยวิธีการถดถอยเชิงพหุคูณ (Multiple Linear Regression) ซึ่งจากการฝึกฝนโมเดลเมื่อนำมาทดสอบด้วยชุดทดสอบ Unseen Data แล้ว ทำการประเมินประสิทธิภาพของโมเดลด้วยค่า Mean Absolute Percentage Error (MAPE) และ R-Squared (R^2) แสดงผลได้ดังตารางที่ 4.1 ดังนี้

ตารางที่ 4.1 ผลการทดสอบการประมาณขนาดของมะม่วงน้ำดอกไม้

Dimensions	Mean Absolute Percentage Error (%)	R-Squared
กว้าง (Width)	3.038	0.9985
ยาว (Length)	2.799	0.9987
สูง (Depth)	5.732	0.9948

จากผลลัพธ์ในตารางที่ 4.1 แสดงผลการทดสอบการประมาณขนาดของมะม่วงน้ำดอกไม้พบว่าเมื่อวิเคราะห์ผลด้วยค่า Mean Absolute Percentage Error (MAPE) การวัดขนาดในด้านความกว้าง ความยาว และความสูงถือว่ามีความแม่นยำที่สูงเนื่องจากมีค่า Error น้อยกว่า 10% (ค่า MAPE มีค่า Error น้อยกว่า 10% หมายถึง มีความแม่นยำมากกว่า 90%) ซึ่งจากการวิเคราะห์ผลด้วยค่า MAPE พบว่าค่าความคลาดเคลื่อนของการประมาณขนาดความสูงมีค่าสูงที่สุด คือ 5.732% ซึ่งอาจเกิดจากความสัมพันธ์ของตัวแปรไม่สมบูรณ์โดยโมเดลการถดถอยเชิงพหุคูณ เป็นการทำนายความสัมพันธ์ระหว่างตัวแปรตาม (ความสูง) กับตัวแปรอิสระ (ความกว้างและความยาว)

ดังนั้น ทำการพิจารณาประเมินประสิทธิภาพของโมเดลด้วยค่า R-Squared (R^2) จะพบว่าค่า R^2 ทั้ง 3 ค่า มีค่าที่เข้าใกล้ 1.00 ซึ่งหมายความว่าโมเดลสามารถทำนายและอธิบายความแปรปรวนของข้อมูลได้ดี แต่ถึงอย่างไรก็ตาม R^2 ไม่บอกถึงความสัมพันธ์ระหว่างตัวแปร และผลการประเมินประสิทธิภาพของโมเดลความสูงด้วยค่า MAPE (Depth) = 5.732% ซึ่งมีค่าที่สูงกว่าความ

กว้างและความยาว จึงทำการวิเคราะห์สหสัมพันธ์ (Correlation Analysis) เพื่อตรวจสอบความสัมพันธ์ระหว่างตัวแปรตามและตัวแปรอิสระ

โดยใช้การวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์แบบ Pearson Correlation Coefficient (r) ซึ่งพบว่า เมื่อใช้ชุดข้อมูลจริงที่ได้จากการวัดค่าความสัมพันธ์ที่ได้จากค่าจริงโดยเป็นความสัมพันธ์ระหว่างความกว้างและความสูง กับความยาวและความสูง มีค่า 0.89 และ 0.80 ตามลำดับ ซึ่งสูงกว่ามีนัยสำคัญเมื่อเทียบกับค่าที่ทำนายได้ ซึ่งมีค่าความสัมพันธ์ระหว่างความกว้างและความสูง กับความยาวและความสูง คือ 0.58 และ 0.26 ตามลำดับ โมเดลอาจมีข้อจำกัดในการทำนายในเรื่องจำนวนของชุดข้อมูลสำหรับการฝึกฝนโมเดล และสภาพแวดล้อมในการทดสอบโมเดล

ค่าความคลาดเคลื่อนจากการทำนายด้วยโมเดลนี้ อาจเกิดจากสภาพแวดล้อมต่าง ๆ เช่น ตำแหน่งการวางวัตถุ แสงและความสว่าง เป็นต้น ดังรูปที่ 4.2 แสดงตัวอย่างตำแหน่งการวางวัตถุที่ส่งผลต่อการทำนายความกว้างและความยาว



รูปที่ 4.2 ตัวอย่างการเปลี่ยนตำแหน่งการวางวัตถุที่ส่งผลต่อการวัดขนาด

จากรูปที่ 4.2 แสดงตัวอย่างตำแหน่งการวางวัตถุที่ส่งผลต่อการทำนายความกว้างและความยาว เป็นการเปลี่ยนวางตำแหน่งการวางวัตถุ ซึ่งใช้วัตถุเดียวกัน ได้แก่ มะม่วง โดยการหมุนลูกมะม่วงให้กลับด้านซึ่งจะเห็นว่าเมื่อมุมมองของภาพเปลี่ยนไป ส่งผลให้การวัดขนาดมีความคลาดเคลื่อน ซึ่งจากตัวอย่างจะเห็นว่าภาพด้านบน วัดขนาดได้ 63 x 126 พิกเซล และภาพทางด้านล่าง วัดขนาดได้

62 x 122 พิกเซล ซึ่งเมื่อนำค่าความกว้างและความยาวในหน่วยพิกเซล เปลี่ยนเป็นหน่วยเซนติเมตร โดยการนำค่าที่ได้มาคูณกับค่า Scale Factor (ความกว้าง SF = 0.105 และ ความยาว SF = 0.110) ภาพด้านบนจะได้ 6.615 x 13.86 เซนติเมตร และภาพด้านล่างจะได้ 6.510 x 13.42 เซนติเมตร จากตัวอย่างจะเห็นว่าตำแหน่งการวางวัตถุส่งผลต่อความสัมพันธ์ระหว่างตัวแปร และส่งผลต่อความแม่นยำของโมเดล ซึ่งในงานวิจัยนี้ได้มีการกำหนดขอบเขตการตำแหน่งการวางวัตถุให้อยู่ในขอบเขต 480 x 280 พิกเซล จึงได้ค่าความคลื่อนที่อยู่ในช่วงที่สามารถยอมรับได้

นอกจากนี้ แสงและความสว่างมีผลกระทบอย่างมากต่อการวัดขนาดของภาพ เนื่องจากการเปลี่ยนแปลงของแสงสามารถส่งผลต่อคุณภาพและลักษณะของภาพที่ได้ โดยเฉพาะเมื่อภาพถ่ายถูกบันทึกในสภาพแสงที่แตกต่างกัน ภาพถ่ายที่มีการจัดแสงไม่เหมาะสมอาจทำให้การวัดขนาดของวัตถุเกิดความคลาดเคลื่อน หรืออาจเกิดการบิดเบือนลักษณะของวัตถุในภาพได้ ซึ่งทำการทดสอบด้วยวิธีการนำภาพถ่ายที่เป็นภาพสี มาทำการปรับความสว่างและแปลงภาพให้เป็นภาพขาว-ดำ เช่นเดียวกันกับภาพที่ใช้ทดสอบ ซึ่งแสดงตัวอย่างดังรูปที่ 4.3 ตัวอย่างของภาพเดียวกันที่ถ่ายในสภาพแสงปกติซึ่งมีความสว่างอยู่ที่ 430-450 ลักซ์ จากนั้นเราทำการปรับความสว่างของภาพเพิ่มขึ้น +5% และลดลง -5% แสดงดังในรูปที่ 4.3 โดยภาพปกติมีขนาด 62 x 124 พิกเซล และผลลัพธ์จากการเพิ่มความสว่างจะทำให้ภาพมีขนาด 62 x 124 พิกเซล ในขณะที่การลดความสว่างจะทำให้ภาพมีขนาด 21 x 124 พิกเซล จะเห็นได้ว่าแสงที่มีความสว่างสูงหรือสูงเกินไป ทำให้ภาพขาดความคมชัด และรายละเอียดที่จำเป็นสำหรับการวัดขนาดที่แม่นยำ ในขณะที่แสงที่มีความสว่างต่ำอาจทำให้รายละเอียดในภาพหายไปและทำให้ขนาดของวัตถุดูเล็กกว่าความเป็นจริง



รูปที่ 4.3 ตัวอย่างการปรับความสว่างที่ส่งผลต่อการวัดขนาด

ดังนั้น การเปลี่ยนตำแหน่งการวางวัตถุและการควบคุมความสว่าง ส่งผลทำให้การวัดขนาด ความกว้าง และความยาวเมื่อใช้เทคนิคการตรวจจับขอบด้วยวิธีการประมวลผลภาพเบื้องต้น (Image Processing) และการมองเห็นด้วยคอมพิวเตอร์ (OpenCV) เกิดค่าความคลาดเคลื่อนได้

ในงานวิจัยนี้จึงได้มีการกำหนดขอบเขตในการวางวัตถุ ให้อยู่ภายในตำแหน่ง 480×280 พิกเซล และมีการควบคุมความสว่างในการถ่ายภาพชุด Unseen Data สำหรับทดสอบโมเดลให้มีความสว่างที่อยู่ในช่วง 430 - 450 ลักซ์ ตลอดการทดสอบ เพื่อให้การทำนายความกว้างและความยาวมีค่าความคลาดเคลื่อนต่ำที่สุด จากนั้นนำไปผ่านโมเดลการประมาณความสูงด้วยเทคนิค Multiple Linear Regression ก็จะมีค่าความคลาดเคลื่อนที่ต่ำ ด้วยเหตุนี้จึงส่งผลให้โมเดลในการประมาณขนาดความกว้าง ความยาว และความสูง มีความแม่นยำมากกว่า 90% ซึ่งถูกประเมินผลด้วยค่า MAPE และ R-Squared (R^2)

4.2 ผลการทดสอบการคัดแยกไซส์ของมะม่วงน้ำดอกไม้

การคัดแยกไซส์ของมะม่วงน้ำดอกไม้เป็นส่วนที่ 2 ของงานวิจัยนี้ โดยผลการทดสอบการคัดแยกไซส์ของมะม่วงน้ำดอกไม้ด้วยเทคนิคโครงข่ายประสาทเทียม (Artificial Neural Network : ANN) ใช้ชุดข้อมูลในการฝึกฝนเป็นตัวเลของความกว้างและความยาวในหน่วยพิกเซล ซึ่งมาตรฐานจะมีการแยกมะม่วงน้ำดอกไม้ออกเป็น 6 ไซส์ คือ 2S, S, M, L, 2L และ 3L โดยสามารถแสดงเป็น Confusion Matrix Precision Recall และ F1-Score ได้ดังนี้

ผลจากการฝึกฝนโมเดลด้วยเทคนิคโครงข่ายประสาทเทียม (ANN) ประเมินประสิทธิภาพของโมเดลด้วยตาราง Confusion Matrix รูปที่ 4.4 แสดง Confusion Matrix ของการ Train Model ANN สำหรับการคัดแยกไซส์

Actual	3L	21	2	1	0	0	0
	2L	1	11	5	0	0	0
	L	0	1	26	4	0	0
	M	0	0	3	46	14	0
	S	0	0	0	3	98	7
	2S	0	0	0	2	23	60
			3L	2L	L	M	S
		Predict					

รูปที่ 4.4 Confusion Matrix ของการ Train Model ANN สำหรับการคัดแยกไซส์


จากตาราง Confusion Matrix ดังรูปที่ 4.4 พบว่าโมเดลมีค่าความแม่นยำ (Accuracy) ของโมเดล คือ Train Accuracy = 79.878 % ซึ่งแสดงผลค่า Precision, Recall และ F1-Score แสดงได้ดังตารางที่ 4.2

ตารางที่ 4.2 ผลการทดสอบการฝึกฝนการคัดแยกไซส์ของมะม่วงน้ำดอกไม้

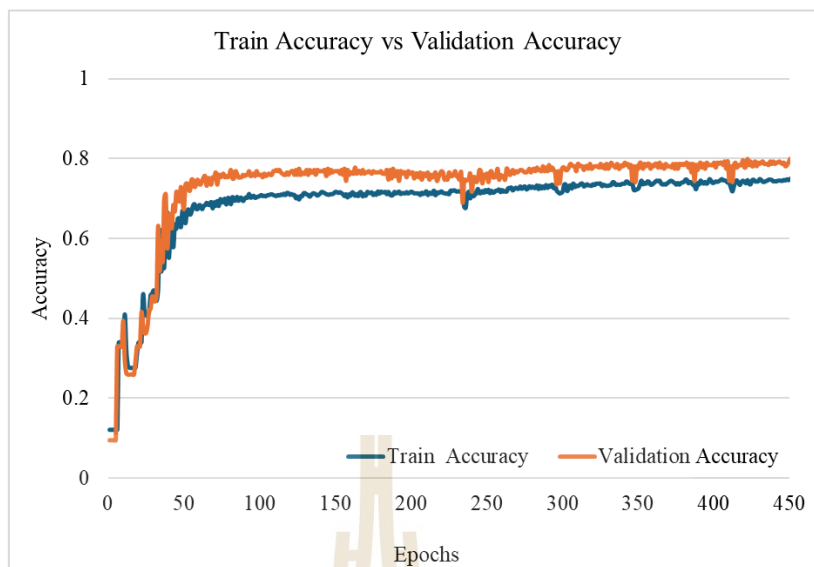
ไซส์ของมะม่วง	Precision	Recall	F1-Score
2S	0.896	0.706	0.790
S	0.726	0.907	0.806
M	0.836	0.719	0.773
L	0.743	0.839	0.788
2L	0.786	0.647	0.710
3L	0.945	0.875	0.909

จากตารางที่ 4.3 แสดงผลการฝึกฝนโมเดลการคัดแยกไซส์พบว่าโมเดลการทำนายไซส์ของมะม่วงไซส์ 3L ทำได้ดีที่สุด จากค่า F1-Score ที่สูงซึ่งหมายความว่าโมเดลทำงานได้ดีที่สุดในการทำนาย และการทำนายไซส์ได้แย่มากที่สุด คือ ไซส์ S จากค่า Precision และ Recall ที่มีความต่างกัน ซึ่งโมเดลสามารถจับมะม่วงไซส์ S ได้ดี แต่มีความแม่นยำในการทำนายต่ำ

ผลการฝึกฝนโมเดลสามารถแสดงกราฟความสัมพันธ์ระหว่าง Train Loss กับ Validation Loss แสดงดังในรูปที่ 4.5 และ Train Accuracy กับ Validation Accuracy แสดงดังรูปในที่ 4.6 ดังนี้



รูปที่ 4.5 กราฟความสัมพันธ์ระหว่าง Train Loss กับ Validation Loss ของโมเดล ANN



รูปที่ 4.6 กราฟความสัมพันธ์ระหว่าง Train Accuracy กับ Validation Accuracy ของโมเดล ANN

จากรูปที่ 4.5 และ 4.6 เมื่อทำการวิเคราะห์ผลจากพฤติกรรมกราฟ Loss และ Accuracy พบว่าในช่วงแรกของการฝึกโมเดลมีการเรียนรู้จากโมเดลได้ดี สังเกตจากกราฟ Loss ที่ลดลง และ Accuracy ที่เพิ่มขึ้นหลังจากนั้น ความแม่นยำทั้งสองเริ่มมีเสถียรภาพ (Stabilize) แต่จะสังเกตได้ว่า Validation Accuracy มีค่าที่สูงกว่า Train Accuracy ซึ่งอาจบ่งบอกว่าโมเดลกำลังประสบกับปัญหาการ Overfitting แต่ไม่รุนแรง เพราะโมเดลยังสามารถทำนายได้ดีกับชุดข้อมูล Validation และมีการใช้เทคนิค Early-Stop ก่อนการเกิดปัญหา Overfitting ในระดับที่รุนแรง

เมื่อได้โมเดลที่มีความแม่นยำจากการฝึกฝนแล้ว นำโมเดลมาทดสอบด้วยชุดข้อมูลที่ไม่เคยเห็นมาก่อน Unseen Data ผลจากการทดสอบโมเดล มีค่าความแม่นยำ (Accuracy) Test Accuracy = 87.00 % ซึ่งแสดงผล Confusion Matrix รูปที่ 4.7 แสดง Confusion Matrix ของการ Test Model ANN สำหรับการคัดแยกไซส์

Actual	3L	5	0	0	0	0	0
	2L	0	2	6	0	0	0
	L	0	0	8	5	0	0
	M	0	0	1	10	0	0
	S	0	0	0	0	32	0
	2S	0	0	0	0	1	30
		Predict	3L	2L	L	M	S

รูปที่ 4.7 Confusion Matrix ของการ Test Model ANN สำหรับการคัดแยกไซส์

จากตาราง Confusion Matrix ที่แสดงดังรูปที่ 4.7 สามารถแสดงผลค่า Precision Recall และ F1-Score แสดงได้ดังตารางที่ 4.3 ดังนี้

ตารางที่ 4.3 ผลการทดสอบการคัดแยกไซส์ของมะม่วงน้ำดอกไม้ด้วยชุดข้อมูล Unseen Data

ไซส์ของมะม่วง	Precision	Recall	F1-Score
2S	1.000	0.968	0.984
S	0.970	1.000	0.985
M	0.667	0.909	0.769
L	0.533	0.615	0.571
2L	1.000	0.333	0.500
3L	1.000	1.000	1.000

จากตารางที่ 4.3 แสดงผลการทดสอบการคัดแยกไซส์ของมะม่วงน้ำดอกไม้ด้วยชุดข้อมูล Unseen Data พบว่าทำได้ดีในการทำนายไซส์ 3L และทำได้แย่ที่สุดในไซส์ 2L จากค่า F1-Score

โดยผลการทดสอบการคัดแยกไซส์ (2S, S, M, L, 2L, 3L) ของมะม่วงน้ำดอกไม้พบว่าโมเดล ANN มีความแม่นยำจากค่า Train Accuracy = 79.878% และเมื่อนำไปทดสอบกับชุดข้อมูล Unseen Data มีค่า Test Accuracy = 87.0% ซึ่งการที่ผลเป็นเช่นนี้ อาจจะบ่งบอกถึงการเกิดปัญหา Underfitting คือ โมเดลไม่มีความซับซ้อนเกิดการเรียนรู้ที่ง่ายเกินไป แต่โมเดลอาจจะมีการเลือกฟีเจอร์ที่ดีจึงทำให้โมเดลสามารถทำงานได้ดีกับชุดข้อมูลทดสอบหรือชุดข้อมูล Unseen Data

ดังนั้น จึงมีการตรวจสอบปัญหาเพื่อให้แน่ใจว่าโมเดลเกิดปัญหา Underfitting หรือไม่ ด้วยการปรับค่า Hyperparameter ที่สำคัญ ได้แก่ อัตราการเรียนรู้ (Learning Rate) จำนวนชั้น (Layer) และจำนวน Epochs เป็นต้น ผลลัพธ์ที่ได้คือ ค่า Test Accuracy ที่สูงกว่าค่า Train Accuracy อาจแสดงว่าโมเดลมีความสามารถในการทำนายได้ดี และไม่ได้เรียนรู้ข้อมูลจากชุดการฝึกได้มากเกินไปจนเกิดการ Overfitting ซึ่งเมื่อนำชุดข้อมูลมาทดสอบพบว่าการทำนายไซส์ที่ผิดพลาดมักจะทายผิดกับมะม่วงที่มีช่วงขนาดที่อยู่ระหว่างการเปลี่ยนไซส์ และมะม่วงที่มีรอยตำหนิเกิดที่ขอบจะทำให้ความสามารถในการสกัดพีเจอร์ของโมเดลลดลง

มะม่วงที่อยู่ระหว่างการเปลี่ยนไซส์ หมายถึง มะม่วงที่มีช่วงน้ำหนักที่อยู่ใกล้กับค่าน้ำหนักที่ต่ำที่สุดหรือสูงที่สุดของไซส์นั้นๆ เมื่อมะม่วงสุก จะเกิดการเปลี่ยนแปลงปฏิกิริยาทางชีวเคมีโดยเกิดกระบวนการเปลี่ยนแป้งเป็นน้ำตาล จึงทำให้มะม่วงสุกนั้นมีรสหวาน แต่ในขณะเดียวกันจะทำให้มะม่วงนั้นมีน้ำหนักลดลง ซึ่งตัวอย่างการเก็บบันทึกข้อมูลมะม่วงน้ำดอกไม้สุกโดยทำการวัดขนาดและชั่งน้ำหนักทั้งหมด 3 ครั้งโดยแต่ละครั้งห่างกัน 2 วัน แสดงดังตารางที่ 4.4 การเปลี่ยนแปลงน้ำหนักของมะม่วงน้ำดอกไม้

ตารางที่ 4.4 การเปลี่ยนแปลงน้ำหนักของมะม่วงน้ำดอกไม้

วัดขนาดและชั่งน้ำหนักครั้งที่ 1 วันที่ 14 มีนาคม พ.ศ. 2567

ลำดับ	ครั้งที่ 1				
	กว้าง	ยาว	สูง	น้ำหนัก	ไซส์
1	8.02	16.16	6.63	405	2L
2	7.53	14.66	6.42	345	L
3	8.04	16.97	7.21	480	3L

วัดขนาดและชั่งน้ำหนักครั้งที่ 2 วันที่ 16 มีนาคม พ.ศ. 2567

ลำดับ	ครั้งที่ 2				
	กว้าง	ยาว	สูง	น้ำหนัก	ไซส์
1	7.93	16.10	6.47	390	2L
2	7.50	14.60	6.22	335	L
3	8.00	16.93	7.09	460	3L

วัดขนาดและชั่งน้ำหนักครั้งที่ 3 วันที่ 19 มีนาคม พ.ศ. 2567

ลำดับ	ครั้งที่ 3				
	กว้าง	ยาว	สูง	น้ำหนัก	ไซส์
1	7.85	16.04	6.20	370	L
2	7.45	14.50	5.97	315	M
3	7.85	16.82	6.75	440	2L

จากตารางที่ 4.4 ในการวัดขนาดและชั่งน้ำหนักทั้งหมด 3 ครั้ง จะเห็นว่าเมื่อเวลาผ่านไปขนาดของมะม่วงน้ำดอกไม้สุกจะลดลง และน้ำหนักก็ลดลงเช่นเดียวกัน จึงทำให้เมื่อเวลาผ่านไปไซส์ของมะม่วงจะเปลี่ยนตามไปด้วยซึ่งมีขนาดลดลง โดยมะม่วงที่มีน้ำหนักในช่วงอยู่ระหว่างไซส์ หากไม่คำนึงถึงวันเก็บเกี่ยวอาจจะทำให้เสี่ยงต่อการอาจจะทำให้ชุดข้อมูลมะม่วงที่มีขนาดเท่ากัน แต่มีน้ำหนักที่ไม่เท่ากัน เนื่องจากอายุวันเก็บเกี่ยวและความสุกมากน้อย ทำให้เกิดความคลาดเคลื่อนหรือการทำนายที่ผิดพลาดในโมเดลได้ โดยเฉลี่ยแล้วน้ำหนักของมะม่วงเมื่อเริ่มมีการสุกน้ำหนักจะลดลงวันละ 5 – 10 กรัมต่อวัน

ดังนั้น ในการฝึกฝนโมเดลการตัดแยกไซส์ของมะม่วงน้ำดอกไม้ด้วยเทคนิคปัญญาประดิษฐ์ซึ่งใช้ฟีเจอร์ของความกว้างและความยาวของมะม่วงน้ำดอกไม้จึงต้องคำนึงถึงอายุของมะม่วงและวันที่เก็บเกี่ยวมะม่วง เพื่อชุดข้อมูลสำหรับฝึกฝนและทดสอบเป็นไปได้อย่างดี และมีความแม่นยำที่สูงขึ้น

4.3 ผลการทดสอบการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้

การทดสอบการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้เป็นส่วนที่ 3 ของงานวิจัยนี้ ซึ่งผลการทดสอบการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้ด้วยเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network : CNN) สามารถตัดแยกคุณภาพของมะม่วงน้ำดอกไม้แบ่งออกเป็น 2 Class ได้แก่ มะม่วงดี และมะม่วงเสีย ซึ่งผลประเมินประสิทธิภาพการฝึกฝนโมเดลด้วย Confusion Matrix รูปที่ 4.8 Confusion Matrix ของการ Train Model CNN สำหรับการตัดแยกคุณภาพ

Actual	Good	176	4
	Not Good	10	170
		Good	Not Good
		Predict	

รูปที่ 4.8 Confusion Matrix ของการ Train Model CNN สำหรับการคัดแยกคุณภาพ


จากตาราง Confusion Matrix จากการฝึกฝนโมเดล ดังรูปที่ 4.8 พบว่ามีค่าความแม่นยำ (Accuracy) Train Accuracy = 96.11 % โมเดลมีความผิดพลาดในการทำนายคลาสของมะม่วงเสีย ในส่วนของ FN (False Negative) คือการทำนายมะม่วงเสียเป็นมะม่วงดี ซึ่งมักจะหายผิดในรูปภาพ ที่มีจุดตำหนิที่เล็กมาก นอกจากนี้สามารถพิจารณาประเมินประสิทธิภาพของโมเดลได้จากค่า Precision Recall และ F1-Score แสดงดังตารางที่ 4.5 ดังนี้

ตารางที่ 4.5 ผลการทดสอบการฝึกฝนการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้


คุณภาพของมะม่วง	Precision	Recall	F1-Score
มะม่วงดี	0.946	0.978	0.962
มะม่วงเสีย	0.977	0.944	0.960

จากผลการทดสอบการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้พบว่าทั้งมะม่วงดีและม่วงเสียมีความสามารถในการทำนายที่ดีโดยพิจารณาจากค่า F1-Score

ผลจากการฝึกฝนโมเดลสามารถแสดงกราฟความสัมพันธ์ระหว่าง Training Loss กับ Validation Loss แสดงดังในรูปที่ 4.9 และ Train Accuracy กับ Validation Accuracy แสดงดังในรูปที่ 4.10 ดังนี้



รูปที่ 4.9 กราฟความสัมพันธ์ระหว่าง Train Loss กับ Validation Loss ของโมเดล CNN



รูปที่ 4.10 กราฟความสัมพันธ์ระหว่าง Train Accuracy กับ Validation Accuracy ของโมเดล CNN

จากรูปที่ 4.9 และ 4.10 เมื่อทำการวิเคราะห์พฤติกรรมของกราฟพบว่าในช่วงแรกโมเดลสามารถเรียนรู้ได้ดี และหลังจากนั้นโมเดลเริ่มมีเสถียรภาพจากกราฟ Accuracy ที่มีความใกล้เคียงกัน ทั้ง Train Accuracy และ Validation Accuracy ในขณะเดียวกัน Training Loss และ Validation Loss ลดลงและลู่เข้าหากัน ซึ่งหมายถึงการที่โมเดลไม่เกิดการ Overfitting เนื่องจากการใช้ Early-Stop และโมเดลมีประสิทธิภาพที่ใกล้เคียงกันในทั้งสองชุดข้อมูล แสดงถึงการปรับค่า


Hyperparameters อย่างเหมาะสม มีความสามารถในการเรียนรู้และทำนายได้ดี ทำให้มีความ Generalization ที่ดี ซึ่งเป็นสิ่งที่ต้องการในกระบวนการฝึกโมเดล

จากผลการฝึกฝนโมเดลการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ เมื่อนำมาทดสอบกับชุดข้อมูลที่ไม่เคยเห็นมาก่อนหรือ Unseen Data พบว่ามีค่าความแม่นยำ (Accuracy) Testing Accuracy = 93.00% ซึ่งแสดงผลได้เป็น Confusion Matrix รูปที่ 4.11 Confusion Matrix ของการ Testing Model CNN สำหรับการคัดแยกคุณภาพ

Actual	Good	50	0
	Not Good	7	43
		Good	Not Good
		Predict	

รูปที่ 4.11 Confusion Matrix ของการ Testing Model CNN สำหรับการคัดแยกคุณภาพ

จากรูปที่ 4.11 แสดงถึง Confusion Matrix ของการ Testing Model CNN สำหรับการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้พบว่ามีคามผิดพลาดในการทำนายคลาสของมะม่วงเสีย ในส่วนของ FN (False Negative) คือการทำนายมะม่วงเสียเป็นมะม่วงดี มักจะเกิดกับมะม่วงที่มีตำหนิเล็กๆ มักจะเป็นจุดดำ แสดงดังรูปที่ 4.12 ซึ่งเป็นอาการเริ่มต้นของโรคแอนแทรกคโนส หรืออาจจะเป็นตำหนิจากแมลงและโรคอื่นๆ



รูปที่ 4.12 ตัวอย่างการทำนายผิดในคลาสของมะม่วงเสียที่เป็น False Negative

โดยจาก Confusion Matrix แล้ว สามารถประเมินประสิทธิภาพ ของโมเดลด้วยค่า Precision Recall และ F1-Score ตารางที่ 4.6 แสดงผลการทดสอบการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้


ตารางที่ 4.6 ผลการทดสอบการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้ด้วยชุดข้อมูล Unseen Data

คุณภาพของมะม่วง	Precision	Recall	F1-Score
มะม่วงดี	0.88	1.00	0.93
มะม่วงเสีย	1.00	0.86	0.92

จากผลการทดลองการตัดแยกคุณภาพมะม่วงโดยใช้เทคนิคการเรียนรู้เชิงลึก พบว่าโมเดล CNN ให้ค่าความแม่นยำ Train Accuracy = 96.11% และเมื่อทดสอบด้วยชุดข้อมูล Unseen Data พบว่ามีค่า Test Accuracy = 93.0% โดยเมื่อตรวจสอบจาก Confusion Matrix พบว่ามีการทำนายมะม่วงเสียเป็นมะม่วงดี ซึ่งมะม่วงเสียนั้นมีตำหนิที่มีขนาดเล็กเป็นรอยตำหนิที่ผิวและเป็นจุดดำที่เกิดจากการเริ่มต้นของโรคแอนแทรกคโนสในมะม่วงน้ำดอกไม้สุกได้

จากการทดสอบและวิเคราะห์ผลของทั้ง 3 โมเดล ได้แก่ โมเดลการประมาณขนาด โมเดลการตัดแยกไซส์ และโมเดลการตัดแยกคุณภาพ พบว่า โมเดลการประมาณขนาด มีความแม่นยำในการ

ทำนายสูงกว่าร้อยละ 90 โดยสิ่งที่ทำให้เกิดความคลาดเคลื่อนในการประมาณขนาด ได้แก่ ตำแหน่งการวางวัตถุ และความสว่างในการเก็บข้อมูลสำหรับชุดการฝึกฝน (Datasets) และขณะทำการทดสอบ โมเดลการตัดแยกไซส์มีความแม่นยำในการทำนายสูงกว่าร้อยละ 85 ซึ่งการตัดไซส์สำหรับมาตรฐานการส่งออกมะม่วงน้ำดอกไม้จะถูกแบ่งด้วยน้ำหนัก ดังนั้น การคัดเลือกมะม่วงน้ำดอกไม้สำหรับเก็บข้อมูลเป็นชุดการฝึกฝนควรมีอายุวันที่ใกล้เคียงกัน เพื่อให้การตัดแยกไซส์มีความแม่นยำมากขึ้น และโมเดลการตัดแยกคุณภาพ มีความแม่นยำในการทำนายสูงกว่าร้อยละ 85 ซึ่งสิ่งทำให้เกิดความคลาดเคลื่อนในการทำนายมักจะเกิดจากมะม่วงที่มีจุดตำหนิเล็ก ๆ ซึ่งในการประเมินประสิทธิภาพของโมเดลแสดงให้เห็นถึงความแม่นยำที่โดดเด่นในการประมาณขนาด การตัดไซส์และคุณภาพ ซึ่งสามารถนำไปสู่การพัฒนาคุณภาพและความแม่นยำในการดำเนินงานอย่างมีประสิทธิภาพ



บทที่ 5

สรุปผลการวิจัย

5.1 สรุปผลการวิจัย

งานวิจัยนี้นำเสนอวิธีการประมาณขนาด การตัดแยกไซส์ การตัดแยกคุณภาพของมะม่วง น้ำดอกไม้พันธุ์สีทองด้วยเทคนิคปัญญาประดิษฐ์ ซึ่งมีการใช้เทคนิคต่างๆร่วมกัน งานวิจัยจึงมีรายละเอียดสรุปดังนี้

การประมาณขนาดของมะม่วงน้ำดอกไม้ ใช้เทคนิคใช้ประมวลผลภาพ (Image Processing) โดยใช้วิธีการตรวจจับขอบด้วยเทคนิคแคนนี่ (Canny Edge Detection) ใช้การมองเห็นด้วยเห็นด้วย คอมพิวเตอร์หรือคอมพิวเตอร์วิชัน (Computer Vision) โดยใช้ Library OpenCV ซึ่งใช้พีเจอร์ในการ ค้นหาขอบเขต (Contours) ในการประมาณความกว้างและความยาว และใช้เทคนิคการถดถอยเชิง เส้นพหุคูณ (Multiple Linear Regression) ในการประมาณความสูง โดยผลจากการทำนายด้วย โปรแกรมมีค่า R-Square (R^2) ของความกว้างอยู่ที่ 0.9985 ความยาวอยู่ที่ 0.9987 และความสูงอยู่ที่ 0.9948 ซึ่งพบว่าโปรแกรมหรือโมเดลนี้มีค่าความแม่นยำมากกว่า 90% สามารถใช้ในการประมาณ ขนาดจริง ซึ่งเมื่อได้ขนาดของมะม่วงน้ำดอกไม้แล้ว จึงทำการตัดแยกไซส์ของมะม่วงน้ำดอกไม้ซึ่ง ประกอบด้วยทั้งหมด 6 ไซส์ ได้แก่ 2S, S, M, L, 2L และ 3L โดยใช้เทคนิคการเรียนรู้เชิงลึกโดยใช้วิธี โครงข่ายประสาทเทียม (Artificial Neural Network : ANN) ซึ่งจะทำการทำนายไซส์ด้วยการการ สกัดพีเจอร์จากความกว้างและความยาวในหน่วยพิกเซล โดยผลจากการฝึกฝนโมเดลมีค่า Training Accuracy อยู่ที่ 79.878% ซึ่งแสดงถึงความสามารถของโมเดลในการเรียนรู้จากข้อมูลฝึกฝน แม้ว่า โมเดลจะมีประสิทธิภาพที่ดีในขั้นตอนการฝึก แต่ผลลัพธ์ที่แท้จริงของโมเดลสามารถวัดได้จากการ ทดสอบกับข้อมูลที่ไม่เคยเห็นมาก่อน (Unseen Data) และเมื่อทดสอบโมเดลกับชุดข้อมูล Unseen Data มีค่า Testing Accuracy อยู่ที่ 87.0% ซึ่งแสดงให้เห็นว่าโมเดลสามารถประมวลผลและทำนาย ขนาดของมะม่วงจากภาพใหม่ ๆ ได้อย่างมีประสิทธิภาพและแม่นยำ และจากนั้นทำการตัดแยก คุณภาพของมะม่วงน้ำดอกไม้ ด้วยเทคนิคการเรียนรู้เชิงลึกโดยใช้วิธีโครงข่ายประสาทเทียมแบบคอน โวลูชัน (Convolutional Neural Network : CNN) ซึ่งเป็นการใช้รูปภาพ โดยมีการปรับแต่งและเพิ่ม ประสิทธิภาพของโมเดลผ่านการเลือกค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม หลังจากการฝึกฝนแล้วซึ่งผล จากการฝึกฝนโมเดลมีค่า Training Accuracy อยู่ที่ 96.11% และเมื่อทดสอบโมเดลกับชุดข้อมูล Unseen Data มีค่า Testing Accuracy อยู่ที่ 93.0%

การประมาณขนาด การตัดแยกไซส์ และการตัดแยกคุณภาพของมะม่วงน้ำดอกไม้ด้วยการใช้เทคนิคปัญญาประดิษฐ์สามารถนำไปใช้ได้จริง ได้พิสูจน์ให้เห็นถึงความสามารถในการนำเทคโนโลยีไปใช้งานได้จริงในอุตสาหกรรม ด้วยการใช้กล้องเว็บแคมเป็นเครื่องมือหลักในการตรวจสอบแทนการใช้สายตามนุษย์ ข้อดีของการใช้กล้องเว็บแคมคือสามารถติดตั้งและใช้งานในพื้นที่ที่มีข้อจำกัดในการเข้าถึงของมนุษย์ เช่น ห้องที่มีการฉายรังสี ทั้งนี้ เมื่อนำการประมาณขนาดไปใช้กับการฉายรังสีจะช่วยลดพลังงานและลดต้นทุนในการฉายรังสี ซึ่งจะช่วยลดต้นทุนและเพิ่มกำไรในการส่งออกมะม่วงน้ำดอกไม้ และนอกจากนี้การใช้งานกล้องเว็บแคมร่วมกับเทคนิคปัญญาประดิษฐ์สามารถตัดแยกไซส์และแยกคุณภาพของมะม่วงน้ำดอกไม้ได้ ดังนั้น การนำเทคโนโลยีนี้มาใช้ไม่เพียงแต่จะช่วยลดต้นทุนการผลิต แต่ยังเป็นการเพิ่มคุณภาพของผลิตภัณฑ์ที่ส่งออกอีกด้วย

5.2 ข้อเสนอแนะ

5.2.1 การใช้เลือกมะม่วงน้ำดอกไม้สำหรับเก็บข้อมูลชุดทดสอบ (Datasets) มะม่วงควรเลือกมะม่วงที่มีอายุและจำนวนวันที่แน่นอน เนื่องจากอายุของมะม่วงส่งผลต่อขนาดและน้ำหนัก และควรเลือกมะม่วงที่มีอายุ (จำนวนวันที่) ที่ใกล้เคียงกันในการนำมาทดลองและทดสอบ

5.2.2 การถ่ายภาพมะม่วงควรถ่ายให้ครบทุกด้านเพื่อที่จะได้สร้างโมเดลตรวจสอบตำหนิได้ครบทุกมุมมอง และการทดสอบหรือการนำไปใช้อาจจะมีการติดกล้อง 4 ด้าน เพื่อที่จะได้โมเดลสามารถทำงานได้อย่างที่มีความแม่นยำมากขึ้น

5.2.3 การถ่ายภาพด้วยกล้องเว็บแคมหรือการใช้กล้องในการเก็บข้อมูล Datasets ต้องมีการควบคุมแสงสว่างให้สม่ำเสมอและมีค่าความสว่างที่ใกล้เคียงกันทุกครั้ง

รายการอ้างอิง

- [1] Shah KA, Patel MB, Patel RJ, Parmar PK. *Mangifera indica* (mango). *Pharmacogn Rev.* 2010 Jan;4(7):42-8. doi: 10.4103/0973-7847.65325. PMID: 22228940; PMCID: PMC3249901.
- [2] Sitah F. Alanazi, Evaluating the effect of X-ray irradiation in the control of food bacterial pathogens, *Journal of King Saud University - Science*, Volume 35, Issue 1, 2023, 102367, ISSN 1018-3647, <https://doi.org/10.1016/j.jksus.2022.102367>.
- [3] Yeong-Seok Yoon, Kashif Ameer, Beom-Seok Song, Jae-Kyung Kim, Ha-Young Park, Ki-Chang Lee, Jong-Bang Eun, Jong-Heum Park, Effects of X-ray irradiation on the postharvest quality characteristics of 'Maehyang' strawberry (*Fragaria x ananassa*), *Food Chemistry*, Volume 325, 2020, 126817, ISSN 0308-8146, <https://doi.org/10.1016/j.foodchem.2020.126817>.
- [4] Katrin Utai, Marcus Nagle, Simone Hämmerle, Wolfram Spreer, Busarakorn Mahayothee, Joachim Müller, Mass estimation of mango fruits (*Mangifera indica* L., cv. 'Nam Dokmai') by linking image processing and artificial neural network, *Engineering in Agriculture, Environment and Food*, Volume 12, Issue 1, 2019, Pages 103-110, ISSN 1881-8366, <https://doi.org/10.1016/j.eaef.2018.10.003>.
- [5] S. Anjanayya, S. P. Sai, S. S. Vardhan, S. Vivek, A. Vaishnavi and V. Ashwanthi, "Object size measurement using open CV (Computer Vision)," 2023 International Conference on Research Methodologies in Knowledge Management, Artificial Intelligence and Telecommunication Engineering (RMKMATE), Chennai, India, 2023, pp. 1-6, doi: 10.1109/RMKMATE59243.2023.10369151.
- [6] P. Topno and G. Murmu, "An Improved Edge Detection Method based on Median Filter," 2019 Devices for Integrated Circuit (DevIC), Kalyani, India, 2019, pp. 378-381, doi: 10.1109/DEVIC.2019.8783450.

- [7] S. Khadane, S. Saini, S. Mittal and K. Sharma, "Real-Time Object Size Dimensioning in Raspberry Pi," 2022 7th International Conference on Communication and Electronics Systems (ICCES), Coimbatore, India, 2022, pp. 344-348, doi: 10.1109/ICCES54183.2022.9836005.
- [8] N. D. Thong, N. T. Thinh and H. T. Cong, "Mango Classification System Uses Image Processing Technology and Artificial Intelligence," 2019 International Conference on System Science and Engineering (ICSSE), Dong Hoi, Vietnam, 2019, pp. 45-52, doi: 10.1109/ICSSE.2019.8823119.
- [9] Thanh-Nghi Doan and Duc-Ngoc Le-Thi, "A Novel Mango Grading System Based on Image Processing and Machine Learning Methods" International Journal of Advanced Computer Science and Applications (IJACSA), 14(5), 2023. <http://dx.doi.org/10.14569/IJACSA.2023.01405115>.
- [10] S. Bagchi, J. V. Aditya, S. Kumari, M. Dhanraj and M. Jenamani, "A Machine Learning-based Approach for Automatic Grading and Quality Inspection of Indian Mangoes," 2023 IEEE 2nd Industrial Electronics Society Annual On-Line Conference (ONCON), SC, USA, 2023, pp. 1-8, doi: 10.1109/ONCON60463.2023.10430932.
- [11] ElGendy, M. (2020). Deep Learning for Vision Systems. Shelter Island: Manning Publications Co. ISBN: 9781617296192.
- [12] Bradski, G., & Kaehler, A. (2008). Learning OpenCV. O'Reilly Media, Inc.
- [13] Aggarwal, C. C. (2018). Neural Networks and Deep Learning: A Textbook. IBM T. J. Watson Research Center, International Business Machines. New York, NY, USA: Springer International Publishing AG. <https://doi.org/10.1007/978-3-319-94463-0>.
- [14] Jocher, G., Laughing-q, AyushExel, & fcakyon. (2023-11-12). YOLOv8: Ultralytics. <https://docs.ultralytics.com/models/yolov8/>



ภาคผนวก ก

ตารางข้อมูลดิบจากการวัดขนาดและชั่งน้ำหนักมะม่วงน้ำดอกไม้

มหาวิทยาลัยเทคโนโลยีสุรนารี

ในงานวิจัยนี้ใช้มะม่วงน้ำดอกไม้พันธุ์สีทองสุกจำนวนทั้งหมด 61 ลูก ซึ่งแสดงข้อมูลการวัดขนาด และชั่งน้ำหนัก เพื่อเก็บเป็นชุดข้อมูลสำหรับการพัฒนาโมเดลและทดสอบโมเดลด้วยเทคนิคปัญญาประดิษฐ์ ดังตาราง ก.1 ดังนี้

ตาราง ก.1 ข้อมูลดิบจากการวัดขนาดและชั่งน้ำหนักมะม่วงน้ำดอกไม้

ลำดับ	กว้าง (Width : cm)	ยาว (Length : cm)	สูง (Depth : cm)	น้ำหนัก (g)	ไซส์
1	7.59	15.90	6.30	355	L
2	7.80	16.60	6.60	420	LL
3	8.80	17.90	7.10	560	LLL
4	8.40	17.10	6.60	435	LL
5	7.05	14.75	6.25	320	M
6	6.52	13.80	5.73	250	S
7	7.18	14.36	6.06	310	M
8	7.16	14.22	6.08	300	M
9	7.09	14.15	6.33	300	M
10	6.97	13.78	6.09	290	M
11	7.33	15.20	6.33	330	L
12	7.50	14.92	6.15	345	L
13	7.70	15.69	6.62	390	LL
14	8.19	16.30	6.65	415	LL
15	7.65	15.56	6.33	370	L
16	8.20	16.47	7.08	455	LLL
17	8.34	16.71	6.85	470	LLL
18	8.00	15.45	6.91	405	LL
19	6.92	15.60	5.97	320	M
20	7.22	15.28	6.20	330	L
21	8.06	16.25	7.12	465	LLL
22	7.87	16.30	7.10	440	LL
23	8.17	16.20	6.95	480	LLL
24	7.33	15.00	6.50	360	L
25	7.25	15.18	6.68	370	L
26	6.60	15.17	6.09	295	M
27	7.02	13.25	6.04	270	S

ตาราง ก.1 ข้อมูลดิบจากการวัดขนาดและชั่งน้ำหนักมะม่วงน้ำดอกไม้ (ต่อ)

ลำดับ	กว้าง (Width : cm)	ยาว (Length : cm)	สูง (Depth : cm)	น้ำหนัก (g)	ไซส์
28	7.04	12.97	6.00	260	S
29	6.34	14.00	5.99	280	M
30	6.65	13.54	5.93	265	S
31	6.67	13.56	5.86	260	S
32	6.74	13.75	6.25	285	M
33	6.56	13.72	5.78	245	SS
34	6.42	12.92	5.20	225	SS
35	7.08	12.55	6.00	250	S
36	6.88	12.57	6.30	270	S
37	6.80	13.85	5.93	275	S
38	6.85	13.82	6.20	265	S
39	6.32	13.93	5.77	245	SS
40	6.70	13.70	5.75	270	S
41	6.80	13.72	6.00	270	S
42	6.92	13.75	6.46	305	M
43	6.90	13.46	6.20	285	M
44	6.55	12.83	5.82	235	SS
45	6.68	12.98	6.13	260	S
46	6.85	13.62	6.16	280	M
47	6.64	13.20	6.10	270	S
48	6.59	12.45	5.72	230	SS
49	6.67	12.77	5.66	225	SS
50	7.10	12.57	6.24	265	S
51	6.87	12.69	6.16	265	S
52	6.82	12.56	6.25	255	S
53	6.73	12.44	5.90	235	SS
54	6.79	13.07	6.10	255	S
55	6.60	12.25	6.00	245	SS
56	6.60	12.94	5.97	245	SS
57	6.59	12.16	5.98	245	SS
58	6.78	12.35	5.85	245	SS
59	6.50	13.48	5.86	260	S
60	6.50	12.90	6.00	255	S
61	6.52	13.33	5.92	245	SS



ภาคผนวก ข

ตารางบันทึกผลการทดสอบโมเดลการประมาณขนาด การตัดแยกไซส์
และการตัดแยกคุณภาพ

มหาวิทยาลัยเทคโนโลยีสุรนารี

ในงานวิจัยนี้ได้มีการฝึกฝนโมเดล โดยแบ่งออกเป็น 3 ส่วน ได้แก่ การประมาณขนาดของมะม่วงน้ำดอกไม้ (กว้าง ยาว สูง) การตัดแยกไซส์ของมะม่วงน้ำดอกไม้ และการตัดแยกคุณภาพ (ดี-เสีย) ของมะม่วงน้ำดอกไม้ ซึ่งเมื่อฝึกฝนโมเดลครบทั้ง 3 ส่วนแล้ว ทำการทดสอบโมเดลด้วยชุดข้อมูลที่ไม่เคยเห็นมาก่อน (Unseen Data) ซึ่งผลลัพธ์จากการทำนายเปรียบเทียบกับของจริงที่วัดได้ (ผลเฉลี่ย) แสดงดังตาราง ข.1 ดังนี้

ตาราง ข.1 ผลการทดสอบโมเดลการประมาณขนาด การตัดแยกไซส์ และการตัดแยกคุณภาพ

ลำดับ	ขนาดจริงที่วัดได้ (cm: เซนติเมตร)			ขนาดที่ทำนายด้วยโปรแกรม (cm: เซนติเมตร)			การตัดไซส์		การตัดคุณภาพ	
	กว้าง	ยาว	สูง	กว้าง	ยาว	สูง	ของจริง	ทำนาย	ของจริง	ทำนาย
1	7.59	15.90	6.30	7.35	15.51	6.40	L	L	NG	NG
2	7.80	16.60	6.60	7.98	16.94	6.21	LL	2L	NG	NG
3	8.80	17.90	7.10	9.76	18.70	5.96	LLL	3L	G	G
4	8.80	17.90	7.10	8.61	18.04	7.49	LLL	3L	NG	NG
5	8.80	17.90	7.10	8.72	18.92	7.97	LLL	3L	NG	NG
6	8.80	17.90	7.10	8.72	18.26	7.47	LLL	3L	NG	NG
7	6.52	13.80	5.73	6.93	14.19	6.16	S	M	G	G
8	6.52	13.80	5.73	6.40	13.64	5.87	S	S	G	G
9	6.52	13.80	5.73	6.93	13.86	6.19	S	M	G	G
10	6.52	13.80	5.73	6.93	13.86	6.19	S	M	G	G
11	6.52	13.80	5.73	6.72	13.75	5.92	S	S	G	G
12	6.52	13.80	5.73	6.72	13.75	5.92	S	S	G	G
13	6.52	13.80	5.73	6.72	14.30	5.81	S	S	G	G
14	6.52	13.80	5.73	6.72	13.75	5.92	S	S	G	G
15	6.52	13.80	5.73	6.93	13.75	6.21	S	M	G	G
16	6.52	13.80	5.73	6.93	14.19	6.16	S	M	G	G
17	6.52	13.80	5.73	6.72	13.75	5.92	S	S	NG	G
18	7.18	14.36	6.06	7.88	14.63	6.09	M	L	NG	NG
19	8.40	17.10	6.60	8.19	16.72	7.24	LL	3L	NG	NG
20	7.33	15.20	6.33	7.67	14.41	6.17	L	L	NG	NG
21	8.19	16.30	6.65	8.19	16.39	6.99	LL	3L	NG	NG
22	8.19	16.30	6.65	8.50	16.28	6.35	LL	2L	NG	NG
23	7.65	15.56	6.33	7.56	16.17	6.35	L	2L	NG	G
24	7.65	15.56	6.33	7.98	15.95	6.14	L	L	G	G

ตาราง ข.1 ผลการทดสอบโมเดลการประมาณขนาด การคัดแยกไซส์ และการคัดแยกคุณภาพ (ต่อ)

ลำดับ	ขนาดจริงที่วัดได้ (cm: เซนติเมตร)			ขนาดที่ทำนายด้วยโปรแกรม			การคัดไซส์		การคัดคุณภาพ	
	กว้าง	ยาว	สูง	กว้าง	ยาว	สูง	ของจริง	ทำนาย	ของจริง	ทำนาย
25	7.65	15.56	6.33	7.46	16.06	6.39	L	2L	NG	NG
26	7.65	15.56	6.33	7.56	16.06	6.34	L	2L	NG	NG
27	7.65	15.56	6.33	7.77	16.06	6.24	L	L	NG	NG
28	7.65	15.56	6.33	7.98	16.50	6.18	L	2L	NG	NG
29	7.65	15.56	6.33	7.46	15.95	6.38	L	L	NG	NG
30	7.65	15.56	6.33	7.35	16.28	6.46	L	2L	G	G
31	7.65	15.56	6.33	7.88	16.06	6.20	L	2L	NG	G
32	8.34	16.71	6.85	9.14	17.27	5.99	LLL	3L	NG	NG
33	8.00	15.45	6.91	8.30	15.07	5.81	LL	L	NG	NG
34	8.00	15.45	6.91	8.19	16.50	7.07	LL	3L	NG	NG
35	6.92	15.60	5.97	6.72	15.84	5.52	M	M	NG	NG
36	6.92	15.60	5.97	7.04	16.50	5.95	M	L	G	G
37	6.92	15.60	5.97	6.93	16.61	5.93	M	L	NG	NG
38	6.92	15.60	5.97	6.72	15.95	5.50	M	M	G	G
39	7.87	16.30	7.10	8.40	15.62	6.04	LL	2L	NG	NG
40	7.87	16.30	7.10	8.08	16.28	7.09	LL	3L	NG	NG
41	7.25	15.18	6.68	7.67	14.96	6.21	L	L	NG	NG
42	7.25	15.18	6.68	7.46	15.62	6.36	L	L	NG	NG
43	6.60	15.17	6.09	6.51	15.29	5.58	M	S	G	G
44	6.60	15.17	6.09	6.93	15.84	6.00	M	L	G	G
45	7.02	13.25	6.04	7.25	12.76	6.25	S	M	G	G
46	7.02	13.25	6.04	7.56	13.53	6.16	S	M	G	G
47	7.02	13.25	6.04	7.46	13.53	6.20	S	M	G	G
48	7.02	13.25	6.04	7.35	13.42	6.25	S	M	G	G
49	6.34	14.00	5.99	6.30	14.85	5.65	M	S	G	G
50	6.34	14.00	5.99	6.19	15.07	5.58	M	S	G	G
51	6.34	14.00	5.99	6.19	15.18	5.58	M	S	G	G
52	6.34	14.00	5.99	6.40	15.18	5.58	M	S	G	G
53	6.65	13.54	5.93	6.51	13.86	5.85	S	S	NG	NG
54	6.65	13.54	5.93	6.72	14.52	5.77	S	S	NG	NG
55	6.65	13.54	5.93	6.83	14.08	6.16	S	M	NG	NG

ตาราง ข.1 ผลการทดสอบโมเดลการประมาณขนาด การคัดแยกไซส์ และการคัดแยกคุณภาพ (ต่อ)

ลำดับ	ขนาดจริงที่วัดได้ (cm: เซนติเมตร)			ขนาดที่ทำนายด้วยโปรแกรม			การคัดไซส์		การคัดคุณภาพ	
	กว้าง	ยาว	สูง	กว้าง	ยาว	สูง	ของจริง	ทำนาย	ของจริง	ทำนาย
56	6.65	13.54	5.93	6.93	13.97	6.18	S	M	G	G
57	6.65	13.54	5.93	7.14	14.08	6.21	S	M	G	G
58	6.65	13.54	5.93	6.61	13.86	5.87	S	S	G	G
59	6.65	13.54	5.93	6.72	13.86	5.89	S	S	NG	NG
60	6.67	13.56	5.86	6.51	13.97	5.83	S	S	NG	NG
61	6.67	13.56	5.86	6.72	13.53	5.96	S	S	NG	NG
62	6.42	12.92	5.20	6.51	13.09	6.00	SS	Out*	G	G
63	6.42	12.92	5.20	6.51	13.09	6.00	SS	Out*	NG	G
64	6.42	12.92	5.20	6.51	13.09	6.00	SS	Out*	NG	NG
65	6.42	12.92	5.20	6.51	13.09	6.00	SS	Out*	NG	NG
66	6.42	12.92	5.20	6.30	12.87	5.57	SS	2S	G	G
67	7.08	12.55	6.00	7.46	11.88	6.08	S	S	G	G
68	6.80	13.85	5.93	6.72	13.53	5.96	S	S	NG	G
69	6.85	13.82	6.20	7.04	13.53	6.24	S	M	G	G
70	6.32	13.93	5.77	6.19	14.30	5.54	SS	2S	NG	NG
71	6.70	13.70	5.75	6.83	13.64	6.20	S	M	NG	NG
72	6.80	13.72	6.00	6.61	13.42	5.96	S	S	G	G
73	6.55	12.83	5.82	6.40	12.21	6.14	SS	2S	G	G
74	6.55	12.83	5.82	6.72	12.76	6.10	SS	S	G	G
75	6.68	12.98	6.13	7.14	12.98	6.31	S	M	NG	NG
76	6.59	12.45	5.72	6.61	11.33	6.35	SS	2S	G	G
77	6.59	12.45	5.72	6.83	11.66	6.39	SS	S	G	G
78	6.59	12.45	5.72	6.61	11.44	6.33	SS	2S	G	G
79	6.67	12.77	5.66	6.40	12.54	6.08	SS	2S	NG	NG
80	6.67	12.77	5.66	6.93	12.76	6.30	SS	M	NG	NG
81	6.67	12.77	5.66	6.61	12.76	6.08	SS	S	NG	NG
82	6.67	12.77	5.66	7.04	12.21	6.37	SS	S	G	G
83	6.67	12.77	5.66	6.51	12.76	6.06	SS	2S	NG	NG
84	7.10	12.57	6.24	7.25	11.88	6.18	S	S	NG	NG
85	6.73	12.44	5.90	6.61	12.32	6.17	SS	2S	G	G
86	6.60	12.25	6.00	6.83	11.88	6.37	SS	S	G	G

ตาราง ข.1 ผลการทดสอบโมเดลการประมาณขนาด การคัดแยกไซส์ และการคัดแยกคุณภาพ (ต่อ)

ลำดับ	ขนาดจริงที่วัดได้ (cm: เซนติเมตร)			ขนาดที่ทำนายด้วยโปรแกรม			การคัดไซส์		การคัดคุณภาพ	
	กว้าง	ยาว	สูง	กว้าง	ยาว	สูง	ของจริง	ทำนาย	ของจริง	ทำนาย
87	6.60	12.94	5.97	6.51	12.76	6.06	SS	2S	G	G
88	6.59	12.16	5.98	6.72	11.99	6.25	SS	2S	NG	NG
89	6.59	12.16	5.98	6.61	12.10	6.21	SS	2S	NG	NG
90	6.78	12.35	5.85	7.04	12.10	6.38	SS	S	G	G
91	6.78	12.35	5.85	6.83	11.99	6.36	SS	S	NG	G
92	6.78	12.35	5.85	7.04	11.77	6.41	SS	S	G	G
93	6.78	12.35	5.85	7.04	11.77	6.41	SS	S	G	G
94	6.78	12.35	5.85	6.93	12.43	6.33	SS	S	NG	NG
95	6.78	12.35	5.85	6.93	11.66	6.41	SS	S	G	G
96	6.78	12.35	5.85	6.93	12.32	6.34	SS	S	G	G
97	6.78	12.35	5.85	6.83	12.10	6.35	SS	S	G	G
98	6.78	12.35	5.85	6.83	12.21	6.34	SS	S	G	G
99	6.78	12.35	5.85	6.83	11.99	6.36	SS	S	G	G
100	6.50	13.48	5.86	6.19	13.53	5.51	S	2S	NG	G

หมายเหตุ G คือ Good Mango (มะม่วงดี)

NG คือ Not Good Mango (มะม่วงเสีย)

Out* คือ Out of Range (การทำนายว่ามะม่วงไม่ผ่านเกณฑ์มาตรฐานหรือมีขนาดเล็กกว่าไซส์ SS)

มหาวิทยาลัยเทคโนโลยีสุรนารี



ภาคผนวก ค









รูปภาพผลการทดสอบโมเดลและโปรแกรม











ในงานวิจัยนี้ได้มีการทดสอบโมเดลแบ่งออกเป็น 3 ส่วน ได้แก่ การประมาณขนาดของมะม่วงน้ำดอกไม้ (กว้าง ยาว สูง) การตัดแยกไซส์ของมะม่วงน้ำดอกไม้ และการตัดแยกคุณภาพ (ดี-เสีย) ของมะม่วงน้ำดอกไม้ ซึ่งมีโปรแกรมในการสร้างและฝึกฝนโมเดล แสดงดังลิงค์ต่อไปนี้


Link: <https://drive.google.com/drive/folders/1qbmK00Qzw61Jv047CdEzo5lCHRXWSoeO?usp=sharing>

แสดงตัวอย่างรูปภาพรูปภาพผลการทดสอบโมเดล ดังนี้











ภาคผนวก ง

บทความที่ได้รับการตีพิมพ์เผยแพร่

รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในขณะศึกษา

Irin Wanthong, Theeraphat Sri-on Soontaree Seangsri Sorada Khaengkarn and Jiraphon Srisertpol (2024) Exploring classification, size, and quality of *Mangifera Indica* L. through image processing and AI techniques, International Conference on Mechanics Electronics Automation and Automatic Control (MEAAC2024), 8 PP.



Exploring classification, size, and quality of *Mangifera Indica* L. through image processing and AI techniques

Irin Wanthong^a, Theeraphat Sri-on^a, Soontaree Seangsri^b, Sorada Khaengkarn^a and Jiraphon Srisertpol^{a,1}

^a*Mechatronics Engineering Program, School of Mechanical Engineering, Suranaree University of Technology, Nakhon Ratchasima, Thailand*

^b*Department of Mechatronics and Robotics Engineering, School of Engineering and Innovation, Rajamangala University of Technology Tawan-ok, Chonburi, Thailand*

ORCID ID: Sorada Khaengkarn <https://orcid.org/0009-0007-3589-3215>

Abstract. This paper introduces methods for efficiently classifying mangoes intended for export, a market valued at approximately 4,500 million baht annually. The classification process is divided into two primary components: size categorization and quality assessment. The first phase involves categorizing mango sizes into four distinct categories (M, 1L, 2L, 3L), while the second phase focuses on assessing mango quality, particularly detecting anthracnose—a prevalent disease affecting mangoes. This detection is achieved through image processing techniques, where images are converted into binary representations and analyzed using both Artificial Neural Networks (ANNs) and Convolutional Neural Networks (CNNs). Comparative analysis reveals that CNN outperforms ANN in size classification, achieving a remarkable train accuracy of 99.16% and a test accuracy of 88.0%. Furthermore, in quality classification, CNN demonstrates a train accuracy of 91.0% and a test accuracy of 88.0%. These findings underscore the effectiveness of CNN techniques in accurately classifying mangoes for export, thereby facilitating improved quality control and market competitiveness.

Keywords. ANN, CNN, Image processing, Mango sorting

1. Introduction

Mangoes (*Mangifera indica*), belonging to the Anacardiaceae family, are native to South Asia and have gained widespread cultivation in tropical and subtropical regions globally. Renowned for their delectably sweet, occasionally tangy flavor and rich nutritional composition, mangoes are esteemed worldwide. With substantial levels of vitamins A and C, dietary fiber, and diverse antioxidants, mangoes offer significant health benefits, warranting further exploration of their bioactive compounds [1]. Thailand's mango industry holds considerable economic significance, contributing to both domestic and international markets. Mango cultivation sustains rural farmers and bolsters regional food security, while a substantial portion of the harvest undergoes processing into value-added products such as dried mango. At the international level,

¹ Corresponding Author: Jiraphon Srisertpol, jiraphon@sut.ac.th.

Thailand stands out as a prominent exporter of both fresh and processed mangoes, with annual export values surpassing 1 billion Baht [2]. Key export destinations encompass China, Japan, South Korea, and other Southeast Asian nations. To facilitate international trade and adhere to stringent quality standards, mangoes undergo sizing protocols before exportation. These protocols typically employ weight-based grading, physical measurements (such as circumference or length), or a combination thereof to categorize mangoes into standardized size classifications.

Machine vision equips computers with the capability to perceive and interpret visual data from the real world [3]. Complementarily, machine learning empowers computers to learn and enhance their performance autonomously, discerning patterns and making data-driven predictions without explicit instructions [4]. And has pioneered a vision system for mango sorting, leveraging 2D and 3D feature analysis. This approach not only achieves accuracy comparable to human sorting but also promises increased efficiency. Deep learning (DL) is reshaping fields like healthcare, as exemplified by Suzuki, and colleagues who utilize DL and activity recognition (AR) for automating the assessment of gross motor skills in children [5]. And has pioneered a vision system for mango sorting, leveraging 2D and 3D feature analysis. Their system evaluates size, volume, and surface area from multiple images, employing a neural network for mango classification by Chalidabhongse and colleagues [6]. Moreover, research in fault detection and classification (FDC) by analyzing mount head surface pixels illustrates proactive fault detection using an Artificial Neural Network (ANN) model, reducing machine downtime, and enhancing production reliability. [7]. Additionally, the development of a portable fruit grading machine using computer vision for small-scale agriculture by Hadha and colleagues captures video images from a webcam and analyze them to categorize fruit quality according to grade [8]. There is also research that aims to develop a smart mango classification system using image processing and artificial intelligence to automate the sorting process, reduce labor costs, and improve productivity in the mango industry [9]. This study showcases the utilization of artificial intelligence (AI) coupled with image processing to construct a model for the precise classification of mangoes into acceptable and defective categories. Moreover, the model endeavors to establish a system adept at sorting mangoes based on size specifications suitable for export and international trade. Employing two distinct types of AI—artificial neural networks (ANNs) and convolutional neural networks (CNNs)—the proposed model is thoroughly examined in terms of image selection for AI training, model development procedures, model functionalities, and system performance evaluation.

2. Method and materials

For the study on classifying mango categories (size and quality) for export, images of mangoes were captured using a webcam under controlled lighting conditions. Two lighting conditions. The images were then augmented by adjusting brightness by $\pm 5\%$. The Binary Algorithm was used for image processing, and the resulting images were used as datasets. The datasets were divided into three parts: Train 70% Test 15% and Validation 15% with additional Unseen data for model testing. The experiment was divided into two sections. Section 1 involved classifying mango sizes as M, 1L, 2L, and 3L using Artificial Neural Network (ANN) and Convolutional Neural Network (CNN) models. Section 2 involved mango quality assessment. The Architecture method is shown in Figure 1.




Figure 1. Architecture method.

2.1. *Mangifera Indica L.*

Mangos are the top fruit exported by Thailand. The ripe fruit is golden yellow, has a sweet aroma, and is called this type of mango “Nam Dok Mai Mango”. The size for export will be divided by weight. As shown in Table 1. Quality control is therefore important. And anthracnose, which causes black spots on the mango skin, which affects the quality of exports shown in Figure 2.

Table 1. Table of mango size sorting by weight.

Size	Weight (grams)
M	225 – 249
1L	330 – 379
2L	380 – 449
3L	More than 450



Figure 2. (A) *Mangifera Indica L.* (Nam Dok Mai Mango) (B) Mango for export (C) Anthracnose disease in mango.

2.2. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) is a computer model that simulates the workings of the human nervous system. The model architecture for mango size classification consists of 4 convolutional layers and 1 fully connected layer. ReLU is used as the activation function for the convolutional layers, and the fully connected layer uses Softmax activation function. Dropout is used to reduce overfitting. The hyperparameters used for training the model learning rate of 0.001, the structure model is shown in Figure 3.

- Image processing

After taking a photo of mango for Datasets, the image will be cut out in the edge of the Conveyor from the original size of 640 x 480 pixels, reduced to 620 x 300 pixels. Then a Binary Algorithm will be used to convert the image into two colors, white and black, to perform processing for detecting pixels in areas where objects are encountered. The example dataset is shown in Figure 6.




Figure 6. (A) Image capturing 640 x 480 pixels (B) Crop Image 620 x 300 pixels (C) Binary algorithm.

- Datasets

Dividing the data into training and testing sets, with 70% for training, 15% for testing, and 15% for validation. Adjust the lighting intensity by $\pm 5\%$ to increase the number of image data (Data Augmentation) Then, test the model with unseen data, as shown in Tables 2 and 3.

Table 2. The number of datasets for training and testing mango size sorting.

Size	Datasets			
	Train	Test	Validation	Unseen data
M	150	30	30	10
1L	150	30	30	10
2L	150	30	30	10
3L	150	30	30	10
Summary	600	120	120	40

Table 3. The number of datasets for training and testing the quality of mango.

Type of Mango	Datasets			
	Train	Test	Validation	Unseen data
Good Mango	176	38	38	20
Not Good Mango	176	38	38	20
Summary	352	76	76	40

3. Experimental and results

In the experiment, the dataset is divided into two parts. Section 1 involves classifying mango sizes as M, 1L, 2L, and 3L using ANN and CNN models, and Section 2 involves detecting mango quality (Anthracnose disease) using the CNN model.

3.1. Classifying mango sizes as M, 1L, 2L, and 3L

To classify mango sizes into M, 1L, 2L, and 3L using ANN and CNN, the same dataset was used for training and unseen data. The results are shown in the confusion matrices in Figures 7 and 8.




Figure 3. The structure ANN model.

2.3. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) efficiently extracts main features from images using preprocessed image data and trained models over an appropriate period. For mango size separation and quality classification, the model employs a structure with 5 convolutional and 2 fully connected layers, along with Dropout to address overfitting. ReLU serves as the activation function, with SoftMax used in the output layer. The hyperparameters used for training the model learning rate of 0.001, the structure model is shown in Figure 4.




Figure 4. The structure CNN model.

2.4. Data Acquisition

• Experimental setup

To collect the Dataset images, images were taken with a test set that was a conveyor for conveying fruit. A webcam camera was installed for taking photos, using a Logitech Brio camera, with the camera set at 55.5 centimeters from the floor of the conveyor. There are 2 stages of lighting control while taking photos. By adjusting from the Dimmable light bulb set and measuring the brightness with a Lux meter, where range 1 is 430-450 lux and range 2 is 1000-1020 lux. Shown in Figure 5.




Figure 5. (A) Experimental setup (B) Lux meter.

- Image processing

After taking a photo of mango for Datasets, the image will be cut out in the edge of the Conveyor from the original size of 640 x 480 pixels, reduced to 620 x 300 pixels. Then a Binary Algorithm will be used to convert the image into two colors, white and black, to perform processing for detecting pixels in areas where objects are encountered. The example dataset is shown in Figure 6.




Figure 6. (A) Image capturing 640 x 480 pixels (B) Crop Image 620 x 300 pixels (C) Binary algorithm.

- Datasets

Dividing the data into training and testing sets, with 70% for training, 15% for testing, and 15% for validation. Adjust the lighting intensity by $\pm 5\%$ to increase the number of image data (Data Augmentation) Then, test the model with unseen data, as shown in Tables 2 and 3.

Table 2. The number of datasets for training and testing mango size sorting.

Size	Datasets			
	Train	Test	Validation	Unseen data
M	150	30	30	10
1L	150	30	30	10
2L	150	30	30	10
3L	150	30	30	10
Summary	600	120	120	40

Table 3. The number of datasets for training and testing the quality of mango.

Type of Mango	Datasets			
	Train	Test	Validation	Unseen data
Good Mango	176	38	38	20
Not Good Mango	176	38	38	20
Summary	352	76	76	40

3. Experimental and results

In the experiment, the dataset is divided into two parts. Section 1 involves classifying mango sizes as M, 1L, 2L, and 3L using ANN and CNN models, and Section 2 involves detecting mango quality (Anthracnose disease) using the CNN model.

3.1. Classifying mango sizes as M, 1L, 2L, and 3L

To classify mango sizes into M, 1L, 2L, and 3L using ANN and CNN, the same dataset was used for training and unseen data. The results are shown in the confusion matrices in Figures 7 and 8.




Figure 7. (A) Confusion Matrix Training ANN model. (B) Confusion Matrix Testing ANN model.



Figure 8. (A) Confusion Matrix Training CNN model. (B) Confusion Matrix Testing CNN model.

The results from training with ANN and CNN show that CNN is more accurate. The Confusion matrix provides an assessment of classification performance, including the number of samples classified correctly and incorrectly. The Train Accuracy of ANN is 25.0%, with a Test Accuracy of 25.0%. On the other hand, the Train Accuracy of CNN is 99.16%, with a Test Accuracy of 88.0%.

3.2. Detecting mango quality

When training with CNN to inspect or classify mangoes as good or not good based on the presence of anthracnose disease, which manifests as black spots on the mango skin, making them unsuitable for export. The results are presented in the confusion matrix in Figure 9.




Figure 9. (A) Confusion Matrix Training CNN model. (B) Confusion Matrix Testing CNN model.

The results from training the CNN to assess the quality of mangoes with anthracnose show an improved accuracy, with a Train Accuracy of 91.0% and a Test Accuracy of 88.0% when evaluated with unseen data. From the tests, it was found that predictions with errors often occur with mangoes that have just started to develop anthracnose (small black spots) or anthracnose that is not yet well-defined.

The results of testing the model for size categorization and quality assessment with Unseen data are shown in Figure 10.




Figure 10. Example result testing with unseen data.

4. Conclusions

This paper addresses two primary objectives: size categorization and quality assessment of mangoes. In the first section, we employ artificial neural network (ANN) and convolutional neural network (CNN) models to classify mango sizes into four distinct categories (M, 1L, 2L, 3L). Results demonstrate the superior accuracy of the CNN model, achieving 99.16% accuracy on the training set and 88% on the test set. Conversely, the ANN model exhibited significantly lower accuracy at 25% for both training and test sets. Additionally, the CNN classification model designed to distinguish between good and bad mangoes yielded highly promising results with 91% accuracy on the training set and 88% on the test set. These findings suggest the potential for successful implementation of this algorithm within the mango industry, facilitating sorting and classification processes for both international and domestic markets in Thailand. Future research should focus on controlling the capture environment. Increasing the size of the data set to increase capacity model accuracy by adjusting the hyperparameter to be appropriate for the model considering the resources used for calculation and experiment with applying the model to other fruits.

References

- [1] Pharmacogn Rev. vol. 4, no. 7, pp. 42-8, Jan 2010. doi: 10.4103/0973-7847.65325.
- [2] FAOSTAT. Value of Agricultural Production. <https://www.fao.org/faostat/en/#data/QV> (accessed 21 March 2024).
- [3] E. R. Davies, Computer and Machine Vision: Theory, Algorithms, Practicalities. Academic Press, 2012.
- [4] A. Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. O'Reilly Media, 2019.
- [5] S. Suzuki, Y. Amemiya, and M. Sato, Deep learning assessment of child gross-motor, in 13th International Conference on Human System Interaction (HSI), 2020.
- [6] T. Chalidabhongse, P. Yimyam, and P. Sirisomboon, 2D/3D Vision-Based Mango's Feature Extraction and Sorting, in ICARCV 2006, 2006.
- [7] T. Wanglomklang, P. Chommaungpuck, K. Chamniprasart, and J. Srisertpol, Using fault detection and classification techniques for machine breakdown reduction of the HGA process caused by the slider loss defect, Manufacturing Review. vol. 9, 2022. doi: 10.1051/mfreview/2022020.
- [8] H. Afrisal, M. Faris, G. Utomo P., L. Grezelda, I. Soesanti and M. Andri F., Portable smart sorting and grading machine for fruits using computer vision, 2013 International Conference on Computer, Control, Informatics and Its Applications (IC3INA), Jakarta, Indonesia, 2013. pp. 71-75. doi: 10.1109/IC3INA.2013.6819151.
- [9] N. D. Thong, N. Truong Thinh and H. T. Cong, Mango Sorting Mechanical System Combines Image Processing, 2019 7th International Conference on Control, Mechatronics and Automation (ICCM), Delft, Netherlands, 2019. pp. 333-341. doi: 10.1109/ICCM46720.2019.8988714.

ประวัติผู้เขียน

นางสาวไอริน วรรณทอง เกิดเมื่อวันที่ 16 กรกฎาคม พ.ศ. 2541 ที่ อำเภอ เมือง จังหวัด นครราชสีมา สำเร็จการศึกษาระดับมัธยมศึกษาตอนปลาย จากโรงเรียนอุบลรัตนราชกัญญาราชวิทยาลัย นครราชสีมา และสำเร็จการศึกษาในระดับปริญญาตรี สาขาวิชาวิศวกรรมเครื่องกล หลักสูตรวิศวกรรมอากาศยาน สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี ในปีการศึกษา 2563 หลังจบการศึกษา ผู้วิจัยได้เข้าทำงานในตำแหน่งวิศวกรออกแบบแม่พิมพ์ (แม่พิมพ์ ป้อนขึ้นรูปโลหะของอุปกรณ์ไฟฟ้า อิเล็กทรอนิกส์ และชิ้นส่วนยานยนต์) ที่บริษัท โคราชมัตซึซึตะ จำกัด เป็นระยะเวลา 3 ปี และได้เข้าศึกษาระดับปริญญาโทในสาขาวิชาวิศวกรรมเมคคาทรอนิกส์ มหาวิทยาลัยเทคโนโลยีสุรนารี ซึ่งในระหว่างการศึกษามีโอกาสเป็นผู้ช่วยสอนรายวิชาทางด้าน วิศวกรรมศาสตร์ประจำสาขาวิชาวิศวกรรมเมคคาทรอนิกส์ สาขาวิชาวิศวกรรมพรีซิชั่น และสาขา วิศวกรรมเครื่องกล 5 รายวิชาได้แก่ (1) วิชาการเขียนแบบวิศวกรรม (2) วิชาการใช้คอมพิวเตอร์ช่วย ในการออกแบบ (CAD) (3) วิชา AutoCAD สำหรับวิศวกรรม (4) วิชาระบบควบคุมอัตโนมัติ และ (5) วิชาการวัดการสั่นสะเทือน ขณะศึกษาผู้วิจัยนำเสนอผลงานทางวิชาการระดับนานาชาติจำนวน 1 เรื่อง ระหว่างวันที่ 15-17 มิถุนายน 2567 ในงาน 2nd International Conference on Mechanics Electronics Automation and Automatic Control (MEAAC2024) ณ เมืองออร์ดอส มองโกเลีย ใน สาธารณรัฐประชาชนจีน ดังแสดงในภาคผนวก ง

มหาวิทยาลัยเทคโนโลยีสุรนารี