

การศึกษาและประยุกต์ใช้การมองเห็นของเครื่องจักรในการจำแนกข้อบกพร่อง
ข้าวโดยวิธีการเรียนรู้ของเครื่องจักรทั้งซัพพอร์ตเวกเตอร์แมชชีน และการ
เรียนรู้ของเครื่องจักรขั้นสูง

ON THE STUDY AND UTILIZING MACHINE VISION FOR RICE DEFECTS
CLASSIFICATION BY USING SUPPORT VECTOR MACHINE AND DEEP
LEARNING



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมสารสนเทศ
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ. 2564

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้ KMUTL-2021-EN-M-230-079 ญาติให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ON THE STUDY AND UTILIZING MACHINE VISION FOR RICE DEFECTS
CLASSIFICATION BY USING SUPPORT VECTOR MACHINE AND DEEP
LEARNING



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN INFORMATION ENGINEERING
SCHOOL OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2021
KMITL-2021-EN-D-018-024

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2021

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์ การศึกษาและประยุกต์ใช้การมองเห็นของเครื่องจักรในการ
จำแนกข้อบกพร่องข้าวโดยวิธีการเรียนรู้ของเครื่องจักรทั้งซัพ
พอร์ตเวกเตอร์แมชชีน และการเรียนรู้ของเครื่องจักรขั้นสูง
นักศึกษา นายภูวินทร์ คงสวัสดิ์
รหัสประจำตัว 59601141
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา วิศวกรรมสารสนเทศ
พ.ศ. 2564
อาจารย์ที่ปรึกษาวิทยานิพนธ์ รศ.ดร.อรรณสิทธิ์ หล้าสกุล

บทคัดย่อ

วิทยานิพนธ์นี้นำเสนอการศึกษาวิธีการใช้การมองเห็นของเครื่องจักรโดยวิธีซัพพอร์ตเวกเตอร์แมชชีน และการเรียนรู้ของเครื่องจักรขั้นสูง ในการยกระดับกระบวนการจำแนกข้าวบกพร่องซึ่งประกอบด้วยข้าวท้องไข่ว้าข้าวขัดสีต่ำกว่ามาตรฐานข้าวเมล็ดแดงกับข้าวขาว ซึ่งมีผลอย่างมีนัยสำคัญกับราคาซื้อขายข้าว โดยงานวิจัยนี้จะศึกษาการประยุกต์ใช้โมเดล (Linear Support Vector Machine) และ (Radius Basin Function Support Vector Machine) ในการวิเคราะห์ความสัมพันธ์ความเป็นเชิงเส้นและไม่เป็นเชิงเส้นโดยการใช้ค่าข้อมูลสีในการสอนการเรียนรู้ของเครื่องจักรและปรับค่าพารามิเตอร์ให้ได้ค่า (Accuracy) สูงสุด รวมไปถึงการป้องกัน (Overfitting) ซึ่งให้ผลลัพธ์ที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้น จากนั้นใช้การเรียนรู้ขั้นสูงโดยใช้โมเดล (Deep Learning Efficientnet B0) ซึ่งจะทำการปรับค่า (Hyperparameters) ซึ่งประกอบด้วย (Learning Rate) และ (Batch Size) และการทำ (Image Flipped Augmentation) และปลดล็อกการแช่แข็งโมเดล (Unfreezing Layers) เพื่อให้ได้ (Accuracy) สูงสุดและไม่ให้เกิด (Overfitting) โดยผลลัพธ์ที่ได้ให้ค่า (Accuracy) เพียงพอที่อุตสาหกรรมยอมรับ

Title	On The Study and Utilizing Machine Vision for Rice Defects Classification by using Support Vector Machine And Deep Learning
Student	Mr.Phuvin Kongsawat
Student ID.	59601141
Degree	Master of Engineering
Program	Information Engineering
Year	2021
Thesis Advisor	Assoc.Prof.Dr. Attasit Lasakul

ABSTRACT

This thesis proposes the methodologies of machine vision applying in rice defects classification task by using Support Vector Machine and Deep Learning to enhance rice quality assessment processes. It's undeniable that, rice's defects which consist of Red Kernel Chalky and Undermilled are very crucial in rice quality assessment processes: consequently, these defects are directly to the price and profitability significantly. This thesis utilizes Support Vector Machine both Linear and Radius Basis Function to analyze linear and non-linear relationship which apply color for classification and find tune parameters in order to obtain best result and avoid overfitting issue. The result of Support Vector Machine is non-linear relationship. After that, employing Deep Learning EfficientnetB0 with find tuning Hyperparameters (Learning Rate and Batch Size) utilizing Image Flipped Augmentation and unfreezing the top layer of model architecture in order to earn great accuracy and avoid overfitting. Deep Learning EfficientnetB0 is able to provide the sufficient accuracy for applying in real scenario.

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สามารถสำเร็จลุล่วงไปได้ด้วยดี โดยความเมตตาและความอนุเคราะห์ของรองศาสตราจารย์ ดร.อรรถสิทธิ์ หล้าสกุล ซึ่งเป็นอาจารย์ที่ปรึกษาที่คอยให้คำแนะนำ ความรู้ และให้คำปรึกษา คำแนะนำ และชี้แนะแนวทางแก้ไขปัญหาต่าง ๆ รวมถึงให้กำลังใจที่ดีต่อข้าพเจ้า

ขอขอบคุณรองศาสตราจารย์บุญชนะ ภูระหงษ์ และผู้ช่วยศาสตราจารย์ ดร.เดือนใจ อาชีวะพนิช และ ที่ให้คำแนะนำในการทำวิทยานิพนธ์ รวมถึงคณาจารย์สาขาวิศวกรรมสารสนเทศทุกท่านที่ให้ความรู้ คำแนะนำ คำปรึกษาในทุก ๆ เรื่อง กับข้าพเจ้า

ขอขอบคุณ ดร.ไอศูรย์ กาญจนสุรัตน์ และ ธนวิษณุ อนุวงศ์พินิจ ที่ช่วยให้คำแนะนำทั้งเรื่อง การเรียนและการทำวิทยานิพนธ์นี้และบุคลากรของบริษัท อีซีโรซ์ ดิจิทัล เทคโนโลยี จำกัดทุกท่านที่เป็นกำลังใจและแนะนำวิธีการทำวิทยานิพนธ์รวมถึงกระบวนการทดลอง

ขอขอบคุณคณะกรรมการผู้ตรวจสอบข้อ สภาหอการค้าแห่งประเทศไทยที่ให้ความอนุเคราะห์ ข้อมูลที่จำเป็นในการทำงานวิจัยอีกทั้งความเมตตากรุณาในการสอนให้มีความรู้ในอุตสาหกรรมข้าว และมีความรู้ที่ถูกต้องในการนำเอาเทคโนโลยีผลลัพธ์จากงานวิจัยนี้มาประยุกต์ใช้จริงให้เกิดประโยชน์ กับอุตสาหกรรมข้าวและประเทศชาติ

ขอขอบพระคุณมารดา บิดา พี่สาว ที่ช่วยสนับสนุนให้กำลังใจ และเห็นความสำคัญของการเรียนครั้งนี้ รวมถึงครอบครัวของข้าพเจ้าทุกคนที่คอยให้กำลังใจ คำแนะนำ สนับสนุน ทำให้ข้าพเจ้าสามารถจัดทำวิทยานิพนธ์จนสำเร็จลุล่วง สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับมารดา และครอบครัว ที่รักและเคารพยิ่ง ตลอดจนจนครุอาจารย์ที่เคารพทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้และถ่ายทอดประสบการณ์ที่ดีให้แก่ข้าพเจ้า และผู้มีพระคุณต่อข้าพเจ้าทุกท่านและข้าพเจ้ามีความภูมิใจที่ได้นำความรู้ที่ได้จากการเรียนมาสร้างประโยชน์ให้กับประเทศชาติ

ภูวินทร์ คงสวัสดิ์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	I
บทคัดย่อภาษาอังกฤษ	II
กิตติกรรมประกาศ	III
สารบัญ	IV
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์การวิจัย	3
1.3 ทฤษฎีหรือแนวคิดที่ใช้ในงานวิจัย	4
1.4 ขอบเขตการวิจัย	4
1.5 รายละเอียดวิทยานิพนธ์	5
บทที่ 2 ทฤษฎีและการทบทวนวรรณกรรมที่เกี่ยวข้อง	6
2.1 การเรียนรู้ของเครื่องจักร	6
2.1.1 โครงข่ายประสาทเทียม (ANN)	6
2.1.2 Support Vector Machine	10
2.2 การเรียนรู้คุณลักษณะและการเรียนรู้เชิงลึก	15
2.2.1 โครงข่ายประสาทเทียมแบบสังวัตนาการ	20
2.3 วิศวกรรมคุณลักษณะและการประมวลผลภาพ	20
2.3.1 คุณลักษณะพื้นฐานของภาพ (Low-level Feature of Image)	20
2.3.2 การตัดส่วนของภาพด้วยโดเมนสี (Color-based Segmentation)	22
2.3.3 แบบจำลองรูปลักษณ์ (Active Appearance Model)	22
2.4 การทบทวนวรรณกรรมที่เกี่ยวข้อง	23
บทที่ 3 การออกแบบการทดลอง	26
3.1 บทนำ	26
3.2 การเตรียมอุปกรณ์และการเตรียมเก็บข้อมูลสำหรับสร้างชุดข้อมูล	28
3.2.1 ขั้นตอนการเตรียมอุปกรณ์	28
3.2.2 การเตรียมเก็บข้อมูลสำหรับสร้างชุดข้อมูล	29

สารบัญ (ต่อ)

	หน้า
3.3 การประมวลผลทางภาพ.....	31
3.4 การสกัดคุณลักษณะ	33
3.5 สร้างและทดสอบแบบจำลอง (Support Vector Machine) ด้วยชุดคุณลักษณะแต่ละ แบบ.....	35
3.5.1 คุณสมบัติการสกัดข้อมูล (Feature Engineering).....	35
3.5.2 รูปแบบของการกระจายของข้อมูล.....	35
3.5.3 Linear Support Vector Machine	36
3.5.4 Radius Basin Function Support Vector Machine	36
3.5.5 การหาพารามิเตอร์ที่เหมาะสมที่สุดกับแบบจำลอง.....	36
3.6 การเรียนรู้ด้วยเครื่องจักรขั้นสูง (Deep Learning Model Efficientnet B0).....	37
3.6.1 หลักการพื้นฐานของ (EfficientNet).....	37
3.6.1 Transfer Learning	38
บทที่ 4 อภิปรายผลการทดลองและแนวทางการพัฒนา.....	40
4.1 ผลการทดลองการ (Support Vector Machine).....	40
4.1.1 ชุดข้อมูลที่ใช้ในการทดลอง.....	40
4.1.2 การปรับพารามิเตอร์และผลการทดลอง.....	40
4.2 ผลการทดลองของการเรียนรู้ของเครื่องจักรขั้นสูงโมเดล (Deep Learning Model EfficeintnetB0).....	42
4.2.1 ชุดข้อมูลที่ใช้ในการทดลอง.....	42
4.2.2 กระบวนการทดลองการเรียนรู้ของเครื่องจักรขั้นสูงโมเดล (Deep Learning Model Efficeintnet B0).....	42
4.3.1 นำผลลัพธ์จากข้อที่ 4.2.2 มาหาโมเดลที่ให้ค่าความแม่นยำสูงสุด.....	51
4.3 การปรับปรุงประสิทธิภาพจากการวิเคราะห์ความผิดพลาด.....	53
บทที่ 5 บทสรุป	55
5.1 บทสรุปการทดลอง.....	55
5.2 การวิเคราะห์เพื่อปรับปรุงผลและการนำมาใช้จริงในอุตสาหกรรม.....	56

สารบัญ (ต่อ)

หน้า

เอกสารอ้างอิง.....	57
ภาคผนวก	59
ภาคผนวก ก. ข้อบกพร่องข้าวที่ส่งผลกระทบต่อราคาข้าว	59
ภาคผนวก ข. ผลงานวิจัยที่ได้รับการตีพิมพ์	60
ประวัติผู้เขียน	64



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ประเทศไทยเป็นประเทศเกษตรกรรมและมีความโดดเด่นในเรื่องของอุตสาหกรรม การเกษตรและจัดได้ว่าได้ว่าเป็นแหล่งอาหารของโลกโดยมีสินค้าทางการเกษตรโดดเด่น หลากหลายและสามารถส่งออกสร้างรายได้ให้กับประเทศถึง 22,364 ล้านดอลลาร์ ต่อปีแต่สินค้า ทางการเกษตรที่สามารถสร้างรายได้ให้กับประเทศไทยมากที่สุดอันดับที่ 1 คือสินค้าข้าวสามารถ ส่งออกได้ถึงปีละ 11.3 ล้านตัน และสร้างรายได้ให้กับประเทศถึงปีละประมาณ 5,167 ล้านดอลลาร์ ซึ่งสินค้าข้าวไทยเป็นที่ยอมรับในเวทีข้าวโลกเรื่องคุณภาพและราคาโดยที่ในปี พ.ศ. 2560 ประเทศไทยเป็นผู้ส่งออกข้าวอันดับที่ 1 ของโลกซึ่งสิ่งที่เป็นตัวช่วยในความสำเร็จของ อุตสาหกรรมข้าวไทยคือกระบวนการตรวจวัดเพื่อรับประกันคุณภาพของสินค้าข้าวไทย (Quality Assurance: QA) ซึ่งกระทรวงพาณิชย์เป็นผู้ออกมาตราฐานเพื่อควบคุมคุณภาพของสินค้าข้าว ไทยโดยที่ผู้ประกอบการทุกส่วนของอุตสาหกรรมข้าวไทยต้องปฏิบัติตาม แต่การตรวจวัดเพื่อ รับประกันคุณภาพสินค้าข้าวในอุตสาหกรรมข้าวไทยก่อให้เกิดปัญหาและผลเสียเช่นเดียวกันดัง โดยมีปัญหาต่าง ๆ เช่น ปัญหาเรื่องความล่าช้าในการทำ (Quality Assurance) เนื่องจาก รูปแบบการตรวจวัดโดยใช้เจ้าหน้าที่ชำนาญการและมีความรู้เรื่องคุณภาพข้าวร่วมกับอุปกรณ์วัด ขนาดเมล็ดข้าวที่เรียกว่า “ไมโครมิเตอร์” ตามรูปที่ 1 และ รูปที่ 2 เพื่อทำการประเมินคุณภาพ ของสินค้าข้าวที่ผลิต หรือ รูปแบบ (Manual Analysis) แต่การตรวจวัดในรูปแบบ (Manual Analysis) มีข้อจำกัดตรงที่ไมโครมิเตอร์วัดขนาดของเมล็ดข้าววัดได้ครั้งละ 1 เมล็ด ซึ่งก่อให้เกิด ความล่าช้าเพราะในการทำงานจริงในอุตสาหกรรมข้าวไทยจะสุ่มตัวอย่างของสินค้าข้าวที่ผลิตได้ 1 ตัน สุ่มตัวอย่างมา 25 กรัม และนำตัวอย่างนั้นมาทำ (Quality Assurance) ซึ่งในตัวอย่างสินค้า ข้าว 25 กรัมจะมีเมล็ดข้าวประมาณ 1,200 เมล็ดแต่การตรวจวัดในรูปแบบ (Manual Analysis) สามารถวัดขนาดและประเมินลักษณะของเมล็ดข้าวได้ครั้ง 1 เมล็ดซึ่งต้องใช้เวลาในการประเมิน คุณภาพสินค้าข้าวถึง 1-4 ชั่วโมง ขึ้นอยู่กับความชำนาญของเจ้าหน้าที่ ซึ่งปัญหานี้ได้นำไปสู่ ปัญหาขอขวดของอุตสาหกรรมข้าวไทยที่ผลิตสินค้าเสร็จแต่ยังไม่สามารถส่งขายได้ต้องรอการ วัดเพื่อรับประกันคุณภาพเสียก่อน ในกรณีที่วัดแล้วยังไม่ผ่านมาตรฐานก็ต้องรอผลถึง 1-4 ชั่วโมงถึงจะนำสินค้าเข้ามา (Process) ใหม่

นอกจากนี้ มีปัญหาจากการทำ (Quality Assurance) ในรูปแบบ (Manual Analysis) ซึ่งใช้ เจ้าหน้าที่ที่มีความชำนาญการและมีความรู้เรื่องคุณภาพข้าวร่วมกับอุปกรณ์วัดขนาดเมล็ดข้าวที่ เรียกว่าไมโครมิเตอร์เพื่อทำการประเมินคุณภาพของสินค้าข้าวที่ผลิต ซึ่งรูปแบบ (Manual Analysis) ให้ผลลัพธ์การประเมินคุณภาพสินค้าข้าวที่คลาดเคลื่อนอันเนื่องมาจากเจ้าหน้าที่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผู้เชี่ยวชาญต้องทำงานเป็นเวลา 8 ชั่วโมงใน 1 วัน ก่อให้เกิดความเมื่อยล้าส่งผลให้เกิดปัญหาในการประเมินคุณภาพสินค้าข้าวที่คลาดเคลื่อนไม่ตรงกับคุณภาพที่แท้จริงของสินค้าข้าวที่ผลิตได้ ซึ่งนำไปสู่การถูกปฏิเสธสินค้าเมื่อส่งออกและก่อให้เกิดชื่อเสียงต่อสินค้าข้าวไทยและส่งผลกระทบต่อวงกว้าง

อีกปัญหาหนึ่ง คือ กลุ่มโรงสีข้าวชุมชนและโรงสีข้าวขนาดเล็กไม่สามารถมีเครื่องมือที่ใช้ทำการประเมินคุณภาพของสินค้าข้าวที่ตรงกับมาตรฐานของกระทรวงพาณิชย์ได้เพราะว่าการทำ (Quality Assurance) ต้องใช้เจ้าหน้าที่ที่มีความเชี่ยวชาญในการทำ แต่กลุ่มโรงสีข้าวชุมชนและโรงสีข้าวขนาดเล็กไม่มีงบประมาณที่มากพอที่จะจ้างเจ้าหน้าที่ที่มีความเชี่ยวชาญ ส่งผลให้สินค้าข้าวที่ผลิตได้ไม่มีการประเมินและรับประกันคุณภาพสินค้าข้าวที่ผลิตทำให้สินค้าข้าวที่ผลิตขายเป็นสินค้าที่ไม่มีเกรดและได้ราคาต่ำ



รูปที่ 1.1 ตัวอย่างการตรวจวัดเพื่อรับประกันคุณภาพสินค้าข้าวในรูปแบบ (Manual Analysis)



รูปที่ 1.2 อุปกรณ์ไมโครมิเตอร์ที่ใช้วัดขนาดเมล็ดข้าวเพื่อทำการวัดเพื่อรับประกันสินค้าข้าว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากปัญหาการประเมินคุณภาพสินค้าข้าวไทย หรือการทำ (Quality Assurance) ของอุตสาหกรรมข้าวไทยในรูปแบบเดิม คือ (Manual Analysis) ที่ต้องใช้เจ้าหน้าที่ที่มีความเชี่ยวชาญในการตรวจวัดคุณภาพเมล็ดข้าวอุปกรณ์ที่ใช้วัดขนาดเมล็ดข้าวไมโครมิเตอร์ที่มีข้อจำกัดในการตรวจวัดเมล็ดข้าวได้ครั้งละ 1 เมล็ด ซึ่งใช้เวลาในการตรวจวัดที่นานอีกทั้งมีความคลาดเคลื่อนที่เกิดจากจากเจ้าหน้าที่ซึ่งต้องทำงานเป็นเวลา 8 ชั่วโมงใน 1 วันซึ่งเกิดความเมื่อยล้าทำให้วัดคุณภาพของสินค้าข้าวผิดพลาดก็ให้เกิดความเสียหาย และรวมถึงกลุ่มโรงสีชุมชนและโรงสีขนาดเล็กที่มีต้นทุนต่ำในการบริหารจัดการที่ไม่สามารถจ้างเจ้าหน้าที่ที่มีความเชี่ยวชาญได้ส่งผลให้ไม่มีการรับประกันคุณภาพสินค้าทำให้ต้องขายสินค้าข้าวในเกรดที่เป็นสินค้าข้าวคละเกรดซึ่งมีราคาต่ำ ดังนั้น วิทยานิพนธ์นี้จึงนำเสนอการใช้งานระบบ (Machine Vision) โดยใช้วิธี ทั้งการใช้ (Support Vector Machine) และการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model Efficientnet B0) เพื่อนำมาใช้แก้ปัญหาและเพิ่มประสิทธิภาพให้กับอุตสาหกรรมข้าวไทยจึงเป็นที่มาของการพัฒนาระบบประเมินคุณภาพเมล็ดข้าวไทยต้นทุนต่ำโดยใช้เทคโนโลยีการประมวลผลทางภาพ เพื่อแก้ไขปัญหาการทำ (Quality Assurance) ในการวิเคราะห์ข้อบกพร่องข้าวซึ่งประกอบไปด้วยข้าวท้องไข่ ข้าวสีต่ำกว่ามาตรฐาน ข้าวเมล็ดแดง และข้าวขาว ของอุตสาหกรรมข้าวไทยและช่วยให้กลุ่มโรงสีขนาดเล็กและโรงสีชุมชนสามารถเข้าถึงเทคโนโลยีและสามารถทำการตรวจวัดคุณภาพสินค้าข้าวหรือการทำ (Quality Assurance) เพื่อรับประกันคุณภาพสินค้าข้าวและขายสินค้าข้าวได้ราคา

1.2 วัตถุประสงค์

- 1.2.1 ศึกษาและวิจัยเพื่อพัฒนาเครื่องมือที่ตอบโจทย์อุตสาหกรรมยุคใหม่ซึ่งใช้ช่วยแก้ไขปัญหาในอุตสาหกรรมข้าวไทยโดยใช้เทคโนโลยีและความรู้ทางวิศวกรรมเข้าไปแก้ปัญหาในอุตสาหกรรมข้าวไทยได้จริง
- 1.2.2 เพื่อสร้างเครื่องมือรับประกันคุณภาพสินค้าที่รวดเร็วและไม่คลาดเคลื่อนเหมือนใช้เจ้าหน้าที่อีก
- 1.2.3 ศึกษาและวิจัยในการใช้การประมวลผลทางภาพในการกำจัด (Noise) ในรูปภาพข้าวและใช้จำแนกข้าวออกมาเป็นรายเมล็ด
- 1.2.4 ทดลองใช้ (Support Vector Machine) ในการจำแนกข้อบกพร่องข้าวซึ่งประกอบไปด้วยข้าวท้องไข่ ข้าวสีต่ำกว่ามาตรฐาน ข้าวเมล็ดแดง และข้าวขาว โดยการดูการกระจายของข้อมูลว่าเป็นเชิงเส้นโดยใช้ (Linear Support Vector Machine) หรือไม่เป็นเชิงเส้นโดยใช้ (Radius Basis Function Support Vector Machine)
- 1.2.5 ทดลองใช้ (Deep Learning Neural Network) โมเดล (Efficientnet B0) ในการจำแนกข้อบกพร่องข้าวซึ่งประกอบไปด้วยข้าวท้องไข่ ข้าวสีต่ำกว่ามาตรฐาน ข้าวเมล็ดแดง และข้าวขาว

1.2.6 เปรียบเทียบการทำงานของ (Radius Basis Function Support Vector Machine) กับ (Deep Learning Neural Network) โมเดล (Efficientnet B0)

1.2.7 วิเคราะห์ผลลัพธ์ที่ได้และสรุปผล

1.3 ทฤษฎีหรือแนวคิดที่ใช้ในงานวิจัย

ทฤษฎีที่นำมาใช้ประยุกต์มาจากรูปแบบการวัดแบบเดิมที่เป็นแบบ (Manual Analysis) โดยการใช้อุปกรณ์ที่มีต้นทุนต่ำและหาซื้อได้ง่ายในท้องตลาดเพื่อให้กลุ่มโรงสีชุมชนและโรงสีข้าวขนาดเล็กสามารถเข้าถึงเทคโนโลยี โดยการใช้รูปแบบ (Machine Vision) โดยการประมวลผลทางภาพโดยใช้สแกนเนอร์ในการรับภาพสีของเมล็ดข้าวที่ถูกสุ่มมาจากสินค้าข้าวที่ผลิตได้ 1 ตัน ในจำนวน 25 กรัม จากนั้นนำภาพที่ได้มาประมวลผลด้วย (Software) ที่พัฒนาขึ้นโดยผู้วิจัย โดยจะทำการแปลงภาพสี (RGB) เป็นภาพแบบ (Gray Scale) และแปลงภาพ (Gray Scale) เป็นภาพ (Binary) โดยการใช้รูปแบบในการหาค่า Threshold แบบ (Ostu's) [11] จากนั้นทำการกำจัด (Speckle Noise) [10] ที่เกิดจากการแปลงภาพ (Gray Scale) เป็นภาพ (Binary) โดยอาศัยหลักการ (Morphological Opening) [10] ในการกำจัด Noise ในภาพจากนั้นใช้หลักการของ (Morphological Labelling)[10] ในการแบ่งแยกพื้นที่ข้าวออกมาเป็นรายเมล็ด เมื่อได้พื้นที่ข้าวที่ถูกจำแนกเป็นรายเมล็ดทำการแปลงภาพจาก (RGB) เป็นโดเมนสีแบบ (HSV) [10] แล้วทำการสกัดคุณลักษณะ (Histogram) ของ (HSV) เพื่อใช้เป็นข้อมูลในการเทรน (Support Vector Machine) ทั้งแบบ (Linear Support Vector Machine) และ (Radius Basis Function Support Vector Machine) เพื่อใช้ในการดูการกระจายของข้อมูลว่าเป็นแบบเชิงเส้นหรือไม่เป็นเชิงเส้นและเปรียบเทียบประสิทธิภาพในรูปแบบ (Accuracy) จากนั้นจะทำการประยุกต์ใช้โมเดล (Deep Learning Neural Network) โมเดล (Efficientnet B0) ในการจำแนกขอบกร่องข้าว เพื่อนำมาเปรียบเทียบกับประสิทธิภาพของโมเดล (Linear Support Vector Machine) และ (Radius Basis Function Support Vector Machine) ในรูปแบบ (Accuracy)

1.4 ขอบเขตการวิจัย

ทำการศึกษาและสืบค้นบทความที่เกี่ยวข้องกับงานวิจัยและทดลองนำหลักการที่สืบค้นได้มาทดลองใช้จริงในอุตสาหกรรมข้าวไทยในกระบวนการตรวจสอบคุณภาพข้าวที่ต้องวิเคราะห์ขอบกร่องข้าวซึ่งประกอบด้วย ข้าวท้อง ข้าวสีต่ำกว่ามาตรฐาน ข้าวเมล็ดแดง ซึ่งต้องถูกแยกและวิเคราะห์จากข้าวสีขาว เพราะเนื่องจากส่งผลต่อราคาในการซื้อขาย โดยงานวิจัยนี้จะทำการศึกษาลักษณะการวิเคราะห์แบบดั้งเดิมโดยการใช้เจ้าหน้าที่ในการตรวจสอบ ซึ่งจะเป็นข้อมูลที่สำคัญที่จะถูกนำมาใช้งานวิจัยและการประยุกต์ใช้ (Linear Support Vector Machine) และ (Radius Basis Function Support Vector Machine) ในการวิเคราะห์การกระจายของข้อมูลว่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เป็นแบบเชิงเส้นหรือไม่และจำแนกข้อบกพร่องข้าวทั้ง ข้าวท้อง ข้าวสีต่ำกว่ามาตรฐาน ข้าวเมล็ดแดง และข้าวขาว จากนั้นจะทำการประยุกต์ใช้โมเดล (Deep Learning Neural Network) โมเดล (Efficientnet B0) ในการทดลองจำแนกข้อบกพร่องข้าวทั้ง ข้าวท้อง ข้าวสีต่ำกว่ามาตรฐาน ข้าวเมล็ดแดง และข้าวขาว และนำผลลัพธ์ที่ได้มาเปรียบเทียบกันโดยการดู (Accuracy) เพื่อหาเดลที่ (Accuracy) สูงที่สุดมาใช้งานจริงในอุตสาหกรรมข้าวโดยมีอุตสาหกรรมข้าวมีความคาดหวังที่จะได้ค่า (Accuracy) สูงกว่า 95% ถึงจะสามารถนำมาใช้งานจริงได้ ดังนั้นผู้วิจัยจึงมีความตั้งใจที่หาโมเดลที่มีค่า ค่า (Accuracy) สูงเพื่อมาใช้งานในการจำแนกนี้

1.5 รายละเอียดวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้อธิบายถึงขั้นตอนและรายละเอียดต่างๆ โดยแบ่งเนื้อหาเป็น 5 บทดังนี้

บทที่ 1 กล่าวถึงที่มาและความสำคัญรวมถึงวัตถุประสงค์ของวิทยานิพนธ์ฉบับนี้

บทที่ 2 กล่าวถึงรายละเอียดของหลักการและทฤษฎีที่นำมาประยุกต์ใช้ในงานวิจัยนี้และการทบทวนบทความงานวิจัย

บทที่ 3 กล่าวถึงขั้นตอนและกระบวนการในการวิจัยและอุปกรณ์ที่ใช้ในงานวิจัยนี้

บทที่ 4 กล่าวถึงผลลัพธ์ที่ได้จากการทดลองใช้งาน

บทที่ 5 เป็นการสรุปผลงานวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและการทบทวนวรรณกรรมที่เกี่ยวข้อง


2.1 การเรียนรู้ของเครื่องจักร

การเรียนรู้ของเครื่องจักรคือศาสตร์ด้านคอมพิวเตอร์ที่ใช้เทคนิคทำให้คอมพิวเตอร์มีความสามารถในการเรียนรู้จากประสบการณ์ หรือการเรียนรู้จากตัวอย่างที่ได้รับ โดยสามารถนำสิ่งที่ได้เรียนรู้นั้นมาสร้างเป็นองค์ความรู้สำหรับการแยกประเภท คัดการณ์ หรือแบ่งกลุ่มข้อมูลได้ รวมถึงประยุกต์ใช้กับข้อมูลอื่น ๆ และสามารถพัฒนาประสิทธิภาพของแบบจำลองจากสิ่งที่ได้เรียนรู้ในภายหลังได้ การเรียนรู้ของเครื่องจักรแบ่งออกเป็นสามประเภทได้แก่ การเรียนรู้แบบมีผู้สอน การเรียนรู้แบบไม่มีผู้สอน และการเรียนรู้แบบเสริมกำลัง

การเรียนรู้แบบมีผู้สอนนั้นคือการเรียนรู้จากข้อมูลที่มีผลเฉลยเพื่อสร้างแบบจำลองสำหรับการคาดการณ์หรือทำนายอนาคตได้ ส่วนการเรียนรู้แบบไม่มีผู้สอนคือการหารูปแบบชุดข้อมูลและโครงสร้างโดยที่ไม่มีคำตอบมาให้ และประเภทสุดท้ายคือ การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning) ซึ่งเป็นการเรียนรู้โดยมีการกำหนดรางวัลและบทลงโทษไว้ เมื่อโปรแกรมแสดงพฤติกรรมหรือปฏิบัติกิจกรรมบางอย่าง หลังจากนั้นโปรแกรมจะพยายามแสดงพฤติกรรมเพื่อให้ได้รางวัลและหลีกเลี่ยงบทลงโทษ

โดยวิธีการเรียนรู้ของเครื่องจักรที่เลือกใช้ในงานวิจัยฉบับนี้คือการเรียนรู้แบบมีผู้สอน โดยเลือกใช้โครงข่ายประสาทเทียมซึ่งมีภาพจำลองเซลล์ประสาทดังรูปที่ 2.1 และเลือกใช้ซอฟต์แวร์เวกเตอร์แมชชีน

2.1.1 โครงข่ายประสาทเทียม (ANN)



รูปที่ 2.1 การจำลองเซลล์ประสาทของมนุษย์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โครงข่ายประสาทเทียมคือระบบคอมพิวเตอร์จากโมเดลหรือแบบจำลองทางคณิตศาสตร์ เพื่อจำลองการทำงานโครงข่ายประสาทชีวภาพที่อยู่ในสมองของสัตว์ โครงข่ายประสาทเทียมสามารถเรียนรู้ที่จะทำงานที่มอบหมายได้จากการเรียนรู้ผ่านตัวอย่าง โดยมีหน่วยการประมวลข้อมูลย่อยที่สุดเป็นเซลล์ประสาท ซึ่งประกอบด้วยตัวเซลล์ (Soma) ซึ่งเปรียบตั้งตัวประมวลผล การของเซลล์ประสาทแต่ละเซลล์ โดยในทุก ๆ เซลล์จะมีใยประสาทนำเข้า (Dendrite) ที่เป็นตั้งตัวกลางการรับกระแสประสาทจากภายนอกเซลล์ และมีแกนประสาทนำออก (Axon) เป็นตัวส่งกระแสประสาทจากเซลล์ประสาทไปยังเซลล์ภายนอกหรือตัวเซลล์อื่นๆ โดยในทุก ๆ เซลล์จะมีใยประสาทนำเข้าที่อื่นก็ได้ แต่จะมีแกนประสาทนำออกเพียงอันเดียว และที่ปลายของใยประสาทนำเข้าจะมีจุดประสานประสาท (Synapse) ซึ่งเป็นมีช่องว่างขนาดเล็กกระหว่างใยประสาทนำเข้า กับตัวเซลล์ประสาท โดยช่องว่างนี้จะส่งผลต่อปริมาณของกระแสประสาทที่วิ่งเข้ามาภายในตัวเซลล์เพื่อประมวลผลผ่านใยประสาทนำเข้า การที่ช่องว่างจุดประสานประสาทถูกเปลี่ยนแปลง จะส่งผลให้การตีความภายในสมองถูกเปลี่ยนแปลงไปด้วย


แนวคิดที่ได้กล่าวมาข้างต้นได้ถูกนำมาประยุกต์ใช้ในการสร้างแบบจำลองการเรียนรู้ที่มีลักษณะคล้ายกับโครงข่ายของระบบประสาท โดยประกอบด้วยแกนประสาทนำออก ใยประสาทนำเข้า และจุดประสานประสาท ดังรูปที่ 2.2 โดยได้นำองค์ประกอบเหล่านั้นมาประยุกต์ใช้ใน รูปแบบของแบบจำลองทางคณิตศาสตร์ ซึ่งสามารถเปรียบเทียบได้ว่า ใยประสาทนำเข้าคือส่วนของตัวรับข้อมูลเชิงตัวเลขที่จะทำหน้าที่รับข้อมูลมาประมวลผล และมีจุดประสานประสาทในที่ เป็นค่าพารามิเตอร์ที่ทำการคูณกับค่าที่ได้รับเข้ามาสำหรับถ่วงน้ำหนัก

จากโครงสร้างระบบประสาทของมนุษย์ที่ตัวเซลล์ได้รับค่าที่ผ่านการคำนวณจากการถ่วงน้ำหนักแล้วจะทำการผ่านฟังก์ชันทางคณิตศาสตร์ใด ๆ และส่งออกไปยังภายนอกของตัวเซลล์ ซึ่งเปรียบเสมือนการทำงานของแกนประสาทนำออก ซึ่งสามารถจำลองเป็นสมการทางคณิตศาสตร์ได้ดังสมการที่ (2.1)

$$Y = f(\sum_{i=1}^N x_i w_i + b) \quad (2.1)$$

โดยที่ N	คือจำนวนข้อมูลนำเข้า
x_i	คือค่าที่ป้อนเข้ามายังเซลล์ประสาท
w_i	คือค่าน้ำหนักของข้อมูลนำเข้า
f	คือฟังก์ชันขาออกที่ส่งไปยังภายนอกเซลล์ประสาท
y	ค่าคำตอบจริง
b	คือค่า Bias

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.2 การประยุกต์ใช้เซลล์ประสาทในการสร้างแบบจำลองทางคณิตศาสตร์ของเซลล์ประสาท

ซึ่งในการสอนแบบจำลองใดๆ จะต้องมีการกำหนดค่าตอบที่ถูกต้องในรูปแบบที่ต้องการ หรือเรียกว่าค่าตอบจริง (True Value) เทียบได้กับตัวแปร y และทำการป้อนค่า x ทั้งหมดเข้ามาภายในเซลล์ประสาทและพิจารณาค่าที่ได้กับค่าคำตอบจริง โดยในทางปกติแล้วแบบจำลองที่ยังไม่สำเร็จกระบวนการสอน ค่าที่ส่งออกมาจากตัวแบบจำลองจะมีการผิดเพี้ยนไปจากตัวคำตอบจริงเป็นอย่างมาก ดังนั้นแล้วเพื่อปรับปรุงประสิทธิภาพของตัวแบบจำลอง จึงมีการแนะนำให้ใช้วิธีการกำหนดฟังก์ชันความผิดพลาด (Error Function หรือ Loss Function) ดังสมการที่ (2.2)

$$L = \frac{1}{2} (\bar{y} - y)^2 = \frac{1}{2} (\bar{y} - f(\sum_{i=1}^N x_i w_i))^2 \quad (2.2)$$

โดยที่ \bar{y} คือค่าคำตอบจริง

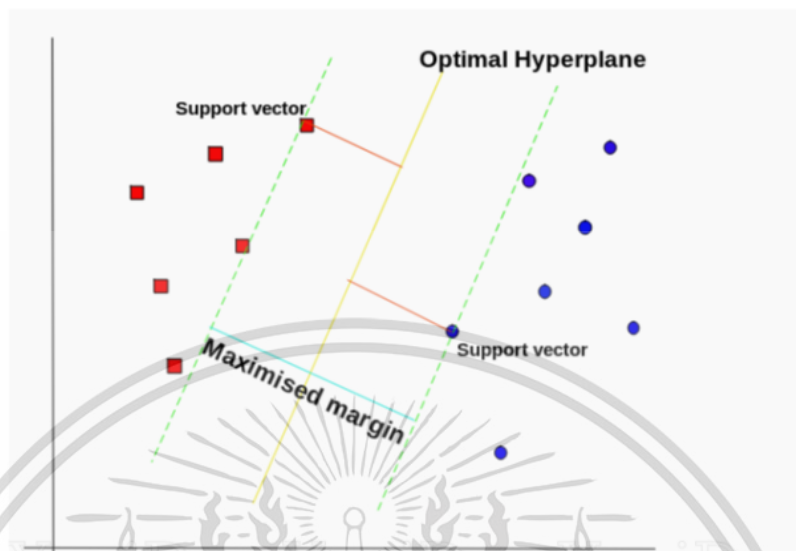
ซึ่งจะมีขั้นตอนและวิธีการต่างๆ ในการพยายามปรับค่า w ไปเรื่อย ๆ จนกว่าฟังก์ชันความผิดพลาดจะแสดงผลออกมาเป็นค่าผิดพลาดที่น้อยที่สุด ซึ่งจะหมายความว่าแบบจำลองสามารถทำนายค่าได้ใกล้เคียงกับค่าที่จริงมากที่สุดเช่นกัน



รูปที่ 2.2 แสดงการจำลองโครงข่ายประสาทเทียมแบบหลายชั้น

จากหลักการข้างต้นที่ได้เสนอในแนวคิดของโครงข่ายประสาทเทียม โดยมีการเปรียบเทียบและพิจารณาเป็นลักษณะของเซลล์ประสาทเซลล์หนึ่ง จะพบปัญหาของการสร้างแบบจำลองเพื่อการแยกหรือจำแนกประเภท หรือการคาดการณ์ค่าในอนาคตด้วยขั้นตอนวิธีโครงข่ายประสาทเทียมแบบเซลล์เดียว เนื่องจากแบบจำลองดังกล่าวถูกจำลองด้วยสมการเชิงเส้น (Linear) ซึ่งปัญหาที่อยู่ในกฎเกณฑ์ของโลกแห่งความเป็นจริงนั้นมีความซับซ้อนและหลากหลายเกินกว่าจะถูกแทนด้วยสมการเส้นตรง การเลือกใช้แบบจำลองสมการที่ไม่เป็นสมการเชิงเส้น (Nonlinear) จึงเป็นวิธีการแก้ปัญหาของสมการในชีวิตจริงที่ซับซ้อนเกินไป โดยเป็นการนำเซลล์ประสาทหลาย ๆ เซลล์มาเชื่อมโยงกันเป็นโครงข่าย ดังภาพที่ 2 ที่แสดงให้เห็นว่าเซลล์ประสาทแต่ละเซลล์มีการส่งค่าให้กันตามลำดับชั้น โดยชั้นที่ได้รับข้อมูลมาจากภายนอก จะถูกเรียกว่าชั้นข้อมูลนำเข้า (Input Layer) และชั้นข้อมูลที่ส่งออกไปเรียกว่า ชั้นข้อมูลส่งออก (Output Layer) และเซลล์ที่อยู่บริเวณตรงกลางระหว่างชั้นข้อมูลนำเข้าและชั้นข้อมูลส่งออกจะเป็นลำดับชั้นที่ทำหน้าที่ในการเป็นตัวประมวลผลหลักของโครงข่าย เรียกว่าแอบแฝง (Hidden Layer) และการออกแบบรูปแบบของแบบจำลองเป็นโครงข่ายในลักษณะนี้จะทำให้แบบจำลองสามารถทดแทนข้อมูลหรือจำแนกข้อมูลโดยใช้สมการที่ไม่เป็นเชิงเส้นได้

2.1.2 Support Vector Machine



รูปที่ 2.3 การสร้างเส้นแบ่งด้วยขั้นตอนวิธีพอร์ตเวกเตอร์แมชชีน

จากหัวข้อ 2.1.1 ที่ได้นำเสนอขั้นตอนและวิธีการเรียนรู้ของเครื่องจักรด้วยโครงข่ายประสาทเทียมในข้างต้นนั้นได้ใช้รูปแบบของสมการทางคณิตศาสตร์ที่ถูกกำหนดไว้และใช้การปรับค่าพารามิเตอร์ต่าง ๆ เพื่อให้แบบจำลองมี (Accuracy) สูงสุด และการสร้างแบบจำลองในลักษณะดังกล่าวอาจก่อให้เกิดปัญหาตามมาหลายอย่าง เช่น เวลาที่ต้องใช้ในการสอนเครื่องคอมพิวเตอร์และแบบจำลอง รวมทั้งปัญหาที่เกิดจาก (Overfitting)

ขั้นตอนและวิธีการเรียนรู้ของเครื่องจักรมีมากมายและภายใต้หัวข้อ 2.1.2 นี้จะกล่าวถึงซัพพอร์ตเวกเตอร์แมชชีนซึ่งเป็นขั้นตอนวิธีการเรียนรู้ของเครื่องจักรด้วยเช่นกัน วิธีการนี้เป็นทางเลือกในการสร้างแบบจำลองเพื่อการทำนายค่าและการจำแนกประเภทรูปแบบหนึ่ง ที่มี (Accuracy) สูงและทนทานต่อการเกิดปัญหา (Overfitting) โดยแนวคิดพื้นฐานของ (Support Vector Machine) คือการสร้างแบบจำลองที่จะทำการแบ่งกลุ่มข้อมูลออกเป็น 2 กลุ่มในรูปแบบเชิงเส้น ซึ่งขั้นตอนและวิธีการในการสร้างเส้นแบ่งข้อมูลทั้งสองกลุ่ม สามารถทำได้โดยการพิจารณาตัวแทนข้อมูลที่อยู่ใกล้ชิดกับตัวแทนข้อมูลอีกกลุ่มมากที่สุด และตัวแทนที่ถูกเลือกเหล่านี้เรียกว่า (Support Vector) และ (Hyper plane) ระหว่างตัวแทนทั้งสองกลุ่มให้มีระยะห่างจากทั้งสองกลุ่มมากที่สุด (Maximum Margin) เพื่อให้ได้ผลลัพธ์และการจำแนกที่ดีที่สุดเช่นกัน ดังรูปที่ 2.3 ซึ่งการเลือก (Support Vector) และสร้างระนาบที่เหมาะสมที่สุดสามารถทำได้โดยเริ่มจากการกำหนดค่าตอบของกลุ่มใดกลุ่มหนึ่งให้มีค่าเป็น +1 และอีกกลุ่มมีค่าเป็น -1 ดังนั้นแล้วจะไม่มีกลุ่มตัวอย่างใดเลยที่มีค่าอยู่ระหว่างช่วง -1 ถึง 1 ดังรูปที่ 2.4 ซึ่งสามารถแสดงเป็นสมการข้อจำกัดได้ดังสมการที่ (2.3)

$$y_i[\langle w, x_i \rangle + b] \geq 1 ; i = 1, \dots, 1 \quad (2.3)$$

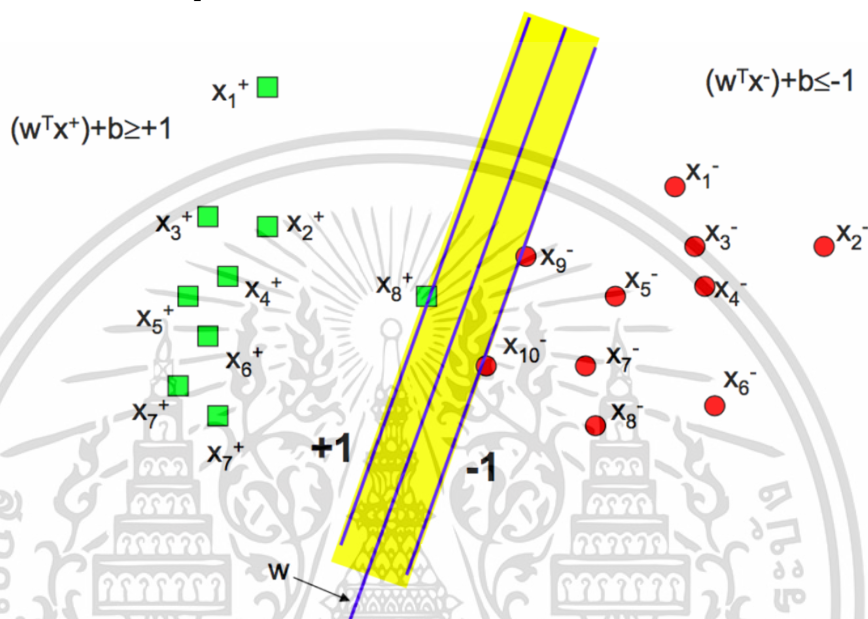
โดยที่ x_i คือกลุ่มตัวอย่างข้อมูลในชุดข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

y_i คือค่าตอบของตัวอย่างข้อมูลซึ่งเป็น -1 กับ 1

w, b คือพารามิเตอร์ของระนาบแบบจำลอง

ในขั้นตอนของการสร้างระนาบจะพิจารณาถึงระยะห่างของ (Support Vector) ทั้งสองกลุ่มมากที่สุด และเส้นตรงที่ลากผ่าน (Support Vector) ทั้งสองกลุ่ม มีสมการว่า $w^T x + b \geq 1$ และ $w^T x + b \leq -1$ ดังรูปที่ 2.4



รูปที่ 2.4 รูปจำลองการแบ่งคลาสและการกำหนดสมการ

ซึ่งหากพิจารณาคุณสมบัติของเส้นตรงสองเส้นนี้ด้วยกฎทางเรขาคณิต จะได้ว่าเส้นตรงทั้งสองเส้นห่างกัน $\frac{2}{\|w\|}$ หน่วย ดังนั้นแล้ว การสร้างระยะห่างของ (Support Vector) ทั้งสองกลุ่มให้มีค่ามากที่สุด ทำได้โดยพยายามทำให้ค่าของ $\|w\|$ มีน้อยที่สุด และสามารถกำหนดได้ดังสมการที่ (2.4)

$$\phi(w) = \frac{1}{2} \|w\|^2 \quad (2.4)$$

โดยที่ ϕ คือฟังก์ชันเป้าหมายที่ต้องการหาจุดที่เหมาะสมที่สุด

ซึ่งโจทย์ปัญหาคือการหาค่าที่ต่ำที่สุดโดยมีสมการ (2.3) เป็นสมการข้อจำกัด การหาค่าที่เหมาะสมที่สุดด้วยเงื่อนไขดังกล่าวจะใช้เทคนิคลากรางจ์มัลติพลายเออร์ (Lagrange Multiplier) โดยใช้สมการ (2.4) เป็นสมการจุดประสงค์หลักและใช้สมการ (2.3) เป็นฟังก์ชันข้อจำกัดสร้างลากรางจ์ฟังก์ชัน (Lagrange function) ได้ดังสมการ (2.5)

$$\phi(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i (y_i [\langle w, x_i \rangle + b] - 1) \quad (2.5)$$

โดยที่ α_i คือคิลากรานจ์มัลติพลีเออร์

เมื่อทำกระบวนการหาค่าที่เหมาะสมที่สุดด้วยแกรนดฟังก์ชัน จะได้สมการจุดประสงค์ในรูปแบบของปัญหาคู่กัน (Dual problem) ดังสมการที่ (2.6)

$$\alpha^* = \arg \min_{\alpha} \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j (x_i, x_j) - \sum_{k=1}^l \alpha_k \quad (2.6)$$

และมีสมการข้อจำกัดดังสมการที่ 2.7

$$0 \leq \alpha_i \leq C ; i = 1, \dots, l$$

$$\sum_{j=1}^l \alpha_j y_j = 0 \quad (2.7)$$

จากตัวอย่างข้อมูลที่ผ่านมาสมการข้อจำกัดจะถูกเลือกเป็น (Support Vector) โดยที่ภายในแบบจำลองของ (Support Vector Machine) จะทำการเก็บตัวอย่างที่เป็น (Support Vector) สำหรับใช้ในการแบ่งกลุ่มของข้อมูลอื่น ๆ ต่อไปการใช้งานแบบจำลองของ (Support Vector Machine) จะใช้ในสมการ (2.8)

$$h(x) = \text{sign}[\sum_{j=1}^l \alpha_j y_j \langle x, x_j \rangle + b] \quad (2.8)$$

โดยที่ α_i, y_i, x_i คือค่าของ (Support Vector) ภายในแบบจำลองแต่ละตัว

x คือตัวอย่างข้อมูลที่ต้องการหาค่าตอบ

โดยถ้าหากผลของการคำนวณได้ค่าเป็นบวกก็สรุปได้ว่าอยู่กลุ่มที่มีค่าเป็น +1 และถ้าผลการคำนวณก็สรุปได้ว่าอยู่กลุ่มเดียวกับกลุ่มที่มีค่าเป็น -1

จากหลักการที่ได้กล่าวมาในข้างต้นนั้นเป็นการสร้างแบบจำลองและใช้งาน (Support Vector Machine) แบบเชิงเส้น ซึ่งหากต้องการจัดการกับชุดข้อมูลที่ไม่เป็นรูปแบบของสมการเชิงเส้นสามารถทำได้โดย

1. ใช้ฟังก์ชัน (Penalty Function) ซึ่งเป็นฟังก์ชันของตัวแปร ξ_i เป็นตัวแปรถ่วงน้ำหนักให้แก่ความสัมพันธ์ระหว่างความผิดพลาดในชุดข้อมูลการสอนกับความเสียหายในชุดข้อมูลแบบทดสอบ พิจารณาสมการข้อจำกัดในสมการที่ (2.9) โดยสมการนี้ใช้สำหรับชุดข้อมูลที่ไม่มีรูปแบบเป็นสมการเชิงเส้น

$$y_i [\langle w, x_i \rangle + b] \geq 1 - \xi_i ; i = 1, \dots, l \quad (2.9)$$

เมื่อตัวแปร ξ มีค่ามากกว่า 0 โดยตัวแปร ξ เปรียบเสมือนค่าที่อนุญาตให้มีความผิดพลาดเกิดขึ้นได้มากเมื่อตัวแปรที่มีค่ามากขึ้น ดังนั้นหากค่าของ ξ_i โดยรวมมากขึ้นจะส่งผลให้ข้อมูลอยู่ผิดตำแหน่งและทำให้ข้อมูลอยู่ไกลจากบริเวณที่ควรอยู่ได้มากขึ้น และทำให้แบบขั้นตอนวิธีจะให้ความสำคัญกับระยะห่างของ (Support Vector) ทั้ง 2 กลุ่ม

มากขึ้น โดยที่ให้ความสำคัญกับความถูกต้องในการจำแนกประเภทข้อมูลน้อยลง และในทางกลับกันหากภาพรวมของตัวแปร ξ_i มีค่าน้อยลงจะทำให้ขั้นตอนวิธีสนใจความถูกต้องในการจำแนกมากขึ้น ดังนั้นการควบคุมขนาดของตัวแปร ξ_i จึงมีความสำคัญมากและต้องมีการกำหนดพารามิเตอร์ใหม่ขึ้นมาเพื่อควบคุมขนาดของ ξ_i ซึ่งปัญหานี้ถูกแก้ไขได้โดยกำหนดสมการจุดประสงค์ใหม่ดังสมการที่ (2.10)

$$\phi(w) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i \quad (2.10)$$

เนื่องจากภายในสมการจุดประสงค์นี้จะถูกทำให้มีค่าต่ำที่สุดด้วยขั้นตอนวิธี ดังนั้นแล้วจะสังเกตได้ว่าถ้าหากค่า C มีค่ามากภาพรวมของตัวแปร ξ_i จะถูกบีบให้ค่าน้อยลงโดยอัตโนมัติ แต่หากค่า C มีค่าน้อยขั้นตอนวิธีจะอนุญาตให้ ξ_i มีค่าได้มาก เพื่อให้ความสำคัญแก่ระยะห่างของ (Support Vector) ทั้งสองกลุ่มมากที่สุดหรือกล่าวคือมีค่าของ $\|w\|$ ต่ำสุด โดยในส่วนของ การหาค่าของ (Support Vector) จะใช้วิธีการลากรางจ์ มัลติพลีเออร์ จากสมการที่ (2.9) และ (2.10) แสดงดังสมการที่ (2.11)

$$\phi(w, b, \alpha) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_{i=1}^l \alpha_i (y_i [\langle w, x_i \rangle + b] - 1 + \xi_i) + \sum_{i=1}^l \beta_i \xi_i \quad (2.11)$$

จากนั้นจึงใช้วิธีการหาค่าตอบเช่นเดียวกับการหา (Support Vector) แบบปกติ

- ใช้เคอร์เนลทริค (Kernel Trick) โดยเทคนิคนี้จะทำการย้ายตัวอย่างในชุดข้อมูลจากระนาบของคุณลักษณะที่ป้อนเข้ามาเป็นระนาบใหม่ที่มีมิติมากขึ้นโดยผ่านฟังก์ชันคณิตศาสตร์ใดๆซึ่ง เคอร์เนลทริค จะเข้าไปแทนในส่วนของ (x_i, x_j) ในขั้นตอนปัญหา คู่กัน ในขั้นตอนการสอนแบบจำลองของขั้นตอนวิธี โดยจากสมการที่ 2.6 สามารถนำมาเขียนให้อยู่ในรูปของการใช้เคอร์เนลฟังก์ชัน (Kernel Function) ได้สมการที่ (2.12)

$$\alpha^* = \arg \min_{\alpha} \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{k=1}^l \alpha_k \quad (2.12)$$

โดยที่ $K(x_i, x_j)$ คือเคอร์เนลฟังก์ชัน

เคอร์เนลฟังก์ชันคือฟังก์ชันที่ทำหน้าที่แปลงข้อมูลที่อยู่ในระนาบของคุณลักษณะเดิมที่อาจไม่สามารถจำแนกประเภทด้วยสมการเส้นตรงได้ ให้เป็นระนาบใหม่ซึ่งมีมิติมากกว่า โดยการใช้เส้นตรงแบ่งแยกข้อมูลในระดับดังกล่าวผ่านเคอร์เนลฟังก์ชันที่กำหนด ดังนั้นแล้วการเลือกเคอร์เนลฟังก์ชัน และพารามิเตอร์ของเคอร์เนลจึงเป็นอีกหนึ่งปัญหาที่ต้องพิจารณาในการจำแนกข้อมูลประเภทชุดข้อมูลไม่เป็นเชิงเส้น โดยเคอร์เนลทริคที่ได้รับความนิยมมากที่สุดมีดังนี้

$$1) \text{ Linear kernel: } K(x_i, x_j) = \langle x_i, x_j \rangle$$

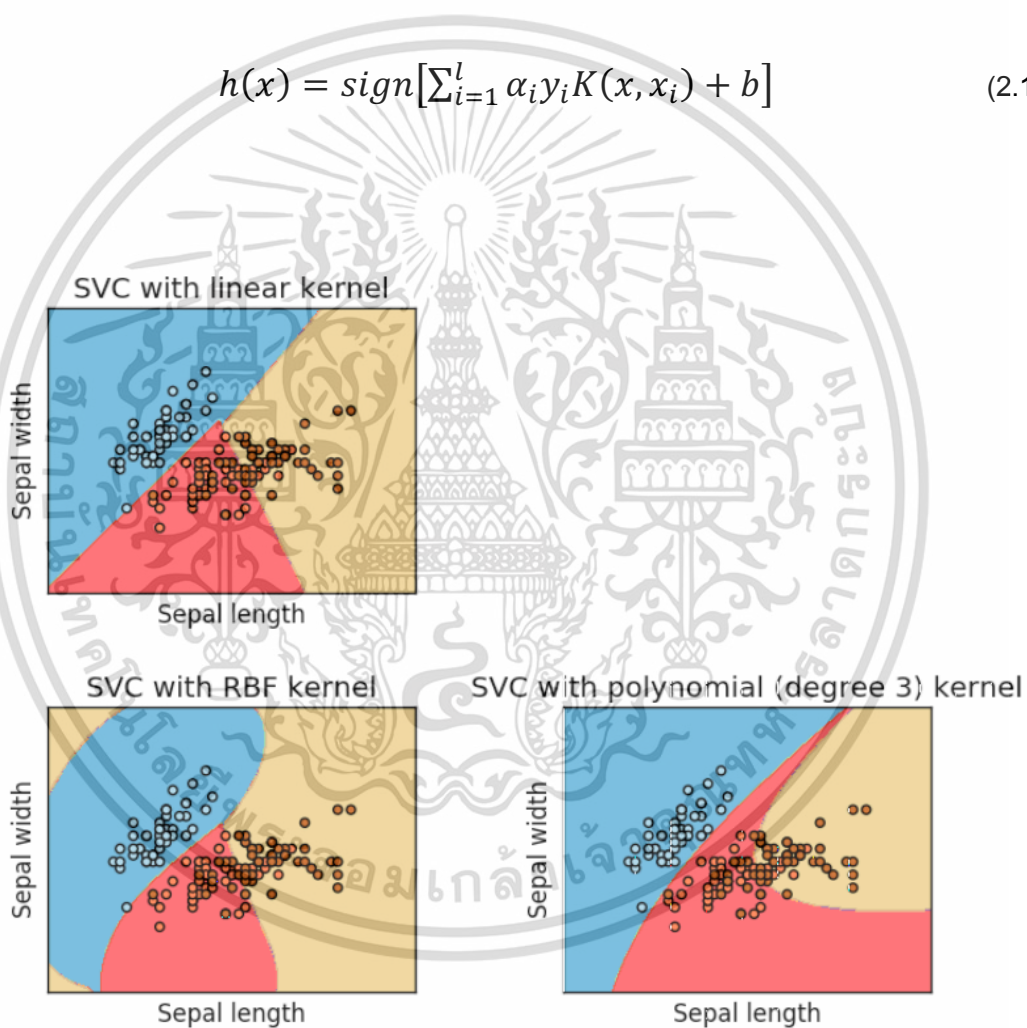
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2) Polynomial kernel: $K(x_i, x_j) = (\gamma \cdot \langle x_i, x_j \rangle + r)^d$

3) Radial Basis Function (RBF) kernel: $K(x_i, x_j) = \exp(-\gamma \cdot |x_i - x_j|^2)$; $\gamma > 0$

ซึ่งลักษณะของทั้งสาม Kernel มีลักษณะดังรูปที่ 2.5 นอกจากนั้นแล้วในขั้นตอนการทำนายยังต้องใส่เคอร์เนลเข้าไปในสมการทำนายด้วยดังสมการที่ (2.13)

$$h(x) = \text{sign}[\sum_{i=1}^l \alpha_i y_i K(x, x_i) + b] \quad (2.13)$$



รูปที่ 2.4 ลักษณะการแบ่งแยกคลาสข้อมูลของ Kernel ทั้งสาม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2 การเรียนรู้คุณลักษณะและการเรียนรู้เชิงลึก


การเรียนรู้ของเครื่องจักรนั้นได้ถูกนำมาต่อยอดเป็นการเรียนรู้เชิงลึก โดยที่การเรียนรู้เชิงลึกคือศาสตร์ที่เข้าไปแก้ปัญหาดั้งเดิมของปัญญาประดิษฐ์มากยิ่งขึ้น การเรียนรู้เชิงลึกจะอาศัยหลักการในการเรียนรู้หลายลำดับขั้นต่อกันเพื่อทำความเข้าใจในข้อมูลนั้น ๆ จากแหล่งข้อมูลโดยตรง ตัวอย่างเช่น การทำความเข้าใจในรูปภาพ การทำความเข้าใจในข้อมูลเชิงเวลา เป็นต้น สำหรับขั้นตอนวิธีในการเรียนรู้ขั้นสูงสามารถเรียนรู้จากแหล่งข้อมูลได้โดยตรง เนื่องจากขั้นตอนวิธีมีกลไกในการสกัดคุณลักษณะออกมาโดยอัตโนมัติสามารถเรียกได้ว่าเป็นกระบวนการเรียนรู้คุณลักษณะ (Feature Learning)

สำหรับขั้นตอนวิธีของการเรียนรู้เชิงลึกที่มีลักษณะความสามารถในการเรียนรู้ดังกล่าวนั้นมีหลากหลายอัลกอริทึมและสามารถเลือกให้เหมาะสมกับงานแต่ละแบบได้โดยในงานวิจัยขั้นตอนนี้สนใจในการใช้การเรียนรู้เชิงลึกในขอบข่ายของคอมพิวเตอร์วิทัศน์ ที่เป็นการใช้ขั้นตอนวิธีกับข้อมูลภาพ โดยมีขั้นตอนวิธีที่นิยมคือโครงข่ายประสาทเทียมแบบสังวัตนาการ ซึ่งมีพื้นฐานมาจากโครงข่ายประสาทเทียมแบบปกติที่กล่าวมาในหัวข้อ 2.1.1 โดยมีรายละเอียดดังต่อไปนี้

2.2.1 โครงข่ายประสาทเทียมแบบสังวัตนาการ

โครงข่ายประสาทเทียมแบบสังวัตนาการ เป็นขั้นตอนวิธีที่มีโครงสร้างพื้นฐานเป็นโครงข่ายประสาทเทียมชนิดหนึ่ง โดยในโครงข่ายประสาทเทียมแบบทั่วไปจะมีลักษณะแบบเดียวกันในแต่ละลำดับขั้นคือในแต่ละชั้นจะเชื่อมต่อและปฏิสัมพันธ์กันกับปมประสาทในชั้นไปยังปมอื่น ๆ ทุกปม (Fully Connected) แต่สำหรับในส่วนของโครงข่ายประสาทเทียมแบบสังวัตนาการ มีโครงสร้างที่หลากหลายซึ่งการเรียนรู้จักภาพโดยมีโครงสร้างลำดับขั้นหลัก ๆ ดังนี้

2.2.1.1 ชั้นสังวัตนาการ (Convolutional Layer)



รูปที่ 2.5 การทำงานของตัวดำเนินการสังวัตนาการระหว่างมาส์กับปริมาตรข้อมูลขาเข้า


คุณลักษณะโดยอัตโนมัติดังรูปที่ 2.7 ซึ่งแสดงถึงตัวอย่างการทำงานของโครงสร้างชั้นสังวัตนาการ เปรียบเสมือนการปรับน้ำหนักให้แก่การเรียนรู้ของข้อมูล ซึ่งทำให้สามารถหาปริมาตรของผลลัพธ์จากชั้นสังวัตนาการได้ โดยการ ใช้สมการที่ (2.14) กำหนดข้อมูลภาพที่รับเข้ามา

$$\begin{aligned} B_0 &= (B - F + 1) \\ H_0 &= (H - F + 1) \\ D_0 &= M \end{aligned} \quad (2.14)$$

โดยที่ M	คือจำนวนหน้ากอก
F	คือความกว้างของหน้ากอก
B	คือความกว้างของข้อมูลภาพ
H	คือความสูงของข้อมูลภาพ
B_0	คือความกว้างของปริมาตรผลลัพธ์
H_0	คือความสูงของปริมาตรผลลัพธ์
D_0	คือความลึกของปริมาตรผลลัพธ์

และจากสมการที่ 2.14 ที่กล่าวมาข้างต้นนั้น ตัวแปรที่คำนวณความกว้าง ความสูงและความลึกของปริมาตรผลลัพธ์ต้องเป็นค่าที่ยังไม่ผ่านการพิจารณาถึงขนาดในการเลื่อนหน้ากอก (Stride) และการทำสังวัตนาการแบบไม่ลดขนาด (Same Result Convolution) โดยใช้หลักการเติมเลข 0 ลงไปในส่วนเกินของภาพเรียกว่าซีโรแพดดิ้ง (Zero-padding) ถูกนำมาประยุกต์ใช้กับงานวิจัยชิ้นนี้ และวิธีการนี้จะทำให้ความกว้างและความยาวของปริมาตรผลลัพธ์เท่ากับภาพที่นำเข้ามาทำให้ง่ายต่อการคำนวณเพื่อปรับเปลี่ยนจำนวนโครงสร้างภายในชั้นต่างๆ

2.2.1.2 ชั้นการหยั่งสัญญาณ (Pooling Layer)



รูปที่ 2.8 แสดงผลลัพธ์ตัวอย่างในชั้นหยั่งสัญญาณด้วยฟังก์ชันหาค่าสูงสุด

(<https://medium.com/ai-in-plain-english/pooling-layer-beginner-to-intermediate-fa0dbdce80eb>)

จากหัวข้อที่ได้กล่าวมาข้างต้นได้กล่าวถึงชั้นสังวัตนาการซึ่งทำหน้าที่สกัดคุณลักษณะของข้อมูลผ่านกระบวนการเรียนรู้คุณลักษณะ แต่สำหรับการทำงานของชั้นสังวัตนาการนั้นจะไม่สามารถทำให้ขนาดของคุณลักษณะในแต่ละเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


มิติมีขนาดลดลงได้ และในจุดนั้นอาจส่งผลทำให้เกิดปัญหาตามมาในภายหลังเช่น (Overfitting) หรือการที่ทำให้แบบจำลองมีความซับซ้อนเกินกว่าความจำเป็น เป็นต้น โดยชั้นการหึงสัญญาณจะมีหน้าที่ลดขนาดในแต่ละมิติลง ส่งผลให้จำนวนพารามิเตอร์ในชั้นถัดไปมีจำนวนลดลง การทำงานของชั้นหึงสัญญาณจะเป็นลักษณะของการเลื่อนหน้ากากเช่นเดียวกับกับชั้นสังวัตนาการ แต่หน้ากากของชั้นนี้จะทำหน้าที่เป็นตัวสรุปข้อมูลในบริเวณที่เลื่อนไปด้วยฟังก์ชันทางคณิตศาสตร์แทนการดำเนินการด้วยผลคูณของชั้นสังวัตนาการ เช่น การหาค่าสูงสุด (Max) การหาค่าเฉลี่ย (Mean) เป็นต้น ดังรูปที่ 2.6 ที่สามารถหาปริมาณของผลลัพธ์จากชั้นการหึงสัญญาณได้สามารถเขียนเป็นสมการได้ ดังเช่นสมการที่ (2.15)

$$\begin{aligned} B_0 &= (B - F)/S + 1 \\ H_0 &= (H - F)/S + 1 \\ D_0 &= D \end{aligned} \quad (2.15)$$

โดยที่ S คือขนาดของการเลื่อนหน้ากาก

D คือความลึกของข้อมูลภาพ

จะสังเกตเห็นว่าการดำเนินการในชั้นการหึงสัญญาณ จะไม่กระทบต่อความลึกของปริมาตรข้อมูลที่เข้ามาและส่วนที่จำเป็นต้องพิจารณาเป็นพิเศษคือขนาดของการเลื่อนหน้ากากซึ่งส่งผลต่อการลดขนาดในแต่ละมิติของปริมาตร แม้ว่า การเลื่อนหน้ากากจะสามารถระบุได้ตั้งแต่ชั้นสังวัตนาการ แต่ก็ยังไม่เป็นที่นิยม เนื่องจากการดำเนินการในชั้นสังวัตนาการมากนัก เนื่องจากภายในชั้นเป็นการสกัดคุณลักษณะหากมีการกระโดดข้ามไปยังส่วนใดส่วนหนึ่งของภาพอาจทำให้ข้อมูลที่สำคัญตกลงหายไปได้ส่วนต่างจากการใช้ชั้นการหึงสัญญาณ การดำเนินการของหน้ากากเป็นเพียงฟังก์ชันทางคณิตศาสตร์ที่ทำหน้าที่สรุปข้อมูลในบริเวณนั้นเท่านั้น



รูปที่ 2.9 แสดงการทำงานของหน้ากากในโครงสร้างการหึงสัญญาณ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ซึ่งโดยส่วนใหญ่แล้วโครงสร้างของชั้นการหยังสัญญาณจะผูกประกอบอยู่ ด้านหลังคอนโวลูชันเสมอและขนาดการเลื่อนหน้ากาก็จะถูกกำหนดให้มีขนาดเท่ากับหน้ากาดังภาพที่ 8 ซึ่งภายในงานวิจัยชิ้นนี้ได้ใช้วิธีดังกล่าวและกำหนดขนาดของหน้ากาคือ $2 * 2$

2.2.1.3 ชั้นการเชื่อมต่อโดยสมบูรณ์ (Fully connected Layer)

ชั้นการเชื่อมต่อโดยสมบูรณ์จะเป็นชั้นที่มักจะถูกกว่าเอาไว้เป็นชั้นสุดท้ายในโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยมีโครงสร้างและรูปแบบการทำงานเหมือนโครงข่ายประสาทเทียมโดยทั่วไปประกอบไปด้วย ชั้นรับข้อมูล ชั้นแอบแฝงและชั้นส่งออก สิ่งที่ต้องพิจารณาเป็นพิเศษสำหรับโครงสร้างในชั้นนี้คือจำนวนปมประสาทในชั้นรับข้อมูลเนื่องจากในชั้นรับข้อมูลต้องรับค่าจากชั้นที่มีโครงสร้างอยู่ในลักษณะของปริมาตรซึ่งสามารถหาขนาดของชั้นรับข้อมูลได้โดยกำหนดข้อมูลที่รับเข้ามามีความกว้าง สูง ลึก เพื่อคำนวณหาจำนวนปมประสาทของชั้นรับข้อมูลได้ว่า กว้างxสูงxลึก ในส่วนของชั้นแอบแฝงและชั้นส่งออกให้พิจารณาเหมือนโครงข่ายประสาทเทียมแบบปกติ

สำหรับการพิจารณาลำดับโครงสร้างของโครงข่ายประสาทเทียมแบบสังวัตนาการ จะไม่มีกฎเกณฑ์ที่ใช้อย่างตายตัว ทำให้ผู้ใช้จำเป็นต้องทำความเข้าใจในโครงสร้างแบบต่าง ๆ ก่อนจึงจะเลือกใช้ตามความเหมาะสมของงานได้ โดยสังเกตได้จากความซับซ้อนของชุดข้อมูลนั้น ๆ นอกจากนี้แล้วโครงข่ายประสาทเทียมแบบสังวัตนาการยังมีปัญหาเรื่องความเหมาะสมของชุดข้อมูลสำหรับสอนมากเกินไป ในกรณีที่ชุดข้อมูลมีขนาดเล็กเนื่องจากขั้นตอนวิธีมีพื้นฐานมาจากโครงข่ายประสาทเทียมแบบหนึ่ง ซึ่งเทคนิคในการแก้ปัญหาความเหมาะสมกับชุดข้อมูลผู้สอนมากเกินไป จะถูกกล่าวถึงในหัวข้อบททวนวรรณกรรมที่เกี่ยวข้อง

สำหรับกลไกการสกัดคุณลักษณะด้วยแนวทางการเรียนรู้คุณลักษณะนั้นจะใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ ผ่านการเรียนรู้ข้อมูลแล้วจึงนำมาใช้โดยป้อนข้อมูลเข้าไปยังโครงข่าย แล้วจึงนำค่าผลลัพธ์ที่ได้ในชั้นกลางก่อนเข้าสู่ชั้นเชื่อมต่อสมบูรณ์มาเป็นชุดคุณลักษณะของข้อมูลที่ป้อนเข้าไป เนื่องจากกระบวนการสกัดคุณลักษณะสิ้นสุดลงแล้วในชั้นดังกล่าว

2.3 วิศวกรรมคุณลักษณะและการประมวลผลภาพ

อีกหนึ่งกระบวนการการสกัดคุณลักษณะกำลังจะกล่าวถึงคือวิศวกรรมคุณลักษณะ โดยกระบวนการวิศวกรรมคุณลักษณะคือกระบวนการที่พยายามสั่งให้คอมพิวเตอร์ทำการดึงลักษณะเด่นของข้อมูลนั้น ๆ ออกมาให้มากที่สุด เนื่องจากคุณลักษณะที่ดีจะส่งผลให้ขั้นตอนวิธีที่สร้างแบบจำลองในการจำแนกข้อมูลมีประสิทธิภาพสูงตามไปด้วย และกระบวนการนี้จำเป็นต้องอาศัยความรู้เกี่ยวกับข้อมูลอย่างละเอียด ซึ่งต่างจากการเรียนรู้คุณลักษณะที่สามารถเรียนรู้ได้โดยอัตโนมัติดังที่กล่าวถึงในหัวข้อ 2.3 ภายใต้งานวิจัยขั้นนี้ขั้นตอนวิธีจะดำเนินการพร้อมกับข้อมูลภาพใบหน้าผู้หญิงซึ่งเป็นข้อมูลภาพดิจิทัล ทำให้กระบวนการวิศวกรรมคุณลักษณะนี้เหมาะสำหรับงานที่ต้องอาศัยเทคนิคการประมวลผลภาพ

เทคนิคการประมวลผลภาพหมายถึง เทคนิคในการประมวลผลสัญญาณที่มีมากกว่า 1 มิติซึ่งสัญญาณที่นำมาประมวลผลนั้นอาจอยู่ในรูปของเมทริกซ์หรือปริมาตรโดยการประมวลผลสัญญาณที่มีลักษณะมากกว่า 1 มิตินั้นจะก่อให้เกิดผลลัพธ์ได้หลายรูปแบบขึ้นอยู่กับจุดประสงค์ที่ต้องการนำผลลัพธ์ไปใช้หลังจากประมวลผลเช่นภาพที่ถูกปรับปรุงแล้วหรือค่าตัวเลขกับภาพที่นำไปใช้ตีความต่อซึ่งในแง่มุมมองของจุดมุ่งหมายของการประมวลผลภาพตลอดเทคนิคนี้จะใช้ในการแก้ปัญหาในขอบข่ายของคอมพิวเตอร์วิทัศน์ซึ่งแบ่งได้เป็น 3 ระดับดังนี้

1. การประมวลผลระดับล่าง (Low-level process) เช่น การลบสัญญาณรบกวนหรือการมองหาภาพที่ไม่ชัดเจน เป็นต้น กระบวนการนี้จะได้ผลลัพธ์ออกเป็นสัญญาณภาพเรียกว่าขั้นตอนการปรับปรุงเปลี่ยนแปลงภาพ (Preprocessing)
2. การประมวลผลระดับกลาง (Mid-level Process) เช่น การตัดส่วนของภาพการหาค่าที่แสดงถึงลักษณะ (Attribute) พื้นผิว เป็นต้นซึ่งกระบวนการนี้ผลลัพธ์ที่ได้จะมีคุณลักษณะโดยอาจเรียกว่าขั้นตอนการสกัดคุณลักษณะของภาพ (Feature Extraction)
3. การประมวลผลระดับสูง (High-level Process) เช่น การทำความเข้าใจในรูปภาพ การจำแนกประเภทวัตถุที่ได้รับเข้ามา เป็นต้น ในกระบวนการนี้จะได้ผลลัพธ์เป็นความหมายจากการตีความ (Understanding) โดยเรียกว่าขั้นตอนการตีความอย่างมนุษย์ (Human Interpretation) และในขั้นตอนนี้ต้องอาศัยองค์ความรู้ในขอบข่ายของปัญญาประดิษฐ์มาประยุกต์ใช้ด้วย

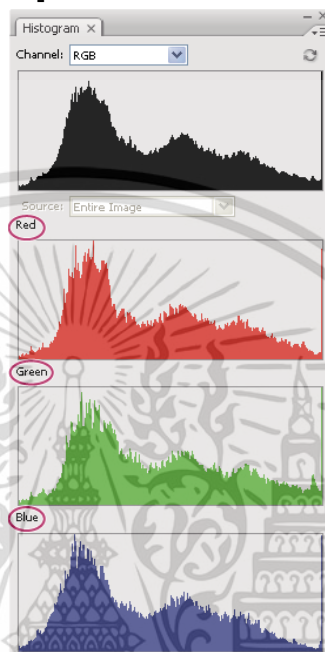
2.3.1 คุณลักษณะพื้นฐานของภาพ (Low-level Feature of Image)

โดยพื้นฐานของภาพแล้วจะมีลักษณะมูลฐานซึ่งเป็นสิ่งสำคัญและเป็นส่วนประกอบในทุกรูปภาพซึ่งจะประกอบไปด้วย

1. สี (Color) เป็นคุณลักษณะที่ง่ายที่สุดในบรรดาคุณลักษณะของภาพทั้งหมด โดยในแต่ละพิกเซลภาพดิจิทัลจะทำการเก็บข้อมูลในรูปแบบต่าง ๆ เช่น ภาพขาวดำจะทำการเก็บค่า 0 ถึง 255 ไว้ โดยที่ค่า 0 จะแสดงสีเป็นสีดำและ 255 จะแสดงสีเป็นสีขาวหรือในรูปที่มีความลึกของการนำเสนอมากขึ้นมาเช่นภาพ 24 Bit หรือที่เรียกว่าภาพอาร์จีบี (RGB)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ยิ่งไปกว่านั้นในขอบข่ายการประมวลผลภาพอาจใช้ภาพที่มีความละเอียดในแนวลึกมากขึ้นไปอีกก็ได้โดยทั่วไปแล้วการนำข้อมูลสีไปใช้จะถูกแบ่งค่าเป็นช่วงสีต่าง ๆ และนำไปวิเคราะห์ในรูปแบบของภาพแฉ่งความถี่ (Histogram) ซึ่งเป็นลักษณะของข้อมูลของสีทั้งสามสีคือสีแดงสีเขียวและสีฟ้า ดังรูปที่ 2.10



รูปที่ 2.10 ลักษณะของ Histogram

2. ลักษณะต่อมาคือรูปร่าง (Shape) ลักษณะพื้นฐานที่มีความเกี่ยวข้องกับการอธิบายรูปร่างของวัตถุภายในภาพ การพิจารณารูปร่างอาจเกิดจากการลากผ่านเส้นรอบขอบหรือเส้นขอบบริเวณโดยรอบของวัตถุที่มีสีแตกต่างจากส่วนอื่นภายในภาพ โดยทั่วไปแล้วการนำข้อมูลรูปร่างไปวิเคราะห์จะทำการแปลงข้อมูลของวัตถุนี้เป็นค่าทางตัวเลขผ่านเทคนิคเฉพาะเช่น ฟูเรียร์ดีสคริปเตอร์ (Fourier Descriptor) [10]
3. พื้นผิว (Texture) เป็นคุณลักษณะพื้นฐานที่แสดงในส่วนตัวส่วนหนึ่งของภาพซึ่งหากมีการลำดับสีหรือลำดับความสว่างไว้ในภาพก็สามารถส่งผลทำให้เกิดคุณลักษณะพื้นผิวที่ต่างกันได้ เช่น ความขรุขระความเรียบ ในแต่ละส่วนของภาพการวิเคราะห์พื้นผิวในเชิงตัวเลขจะใช้ค่าที่เกิดจากการคำนวณค่าสีในบริเวณนั้นประกอบเข้าด้วยกันในการแสดงคุณลักษณะของพื้นผิวดังกล่าวเพื่อทำการวิเคราะห์ต่อไป โดยมีค่าพื้นฐานที่ต้องใช้ซึ่งคำนวณได้จากค่าสีในบริเวณโดยรอบคือ ค่าความขัดแย้ง (Contrast) สหสัมพันธ์ (Correlation) และเอนโทรปี (Entropy)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับการหาตำแหน่งบริเวณใบหน้าของมนุษย์ในงานวิจัยชิ้นนี้จะใช้เทคนิคการประมวลผลภาพหลัก ๆ ทั้งหมด 2 เทคนิค คือการตัดส่วนของภาพโดยใช้โดเมนสี ซึ่งจะใช้เทคนิคในการการแยกส่วนที่เป็นสีผิวของมนุษย์ออกจากองค์ประกอบภายนอกของภาพ และอีกเทคนิคคือการหาตำแหน่งของขอบหน้าผากและใช้รูปการจำลองรูปลักษณะ ซึ่งมี (Accuracy) มากกว่าในการค้นหาบริเวณต่าง ๆ บนใบหน้า และทั้งสองวิธีนี้จะสามารถทำให้ได้องค์ประกอบสำคัญสำหรับสร้างชุดคุณลักษณะสำหรับใช้กับแบบจำลองต่อไปได้

2.3.2 การตัดส่วนของภาพด้วยโดเมนสี (Color-based Segmentation)

การตัดส่วนของภาพด้วยโดเมนสีเป็นเทคนิคที่ง่ายที่สุดในการสกัดส่วนที่สนใจออกมาจากภาพ สามารถทำได้โดยการกำหนดช่วงสีที่ต้องการเป็นเงื่อนไขและตัดช่วงสีที่ไม่ต้องการออกไป โดยโดเมนสีที่นำมาตั้งเป็นเงื่อนไขในการเลือกอาจจะเป็นโดเมนเฉดสีเทา อาร์จีบี เอชเอชวี เป็นต้น สำหรับการตัดส่วนของภาพด้วยโดเมนสี มีข้อเสียที่เห็นได้ชัดคือความไม่ทนทานต่อลักษณะของภาพที่มีความหลากหลายสูง มีปริมาณแสงสูง รวมถึงความละเอียดในการการตัดภาพออกมามีคุณภาพที่ค่อนข้างต่ำ อาจหลงเหลือส่วนที่ไม่ต้องการหรืออาจตัดล้ำเข้ามาในส่วนของวัตถุที่ต้องการเก็บได้

2.3.3 แบบจำลองรูปลักษณะ (Active Appearance Model)

แบบจำลองรูปลักษณะเป็นแบบจำลองทางสถิติ ใช้เพื่อถอดลักษณะเชิงปรากฏของวัตถุภายในภาพซึ่งเป็นแบบจำลองที่มีประสิทธิภาพในการหารูปร่างของวัตถุที่แบบจำลองถูกสอนมา แบบจำลองรูปลักษณะนี้มีความทนทานต่อความหลากหลายของภาพมากกว่าเทคนิคการตัดส่วนของภาพด้วยโดเมนสี รวมถึงทนทานต่อการเปลี่ยนแปลงภาพเชิงเรขาคณิตมากกว่า เช่น การสะท้อน การหมุน เป็นต้น แบบจำลองรูปลักษณะมีแนวคิดพื้นฐานมาจากแบบจำลองรูปร่างที่ทำงานในลักษณะเดียวกัน เพียงแต่แบบจำลองรูปร่างจะมีการต่อยอดเทคนิคบางอย่างเพื่อเพิ่มเติมประสิทธิภาพ โดยในที่นี้จะทำการอธิบายหลักการพื้นฐานของทั้ง 2 แบบจำลองซึ่งขั้นตอนการสร้างแบบจำลองสามารถอธิบายได้ดังนี้

1. กำหนดจุดสำคัญ (Landmark) ต่าง ๆ ในภาพจำนวน L จุด และแต่ละจุดจะถูกนำเสนอด้วยเวกเตอร์ s ดังที่แสดงในสมการ 2.15
- 2.

$$s = [p_1^x, p_1^y, \dots, p_L^x, p_L^y] \quad (2.15)$$

โดยที่ s	คือเวกเตอร์
L	คือจำนวนของจุดสำคัญในภาพ
p_i^x	คือตำแหน่งในแนวนอนลำดับที่ i ของจุดสำคัญ
p_i^y	คือตำแหน่งในแนวตั้งลำดับที่ i ของจุดสำคัญ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. นำเวกเตอร์ s ของภาพทุกภาพมาสร้างแบบจำลองด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เพื่อสร้างเวกเตอร์ลักษณะเฉพาะ U_s ดังสมการที่ 2.16 เพื่อเป็นตัวกำหนดทิศทางที่สามารถมีผลทำให้เปลี่ยนทิศทางไปยังคุณลักษณะที่เป็นตำแหน่งของจุดอ้างอิงทั้งหมดได้และเป็นทิศทางของคุณลักษณะที่มีขนาดเล็กลง ซึ่ง U_s สามารถเป็นชุดเวกเตอร์ขนาดใด ๆ เป็นเวกเตอร์ที่มีขนาด $2L$ ได้นอกจากนั้นยังได้ \bar{s} ซึ่งเป็นค่าเฉลี่ยของรูปร่างขนาดของ $2L$.15

$$s = \bar{s} + U_s a \quad (2.16)$$

โดยที่ \bar{s} คือค่าเฉลี่ยของรูปร่างขนาดของเวกเตอร์

U_s คือเวกเตอร์ลักษณะเฉพาะ


a คือพารามิเตอร์รูปทรงในภาพใด ๆ

จากขั้นตอนที่กล่าวมาข้างต้นจะแสดงสมการปริมาณตำแหน่งของจุดอ้างอิงที่ถูกระบุด้วยสมการ 2.16 และแบบจำลองลักษณะจะมีการเพิ่มประสิทธิภาพ Model โดยอ้างอิงจากข้อมูลอื่นเช่นระดับการปรากฏของเงตสีเทาอีกด้วย (Gray-level Appearance)

2.4 การทบทวนวรรณกรรมที่เกี่ยวข้อง


สำหรับเทคนิคทางวิทยาศาสตร์มีหลายกระบวนการที่ใช้วิธีการของ machine vision [1] ในการตรวจสอบและประเมินคุณภาพของเมล็ดข้าว โดยกระบวนการเหล่านั้นได้ถูกพัฒนาขึ้นภายในช่วงไม่กี่ปีที่ผ่านมา โดย V.S.Kolkure และ B.N.Shaikh [2] ได้ใช้ machine vision ในการประเมินคุณภาพของเมล็ดข้าว โดยมีการคัดเลือกจากคุณสมบัติของแกนเอก แกนโท พื้นที่ผิว และรูปทรงที่ผิดปกติของเมล็ด จากนั้นจึงนำคุณสมบัติเหล่านั้นใส่ในแบบจำลองโครงข่ายประสาทเทียม Probabilistic Neural Network (PNN) เพื่อที่จะคาดการณ์คุณภาพของเมล็ดข้าว

ต่อมา Dollawat Ngampak และ Punpiti Piamsa-nga [3] ได้นำเสนอการประเมินคุณภาพของเมล็ดข้าวโดยการเน้นไปที่การคัดเมล็ดข้าวที่แตกหัก แฉก ขนาดเล็กที่เสียแตกหัก และขนาดใหญ่เกินออกจากกระบวนการดังแสดงในรูปที่ 2.9 โดยใช้ Least-Square Support Vector Machine (LS-SVM) และ Radius Basis Function (RBF) โดยที่มี (Accuracy) มากถึง 98.20%



ภาพที่ 2.9 ตัวอย่างเมล็ดข้าวที่ไม่สมบูรณ์

P. Kongsawat, S. Chivapreecha และ T. Sato [4] ใช้ machine vision ในการวัดขนาดของเมล็ดข้าวดังแสดงในภาพที่ โดยมีการให้ผลลัพธ์ที่(Accuracy) กวาวีธีการวัดแบบ Scion และ Feret diameter

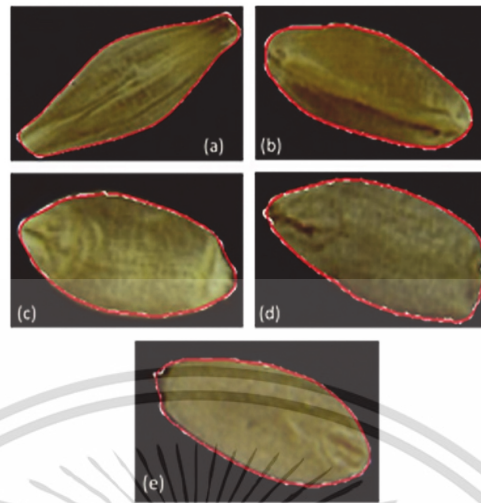


ภาพที่ 2.10 การลากเส้นวงรีสมมุติสีแดงและเส้นแกนสมมุติสีน้ำเงิน

Bhupinder Verma [5] ได้ทำการประยุกต์ใช้ machine vision และการประมวลผลภาพ (Image Processing) สำหรับการทำ Chalky kernel detection ซึ่งมีการแยกคุณสมบัติตามรูปทรงเรขาคณิต จากนั้นจึงนำส่งคุณสมบัติเหล่านั้นไปทำการฝึกฝน (Train) และทำนายผลลัพธ์ (Predict) ต่อโดยการใช้ Back-propagation Neural Network ส่งผลให้มี (Accuracy) มากถึง 90%


Harpreet Kaur และ Baljit Singh [6] ได้นำ Support Vector Machine มาใช้ประโยชน์ในการจำแนกคุณภาพของเมล็ดข้าว เพื่อแบ่งคุณภาพเป็นระดับต่าง ๆ ได้แก่ คุณภาพสูง ระดับเอ ระดับบี และระดับซี

H.K. Mebatsion, J. Paliwal และ D.S. Jayas [7] ใช้ machine vision ในการจำแนกชนิดของเมล็ดธัญพืช ได้แก่ เมล็ดข้าวบาร์เลย์ เมล็ดข้าวไรต์ เมล็ดข้าวโอ๊ตและเมล็ดข้าวสาลี ดังแสดงในรูปที่ 2.11 ซึ่ง (Accuracy) ในการจำแนกเมล็ดข้าวบาร์เลย์อยู่ที่ 98.5% สำหรับ CWRS อยู่ที่ 99.97% สำหรับเมล็ดข้าวโอ๊ตมี (Accuracy) อยู่ที่ 99.93% และ 100% สำหรับเมล็ดข้าวไรต์



รูปที่ 2.11 การวิเคราะห์รูปร่างของเมล็ดธัญพืชเพื่อจำแนกชนิดของเมล็ด

L.A.I.Pabamalie และ H.L.Premaratne [8] ได้ให้ความสนใจกับการจำแนกสิ่งแปลกปลอม การจำแนกการผสมกันของเมล็ดและการจำแนกเมล็ดข้าวกล้อง โดยการใช้ Back-propagation Neural Network ทำการทดสอบระบบของการฝึกและชุดทดสอบ ได้ผลลัพธ์ที่มี (Accuracy) อยู่ระหว่าง 94 – 68% สำหรับ 4 ระดับ และได้ทำการจำแนกคุณภาพเมล็ดข้าวออกเป็น 4 ประเภทตามหลายตัวแปรดังแสดงในรูปที่ 2.12



ภาพที่ 2.12 ตัวอย่างการจำแนกคุณภาพของเมล็ดข้าวเป็น 4 ประเภท

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

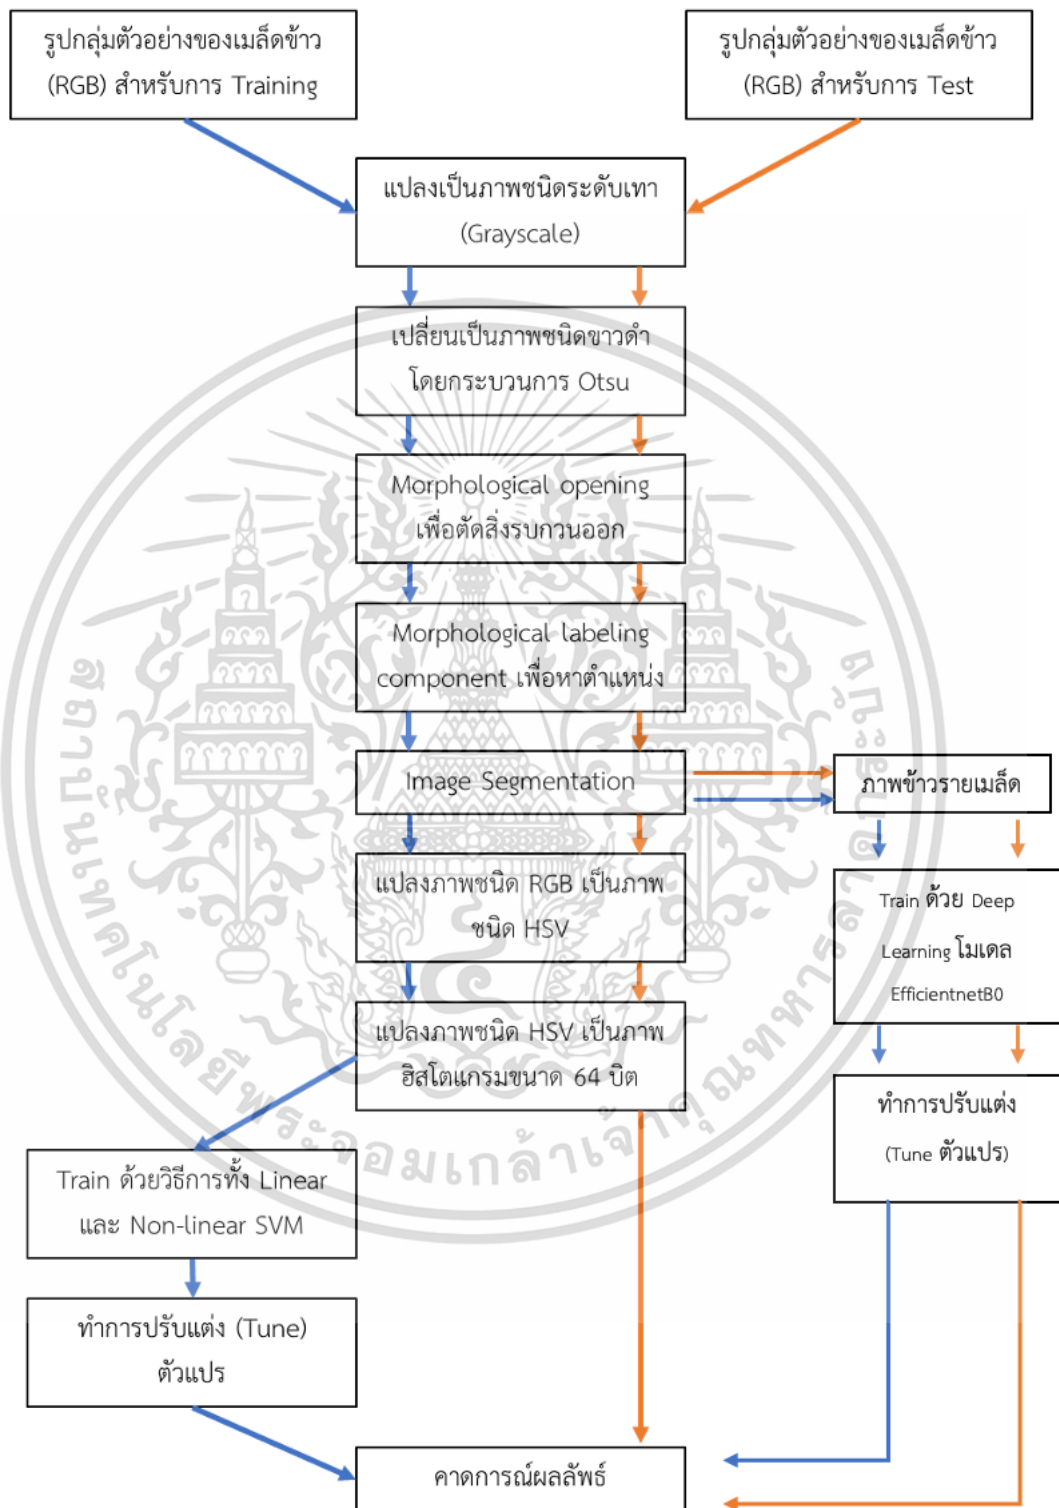
บทที่ 3

การออกแบบการทดลอง

3.1 บทนำ

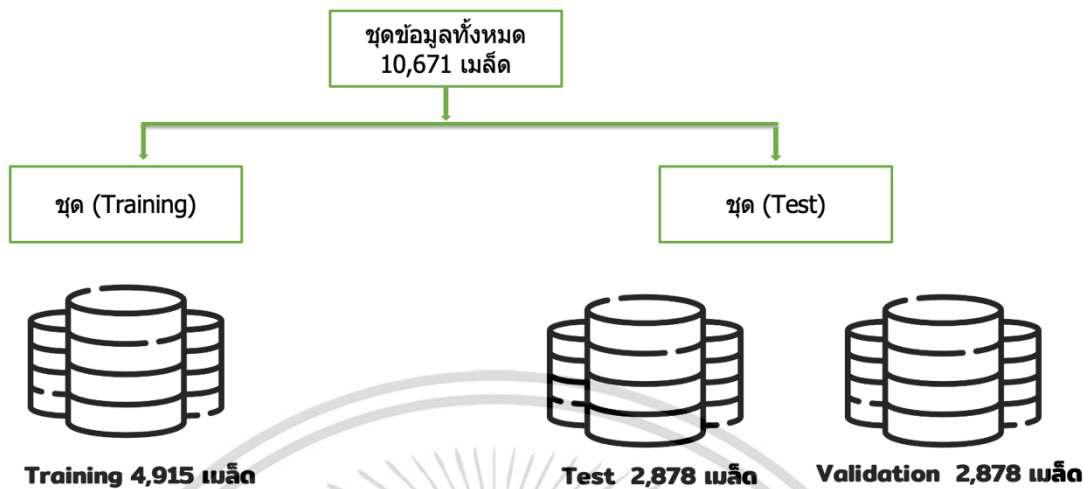
ในบทนี้จะกล่าวถึงการทดลองซึ่งประกอบไปด้วยกระบวนการทดลองเพื่อให้ได้โมเดลที่สามารถจำแนกข้อบกพร่องข้าวคือ ข้าวท้องไขข้าวสีต่ำกว่ามาตรฐานข้าวเมล็ดแดงและข้าวขาวให้มีประสิทธิภาพโดยการพิจารณาจาก (Accuracy) ดังสมการที่ 3.1 ในการเปรียบเทียบประสิทธิภาพของโมเดลที่ใช้ โดยที่ขั้นตอนกระบวนการทดลองจะมีขั้นตอนดังรูปที่ 3.1 ซึ่งจะเริ่มต้นที่ ทำการแบ่งข้อมูลออกเป็นสองชุดคือ ชุด (Training) และชุด (Test) โดยที่ ชุด (Training) จำนวน 4,915 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 1,438 เมล็ดและเมล็ดสีขาวจำนวน 1,438 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 719 เมล็ดและข้าวท้องไข 1,320 เมล็ด) และข้อมูลชุด (Test) จะมีชุดข้อมูลที่ถูกแบ่งออกเป็นสองชุดคือชุด (Validation) จำนวน 2,878 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 719 เมล็ดและเมล็ดสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข 720 เมล็ด) และชุด (Test) จำนวน 2,878 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 719 เมล็ดและเมล็ดสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข 720 เมล็ด) ดังรูปที่ 3.2

จากนั้นใช้กระบวนการประมวลผลทางภาพในการกำจัด (Noise) และหาพื้นที่ของเมล็ดข้าวแล้วทำการแบ่งแยกพื้นที่เมล็ดข้าวออกมาเป็นรายเมล็ด แล้วใช้โมเดล (Linear Support Vector Machine) และ (Radius Basis Function Support Vector Machine) เพื่อใช้ในการดูการกระจายของข้อมูลว่าเป็นแบบเชิงเส้นหรือไม่ ซึ่งหากเป็นเชิงเส้นจะใช้โมเดลในลักษณะเชิงเส้นเพื่อทำการเพิ่มประสิทธิภาพ (Accuracy) แต่ในงานวิจัยนี้ผลปรากฏว่าค่า (Accuracy) ที่ได้จาก (Radius Basis Function Support Vector Machine) ให้ค่า (Accuracy) ที่มากกว่าดังนั้นผู้วิจัยจะใช้โมเดลที่ไม่เป็นเชิงเส้น (Deep Learning Neural Network Efficientnet B0) ในการที่จะเพิ่มประสิทธิภาพและค่า (Accuracy) ของการจำแนกข้อบกพร่องข้าว เพราะเนื่องจากโมเดล (Deep Learning Neural Network Efficientnet B0) มีจำนวนชั้นของ (Neural Network) 127 ชั้นเพียงพอที่จะทำให้ไม่เกิด (Overfitting) และ (Local Minimum) [14] และสามารถปรับค่า (Hyperparameters) ได้เช่น (Learning Rate) และ (Batch Size) รวมถึงการทำ (Image Flipped Augmentation) และ (Unfreezing Layers) ซึ่งจะถูกล่ามถึงในบทที่ 4 โดยการปรับค่า (Hyperparameters) และการทำ (Image Flipped Augmentation) และ (Unfreezing Layers) จะทำให้ผลลัพธ์ค่า (Accuracy) มีค่า (Accuracy) เพิ่มขึ้นและสามารถใช้งานได้จริงในอุตสาหกรรมดังจุดประสงค์ของงานวิจัยนี้



รูปที่ 3.1 Flow การทำงานของกระบวนการทดลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.2 ลักษณะการแบ่งชุดข้อมูลในงานวิจัย

$$Accuracy = \frac{TP}{FP + TP}$$


(3.1)

โดยที่ TP คือค่าที่ทายถูก
 FP คือค่าที่ทายผิด

3.2 การเตรียมอุปกรณ์และการเตรียมเก็บข้อมูลสำหรับสร้างชุดข้อมูล

3.2.1 ขั้นตอนการเตรียมอุปกรณ์

ในขั้นตอนแรกการมองเห็นของเครื่องจักร (Machine Vision) ควรได้รับข้อมูลรูปภาพที่แน่นอนเพื่อให้ได้มาซึ่งผลลัพธ์ที่ถูกต้องและแม่นยำ ดังนั้นแล้วจำเป็นต้องใช้เครื่องสแกนแบบ Flatbed โดยภายในวิทยานิพนธ์ฉบับนี้ได้ใช้เครื่องสแกน Canon LIDE 120 Flatbed ที่ความละเอียด 600 dpi ดังรูปที่ 3.3 เครื่องสแกนเป็นอิสระต่อแสงจากภายนอกและให้ภาพที่มีคุณภาพดีที่สุด ซึ่งเหมาะสมกับงานด้านการจำแนกประเภท โดยพื้นหลังของเครื่องเป็นสีดำ เมล็ดข้าวจะกระจายบนกระจกของเครื่องสแกนแบบส้อม และเนื่องด้วยเหตุนี้จึงจำเป็นต้องตรวจสอบให้แน่ใจว่าเมล็ดข้าวไม่มีการทับซ้อนกัน หลังจากนั้นรูปภาพจะถูกถ่ายและจัดเก็บในรูปแบบ JPEG โดยอัตโนมัติ




รูปที่ 3.3 เครื่องสแกน Canon LIDE 120 Flatbed


3.2.2 การเตรียมเก็บข้อมูลสำหรับสร้างชุดข้อมูล

เนื่องจากทางผู้วิจัยมีความต้องการจะนำเอาผลการทดลองไปใช้จริงในอุตสาหกรรมข้าวไทยดังนั้นจึงขอความได้ร่วมมือจากหน่วยงานที่รับผิดชอบเรื่องการตรวจสอบคุณภาพข้าวของประเทศไทยคือ คณะกรรมการผู้ตรวจสอบข้าว สภาหอการค้าแห่งประเทศไทย ซึ่งได้ผู้เชี่ยวชาญที่มีประสบการณ์ตรวจสอบคุณภาพข้าวมากกว่า 26 ปีมาเป็นผู้คัดแยกตัวอย่างข้าวที่ถูกต้องในการสอนการเรียนรู้ของเครื่องจักรโดยได้ตัวอย่างข้าวที่ถูกต้องตามหัวข้อที่ 3.1


ซึ่งเมล็ดสีต่ำกว่ามาตรฐานหมายถึงข้าวเมล็ดขาวที่ผ่านการขัดสีต่ำกว่าระดับการขัดสีที่กำหนดไว้สำหรับข้าวแต่ละชนิดดังรูปที่ 3.4 และข้าวเมล็ดแดงหมายถึงข้าวที่มีรำสีแดงหุ้มทั้งเมล็ดหรือบางส่วนของเมล็ด [1] ดังรูปที่ 3.5 และข้าวท้องไขหมายถึงเมล็ดข้าวเจ้าที่เป็นสีขาวขุนคล้ายขอล็ก และมีเนื้อที่ ตั้งแต่ 50% ขึ้นไปของเนื้อที่เมล็ดข้าว ดังรูปที่ 3.6 และข้าวสารสีขาวในที่นี้คือข้าวที่เป็นสีขาวเป็นได้ทั้งข้าวพื้นและข้าวพื้นแข็ง ดังรูปที่ 3.7




รูปที่ 3.4 ข้าวเมล็ดขัดสีต่ำกว่ามาตรฐาน



รูปที่ 3.5 ข้าวเมล็ดแดง



รูปที่ 3.6 ข้าวท้องไข




รูปที่ 3.7 ข้าวขาว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3 การประมวลผลทางภาพ

ในกระบวนการนี้จะเป็นการประยุกต์ใช้การประมวลผลทางภาพเพื่อทำการกำจัดสิ่งปลอมปนและทำการเลือกคุณสมบัติที่ใช้ในการสอนการเรียนรู้ของเครื่องจักร (Feature Engineering) ซึ่งจะใช้ภาพที่มีความละเอียด 600 DPI มาเพื่อประมวลผล

3.3.1 เริ่มต้นจากภาพสีในโดเมนสีแดงสีเขียวสีฟ้า (RGB Image) ตามรูปที่ 3.6



รูปที่ 3.6 ตัวอย่างภาพสีในโดเมนสีแดงสีเขียวสีฟ้า (RGB Image)


3.3.2 ทำการแปลงภาพจะภาพสีในโดเมนสีแดงสีเขียวสีฟ้าเป็นภาพสีเทา (Gray Scale Image)



รูปที่ 3.7 ภาพสีเทา (Gray Scale Image)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.3 หลังจากนั้นก็จึงถูกแปลงเป็นภาพขาวดำด้วยวิธีการของ Otus [11]



รูปที่ 3.8 ภาพขาวดำ

3.3.4 ต่อมาใช้วิธี (Morphological Opening)

เพื่อกำจัดจุดรบกวนที่ไม่จำเป็นออกจากภาพดังแสดงภาพที่ 12 และใช้วิธีการ Morphological Labeling[10] ดังสมการที่ 3.1 ซึ่งจะเป็นการกำจัด (Noise) ที่อยู่ในภาพ



รูปที่ 3.9 ภาพที่ถูกกำจัดสิ่งปลอมปนออก

$$A \circ B = (A \ominus B) \oplus B$$

(3.1)

โดยที่

\ominus คือ การกร่อนขนาด (Erosion)

\oplus คือ การขยายภาพ (Dilation)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

A คือ ภาพ Binary

B คือ เมทริกซ์ ขนาด 8×8 ที่ทุกค่าเท่ากับ 1

3.3.5 การใช้ (Morphological Connected Component)

การใช้ในการแบ่งแยกภาพขาวออกมาเป็นรายเมล็ดเพื่อใช้ในการประมวลผลต่อ ซึ่งจะใช้หลักการของ (Morphological Connected Component) ดังสมการที่ 3.2 เพื่อให้ได้ตำแหน่งของเมล็ดขาวในภาพแล้วทำการแบ่งแยกเฉพาะพื้นเมล็ดในภาพ (RGB) ซึ่งจะได้ผลดังรูปที่ 3.10

$$X_k = (X_{k-1} \oplus B) \cap A$$

(3.2)

โดยที่

\oplus คือ การขยายภาพ (Dilation)

A คือ ภาพ Binary

B คือ เมทริกซ์ ขนาด 8×8 ที่ทุกค่าเท่ากับ 1

X_k คือ พื้นที่ติดกัน



รูปที่ 3.10 การแบ่งแยกภาพขาวออกเป็นรายเมล็ด


3.4 การสกัดคุณลักษณะ

การสกัดคุณลักษณะเพื่อเป็นคุณสมบัติที่จำเป็นในการสอนโมเดลการเรียนรู้ของเครื่องจักรซึ่งในที่นี้ได้รับข้อมูลมาจากผู้เชี่ยวชาญจากทาง คณะกรรมการผู้ตรวจสอบข้าวสากหอการค้าแห่งประเทศไทยว่าในการจำแนกข้าวสีต่ำกว่ามาตรฐานและข้าวท้องไขจะการใช้การแยกจากลักษณะทางกายภาพทางสี ดังนั้นทางผู้วิจัยจึงได้ทำการคัดเลือกคุณสมบัติทางสีมาใช้ในกระบวนการสีโมเดลการเรียนรู้ของเครื่องจักรซอฟต์แวร์เวกเตอร์มะชินในการคัดแยก ซึ่งมีขั้นตอนดังต่อไปนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.4.1 ทำการแปลงโดเมนสีจากค่าสี (RGB) เป็นโดเมนสี (HSV Hue: H, Saturation: S and Value: V)

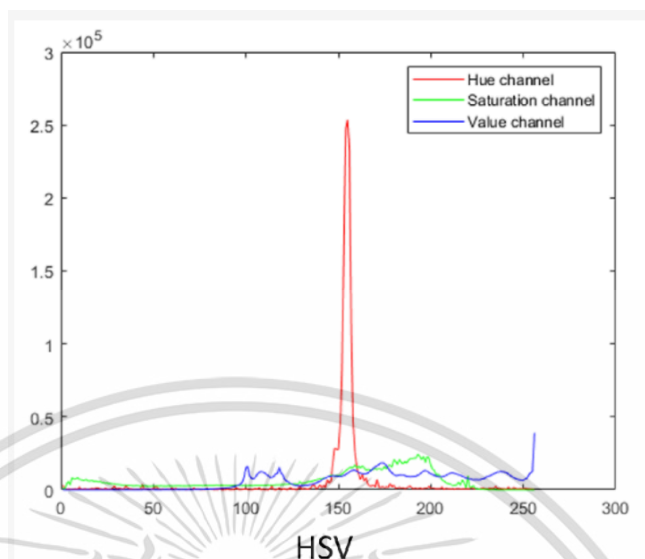
ซึ่ง Hue ให้ค่า สีของ แดง เขียวและน้ำเงิน ในทางปฏิบัติจะอยู่ระหว่าง 0 และ 255 ซึ่งถ้า Hue มีค่าเท่ากับ 0 จะแทนสีแดงและเมื่อ Hue มีค่าเพิ่มขึ้นเรื่อย ๆ สีก็จะเปลี่ยนแปลงไปตามสเปกตรัมของสีจนถึง 256 จึงจะกลับมาเป็นสีแดงอีกครั้ง ซึ่งสามารถแทนให้อยู่ในรูปขององศาได้ ดังนี้คือ สีแดง = 0 องศา สีเขียวเท่ากับ 120 องศา สีน้ำเงินเท่ากับ 240 องศา ดังรูปที่ 10 Saturation คือความบริสุทธิ์ของสีซึ่งถ้า Saturation มีค่าเท่ากับ 0 แล้วสีที่ได้จะไม่มี Hue ซึ่งจะเป็นสีขาวล้วนแต่ถ้า Saturation มีค่าเท่ากับ 255 แสดงว่าจะไม่มีแสงสีขาวผสมอยู่เลย Value คือความสว่างของสี



รูปที่ 3.11 แผนคุณสมบัติสีของโดเมนสี HSV

3.4.2 หลังจากการแปลงภาพจากโดเมนสี RGB เป็น HSV ทำการแปลงข้อมูลให้อยู่ในรูปแปด Histogram [10] ดังรูปที่ 3.12

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.12 Histogram ของ (HSV)

3.5 สร้างและทดสอบแบบจำลอง (Support Vector Machine) ด้วยชุดคุณลักษณะแต่ละแบบ

ในการทดสอบการเรียนรู้ของเครื่องจักร (Support Vector Machine) นั้นเป็นโมเดลที่ได้รับความนิยมในลักษณะของการจำแนก (Classification Model) ในกรณีที่มีข้อมูลในการสอน การเรียนรู้ของเครื่องจักรในกรณีที่มีข้อมูลจำนวนไม่มากซึ่งในการทดลองจะเริ่มต้นจากการเอาข้อมูลจากการสกัดข้อมูล (Feature Engineering) มากทำการสอนการเรียนรู้ของเครื่องจักร

3.5.1 คุณสมบัติการสกัดข้อมูล (Feature Engineering)

ทางผู้วิจัยได้ทำการเลือกคุณสมบัติจากฮิสโตแกรมทั้ง 3 ที่ความเข้มข้น 64 บิตรวมไปถึง (Hue: H, Saturation: S และ Value: V.) จากนั้นทำการทำให้เป็นมาตรฐาน (Normalization) โดยการแยกหารแต่ละบิตด้วยตัวค่าบิตรวมในแต่ละฮิสโตแกรม

3.5.2 รูปแบบของการกระจายของข้อมูล

ทางผู้วิจัยได้ทำการสร้างทดลองขึ้นขึ้นเพื่อเพิ่มความเข้าใจในรูปแบบการกระจายของข้อมูล โดยใช้วิธีการ (Linear Support Vector Machine) และ (Radius Basis Function Support Vector Machine) โดยผลลัพธ์ที่ถูกต้องจะบอกถึงรูปแบบของการกระจาย โดยหากการกระจายเป็นแบบเชิงเส้นวิธีการ (Linear Support Vector Machine) จะให้ผลลัพธ์ที่มีค่า (Accuracy) มากกว่าวิธีการ (Radius Basis Function Support Vector Machine) และในทางกลับกัน (Radius Basis Function Support Vector Machine) จะให้ผลลัพธ์ที่แม่นยำกว่าวิธีการ (Linear Support Vector Machine) หากการกระจายของข้อมูลที่ไม่เป็นแบบเชิงเส้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5.3 (Linear Support Vector Machine)


ตัวแปรซี (C parameter) หรือค่าแลกเปลี่ยนระหว่างความผิดพลาดในชุดข้อมูล สอนกับความเสียหายในชุดข้อมูล โดยการเปลี่ยนให้เป็นค่าที่อยู่ในรายการ (List) ซึ่ง ประกอบด้วย 1, 10, 100, 1000, 10000 และ 100000

3.5.4 (Radius Basis Function Support Vector Machine)

ค่าตัวแปรซีและตัวแปรจี (G parameter) เพื่อเพิ่มประสิทธิภาพแก่ผลลัพธ์ให้ ได้มากที่สุด โดยค่าซีได้ถูกเปลี่ยนเป็นค่าที่หลากหลายในเซต {1, 10, 100, 1000, 10000, 100000, 1000000} และค่าจีได้เปลี่ยนเป็นค่าในเซต {0.1, 0.01, 0.0001, 0.00001, 0.000001, 0.0000001}

3.5.5 การหาพารามิเตอร์ที่เหมาะสมที่สุดกับแบบจำลอง

ในการทดลองเพื่อให้ค่าที่ให้ (Accuracy) ที่สูงนั้นจะใช้หลักการของไฟว์โพลด์ ครอสวาไลเดชัน (5 Fold Cross Validation) กับข้อมูลในโดยที่ (5 Fold Cross Validation) จะเป็นการแบ่งข้อมูลออกเป็น 5 ส่วน โดยที่ 4 ส่วนจะเป็นส่วนที่ใช้ในการสอนและ 1 ส่วนจะใช้ในการทดสอบซึ่งจะสลับชุดข้อมูลไปตามรูปที่ 16 ซึ่ง (5 Fold Cross Validation) จะช่วยไม่ให้ข้อมูลเกิดการเลือกพารามิเตอร์ที่เหมาะสมกับข้อมูลเกินไป (Overfitting) จากนั้นนำค่า (Accuracy) เฉลี่ยที่ดีที่สุดจาก(5 Fold Cross Validation) มา เข้าโมเดลการเรียนรู้ของเครื่องจักร (Support Vector Machine) ทั้งแบบ (Linear Support Vector Machine) และ (Radius Basis Function Support Vector Machine)

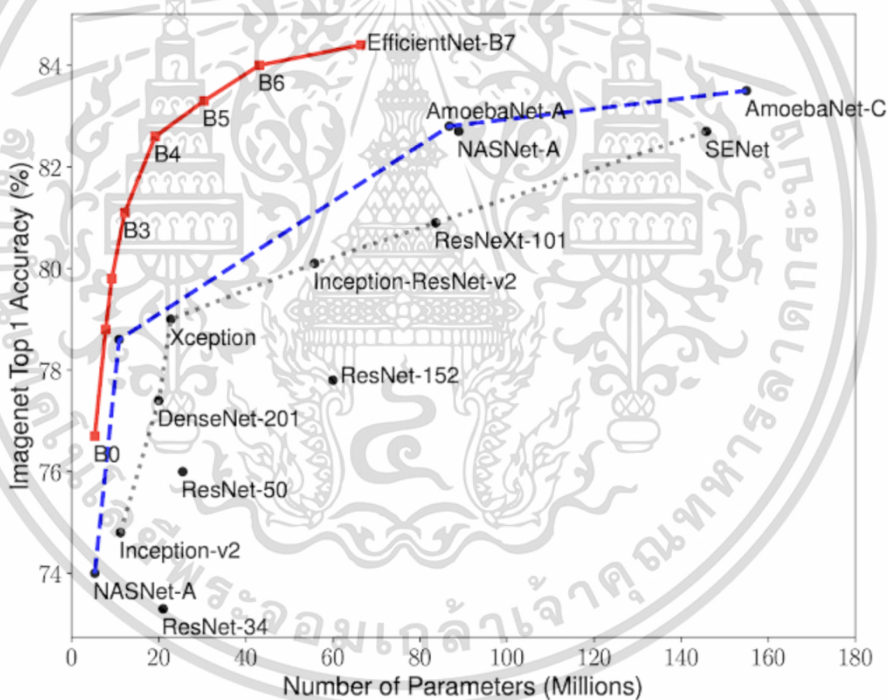


รูปที่ 3.11 ไฟว์โพลด์ครอสวาไลเดชัน (5 Fold Cross Validation)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.6 การเรียนรู้ด้วยเครื่องจักรขั้นสูง (Deep Learning Model EfficientnetB0)

โมเดล (EfficientNet) วิจัยและคิดค้นโดย M. Tan และ Q. Le [12] ในปี 2019 ซึ่งจะประกอบด้วยโมเดลหลายโมเดล (EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3, EfficientNetB4, EfficientNetB5, EfficientNetB6 และ EfficientNetB7) เรียงตามขนาดเล็กที่สุด ไปจนถึงใหญ่ที่สุดสำหรับโมเดลในตระกูล (EfficientNet) นี้ถูกออกแบบมาให้มีจำนวน พารามิเตอร์น้อย แต่กระนั้นยังสามารถให้ค่า (Accuracy) สูงสุด กับฐานข้อมูล (ImageNet) ที่สูงมาก สำหรับค่า (Accuracy) ของ (EfficientNetB0) ถึง (EfficientNetB7) ดังรูปที่ 3.12 ซึ่งอธิบายถึง (Accuracy) ของโมเดลในการทำนายผลซึ่ง (EfficientNetB0) มีพารามิเตอร์น้อยให้ (Accuracy) น้อยที่สุดและ (EfficientNetB7) มีพารามิเตอร์มากที่สุดและ (Accuracy) สูงสุดสำหรับการทดลองในงานวิจัยนี้จะเลือกใช้ (EfficientNetB0) เนื่องจากมีความต้องการมาใช้จริงในอุตสาหกรรมจึงต้องจำกัดการกราฟิกระมวลผลและขนาดของภาพ




รูปที่ 3.12 รูปการเปรียบเทียบพารามิเตอร์และ(Accuracy) ของ (Efficientnet) และโมเดลอื่น

3.6.1 หลักการพื้นฐานของ (EfficientNet)

(EfficientNet) ใช้วิธีการที่เรียกว่า (Compound Scaling) ที่แตกต่างจากโมเดลอื่น ๆ เช่น DenseNet [13] ที่สามารถที่จะขยายขนาดของสถาปัตยกรรมตั้งต้น ทั้งความลึก ความกว้าง และความละเอียด พร้อมกันทั้งสามค่าดังรูปที่ 18 ซึ่ง EfficientNet จะประกอบไปด้วยส่วนประกอบหลักคือ (Mobile Inverted Bottleneck MBConv Block)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

[14] และ (Squeeze and Excitation Optimization) [14] ร่วมด้วยทั้งนี้องค์ประกอบเหล่านี้ ถูกกำหนดไว้ตายตัวและใช้วิธีการ (Multi-Objective Neural Architecture Search) ในการโมเดลค้นหาที่ดีที่สุดทั้งในด้านความ (Accuracy) และจำนวน (FLOPS) เมื่อได้ค่าจะทำการขยายโมเดลโดยใช้เทคนิค(Compound Scaling) โดยมีลักษณะดังรูปที่ 3.13




รูปที่ 3.13 ลักษณะการขยายโมเดล (EfficientNet)

3.6.2 Transfer Learning

หลักการของ Transfer Learning [12] อยู่บนหลักการของโมเดลที่ได้จากการเรียนรู้ข้อมูลชุดหนึ่ง ที่สามารถนำไปเป็นโมเดลตั้งต้นในการเรียนรู้ข้อมูลอีกชุดหนึ่งได้ บนสมมติฐานที่ว่าข้อมูลชุดใหม่ เป็นข้อมูลที่มีรูปแบบพื้นฐานเหมือนกัน ซึ่งในกรณีของโมเดลที่ได้เรียนรู้จากฐานข้อมูล (ImageNet) แล้ว แม้ว่า รูปใน (ImageNet) จะแตกต่างจากรูปที่ผู้วิจัยได้รับจากผู้เชี่ยวชาญของคณะกรรมการผู้ตรวจสอบข่าวแต่ (ImageNet) ก็สามารถนำมาประยุกต์ใช้กับข่าวไทยได้ ซึ่ง (ImageNet) คือโมเดลที่ถูกเทรนกับชุดข้อมูลตั้งต้น (Pre-trained Model) ซึ่งในตัว (ImageNet) จะประกอบไปด้วยการเทรนข้อมูลมากกว่า 14 ล้านภาพและถ่ายต่อการนำมาใช้งานต่อ โดยงานวิจัยนี้จะประยุกต์ใช้ (ImageNet) เพื่อประหยัดเวลาและทรัพยากรในการวิจัยเพราะเนื่องจากการทำงานจริงต้องวิเคราะห์ถึงต้นทุนและเวลาเป็นสิ่งสำคัญ

ในส่วนของการวิจัยจะใช้โมเดล (EfficientNetB0) โดยจะมีการปรับดัดแปลงส่วนท้ายของโมเดลให้มีความเหมาะสมกับงานของผู้วิจัยดังรูปที่ 3.14



รูปที่ 3.14 ลักษณะการขยายโมเดล (EfficientNet)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

อธิปราชผลการทดลองและแนวทางการพัฒนา

จากหัวข้อที่ผ่านมาได้นำเสนอวิธีการทดสอบและขั้นตอนการทดลองการใช้การเรียนรู้ของเครื่องจักรทั้ง (Support Vector Machine) และการเรียนรู้ของเครื่องจักรขั้นสูงโมเดล (Deep Learning Model EfficientnetB0) โดยในบทนี้จะกล่าวถึงผลลัพธ์ที่ได้จากการทดลองซึ่งมีผลลัพธ์ดังนี้

4.1 ผลการทดลอง (Support Vector Machine)

4.1.1 ชุดข้อมูลที่ใช้ในการทดลอง

ในขั้นตอนแรก ทางผู้วิจัยได้ทำการแบ่งข้อมูลเมล็ดข้าวเป็น 3 ชุด ประกอบด้วยชุดการฝึกข้อมูล (Training) จำนวน 4,915 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 1,438 เมล็ดและเมล็ดสีขาวจำนวน 1,438 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 719 เมล็ดและข้าวท้องไข 1,320 เมล็ด) ชุดการประเมินผล (Validation) จำนวน 2,878 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 719 เมล็ดและเมล็ดสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข 720 เมล็ด) และชุดการทดสอบ (Test) จำนวน 2,878 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 719 เมล็ดและเมล็ดสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข 720 เมล็ด) โดยข้อมูลข้าวผู้วิจัยได้มาจากคณะกรรมการผู้ตรวจสอบข้าว สภาหอการค้าแห่งประเทศไทย

4.1.2 การปรับพารามิเตอร์และผลการทดลอง

หลังได้ชุดข้อมูลเป็นที่เรียบร้อยแล้ว จากนั้นทางผู้วิจัยได้ใช้ (Linear Support Vector Machine) เพื่อทำการฝึกการจำแนกประเภทของเมล็ดสีแดงตลอดชุดการฝึกต่อมาทางผู้วิจัยได้ปรับแต่งค่าของตัวแปรซี (C parameter) โดยการเปลี่ยนให้เป็นค่าที่อยู่ในรายการ (List) ซึ่งประกอบด้วย 1, 10, 100, 1000, 10000 และ 100000 เพื่อให้ได้ผลลัพธ์ที่มีค่า (Accuracy) ที่สูง โดยสำหรับกระบวนการปรับแต่งค่าแสดงให้เห็นว่าค่าซีที่เหมาะสมกับงานอยู่ที่ 1000 ด้วยเหตุนี้เองผลการทำงานของชุดทดสอบจึงให้ค่าความค่า (Accuracy) อยู่ที่ 92.48 ในขั้นตอนถัดมาผู้วิจัยได้นำชุดการฝึกมาใช้เพื่อฝึก (Radial Basis Function Support Vector Machine) ผู้วิจัยได้ปรับแต่งค่าตัวแปรซีและตัวแปรจี (G parameter) เพื่อเพิ่มประสิทธิภาพแก่ผลลัพธ์ให้ได้มากที่สุด โดยค่าซีได้ถูกเปลี่ยนเป็นค่าที่หลากหลายในเซต {1, 10, 100, 1000, 10000, 100000, 1000000} และค่าจีได้เปลี่ยนเป็นค่าในเซต {0.1, 0.01, 0.0001, 0.00001, 0.000001, 0.0000001} สืบเนื่องจากผลการทดลองผู้วิจัยได้ค้นพบว่าค่าของซีและจีที่สอดคล้องและเหมาะสมกับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

งานการวิจัยอยู่ที่ 100000 และ 0.0001 ตามลำดับ จากค่าตัวแปรที่เหมาะสมเหล่านี้ ส่งผลให้แบบจำลองแสดงผลลัพธ์ที่ค่า (Accuracy) ถึง 93.6% เมื่อได้รับการประเมินค่า จากชุดการทดสอบ

จากนั้นผู้วิจัยได้ใช้ชุดการทดสอบเพื่อประเมินประสิทธิภาพของ แบบจำลองโดย (Linear Support Vector Machine) ให้ผลลัพธ์ที่มีค่า (Accuracy) เท่ากับ 85.79 % ซึ่งให้ค่า (Accuracy) น้อยกว่า (Radius Basis Function Support Vector Machine) ที่ให้ผลลัพธ์ค่า (Accuracy) เท่ากับ 88.74% ตามตารางที่ 4.1 และ 4.2 ตามลำดับ

ตารางที่ 4.1 การประเมินผลการทำนายแบบ (Linear Support Vector Machine) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไร่	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไร่	621	0	33	66
	ข้าวสีแดง	0	689	22	8
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	55	80	521	64
	ข้าวขาว	36	15	30	638

ตารางที่ 4.2 การประเมินผลการทำนายแบบ (Radius Basis Function Support Vector Machine) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไร่	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไร่	641	0	26	53
	ข้าวสีแดง	0	693	9	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	42	88	543	47
	ข้าวขาว	9	1	6	677

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2 ผลการทดลองของการเรียนรู้ของเครื่องจักรขั้นสูงโมเดล (Deep Learning Model Efficentnet B0)

4.2.1 ชุดข้อมูลที่ใช้ในการทดลอง

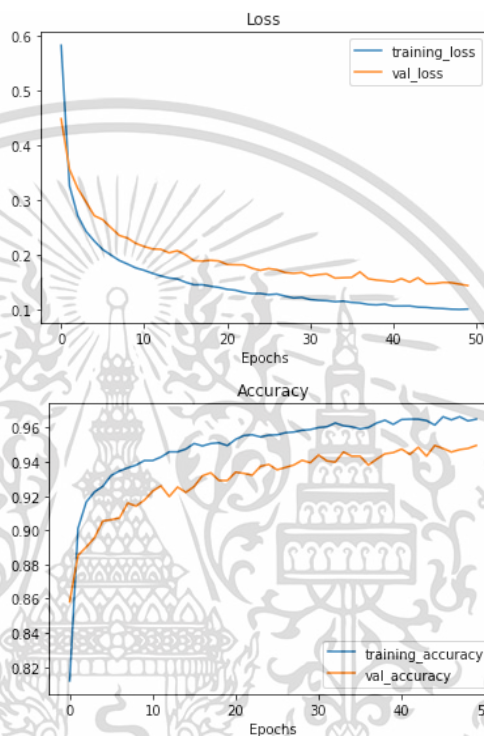
ในขั้นตอนแรก ทางผู้วิจัยได้ทำการแบ่งข้อมูลเมล็ดข้าวเป็น 3 ชุด ประกอบด้วย ชุดการฝึกข้อมูล (Training) จำนวน 4,915 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 1,438 เมล็ดและเมล็ดสีขาวจำนวน 1,438 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 719 เมล็ดและข้าวท้องไข่ 1,320 เมล็ด) ชุดการประเมินผล (Validation) จำนวน 2,878 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 719 เมล็ดและเมล็ดสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข่ 720 เมล็ด) และชุดการทดสอบ (Test) จำนวน 2,878 เมล็ด (ประกอบด้วยเมล็ดสีแดง จำนวน 719 เมล็ดและเมล็ดสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข่ 720 เมล็ด)

4.2.2 กระบวนการทดลองการเรียนรู้ของเครื่องจักรขั้นสูงโมเดล (Deep Learning Model EfficentnetB0)

ในกระบวนการทดสอบของการเรียนรู้ของเครื่องจักรขั้นสูงโมเดล (Deep Learning Model EfficentnetB0) จะเป็นออกเป็น 4 ขั้นตอนซึ่งจะเป็นการทดลองเทรน โมเดลและทำการปรับปรับไฮเปอร์พารามิเตอร์ (Hyperparameter) การทำ อิมมิจฟลิปพ้ออกเมนเทชัน (Image Flipped Augmentation) รวมถึงการปลดล็อก แช่แข็งโมเดล (Unfreezing Layers)

ในการทดลองขั้นตอนที่ 1 จะยังไม่การปรับไฮเปอร์พารามิเตอร์ (Hyperparameter) จะถูกกำหนดค่าเอาไว้ซึ่งประกอบด้วย Learning Rate = 0.0001 และ Batch Size = 32 และไม่มีการทำ (Image Flipped Augmentation) และรวมถึงแช่แข็งโมเดล (Freezing Layer) โดยไม่มีการ Update ค่า และทดลองเทรน 50 Epochs เพื่อให้ได้โมเดลพื้นฐาน (Base Line Model) ที่จะใช้เปรียบกับการปรับ (Hyperparameter) และการทำ (Image Flipped Augmentation) รวมถึงการ (Freezing Layer) ซึ่งได้ผลลัพธ์ดังต่อไปนี้ผลลัพธ์ที่ได้จากการทดลองนี้ให้ความสัมพันธ์ออกมาในขณะที่เทรนโมเดล 50 Epochs มีลักษณะความสัมพันธ์ ของค่าเทรนศูนย์เสีย (Training Loss) คือค่าศูนย์เสียที่เกิดจากเทรนโมเดลและค่าเสียจากข้อมูลทดสอบ (Validation Loss) คือค่าที่เกิดจากการคำนวณจากข้อมูลที่โมเดลไม่เคยเห็นมาก่อน ซึ่งมีความสัมพันธ์กันตามรูปกราฟด้านบน และค่าความแม่นยำจากการเทรน (Training Accuracy) คือความแม่นยำของโมเดลที่กำลังเทรน ค่าความแม่นยำชุดทดสอบ

(Validation Accuracy) คือความแม่นยำจากการใช้โมเดลทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่งความสัมพันธ์ระหว่าง ค่าความแม่นยำจากการเทรน (Training Accuracy) และ ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) มีลักษณะความสัมพันธ์ตามรูปกราฟด้านล่าง ตามรูปกราฟที่ 4.1 ซึ่งผลสุดท้ายให้ค่าความแม่นยำในการทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อน Validation ให้ค่า (Accuracy) อยู่ที่ 94.96%



รูปที่ 4.1 ลักษณะความสัมพันธ์ค่าความแม่นยำและค่า Training loss

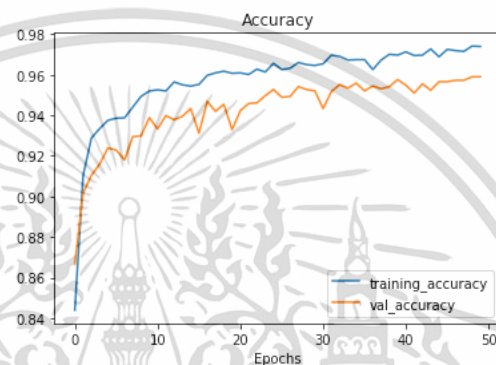

จากนั้นนำเอาโมเดลมาทำนายชุดข้อมูล (Test) ซึ่งเป็นข้อมูลที่เก็บไว้เป็นตัวอย่างทดสอบอีกชุดข้อมูลซึ่งผลลัพธ์ที่ได้นั้นได้ค่า (Accuracy) จากการทำนายอยู่ที่ 96.14% และลักษณะ (Confusion Metric) ตามตารางข้อมูลที่ 4.3

ตารางที่ 4.3 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficientNetB0) ในชุดข้อมูล (Test)

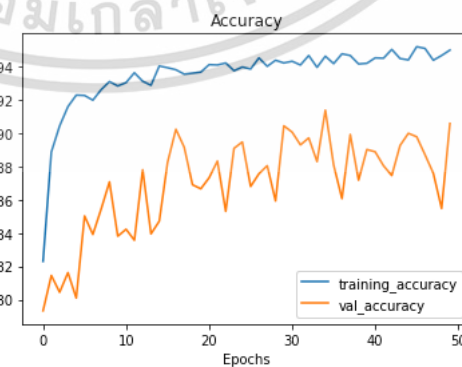
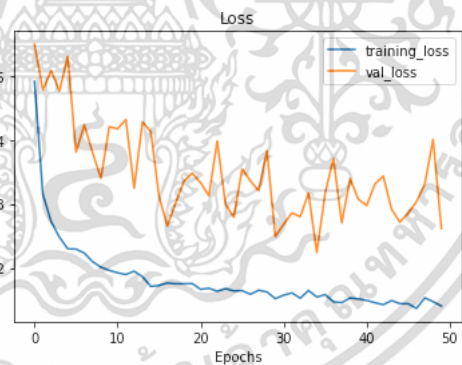
การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไร่	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไร่	680	0	7	33
	ข้าวสีแดง	0	715	3	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	15	1	660	44
	ข้าวขาว	3	3	1	712

ในการทดลองขั้นตอนที่ 2 จะมีการปรับไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งประกอบด้วย Learning Rate ที่ค่า 0.0025 และ Batch Size ที่ค่า 32 64 และไม่มีการทำ (Image Flipped Augmentation) และรวมถึงการ แช่แข็งโมเดล (Freezing Layer) โดยไม่มีการ Update ค่า โดยทดลองเทรนชุดละ 50 Epochs

ผลลัพธ์ที่ได้จากการทดลองนี้ให้ความสัมพันธ์ออกมาในขณะที่เทรนโมเดล 50 Epochs มีลักษณะความสัมพันธ์ ของค่าเทรนสูญเสีย (Training Loss) คือค่าสูญเสียที่เกิดจากเทรนโมเดลและค่าเสียจากข้อมูลทดสอบ (Validation Loss) คือค่าที่เกิดจากการคำนวณจากข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่งมีความสัมพันธ์กันตามรูปกราฟด้านบน และค่า (Accuracy) จากการเทรน (Training Accuracy) คือความแม่นยำของโมเดลที่กำลังเทรน ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) คือความแม่นยำจากการใช้โมเดลทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่งความสัมพันธ์ระหว่าง ค่าความแม่นยำจากการเทรน (Training Accuracy) และ ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) มีลักษณะความสัมพันธ์ตามรูปกราฟด้านล่าง ซึ่งผลสุดท้ายให้ค่าความแม่นยำในการทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อน (Validation) ให้ค่า (Accuracy) อยู่ที่ 95.90% ในกรณีที่กำหนดค่า (Batch Size) ที่ค่า 32 และให้ค่า (Accuracy) อยู่ที่ 90.65% กรณีที่กำหนดค่า (Batch Size) ที่ค่า 64 ตามรูปกราฟที่ 4.2 และ 4.3 ตามลำดับ



รูปที่ 4.2 ลักษณะความสัมพันธ์ค่าความแม่นยำและค่า Training loss



รูปที่ 4.3 ลักษณะความสัมพันธ์ค่าความแม่นยำและค่า Training loss

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากนั้นนำเอาโมเดลมาทำนายชุดข้อมูล Test ซึ่งเป็นข้อมูลที่เก็บไว้เป็นตัวอย่างทดสอบซึ่งผลลัพธ์ที่ได้นั้นได้ค่า (Accuracy) จากการทำนายอยู่ที่ 96.91% ในกรณีที่กำหนดค่า (Batch Size) ที่ค่า 32 โดยที่ลักษณะ (Confusion Metric) ตามตารางข้อมูลที่ 4.4 และได้ค่า (Accuracy) จากการทำนายอยู่ที่ 94.64% ในกรณีที่กำหนดค่า (Batch Size) ที่ค่า 64 ตามตารางข้อมูลที่ 4.5

ตารางที่ 4.4 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficentnetB0) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไข	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไข	681	0	7	32
	ข้าวสีแดง	0	716	2	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	9	0	678	33
	ข้าวขาว	1	4	0	714

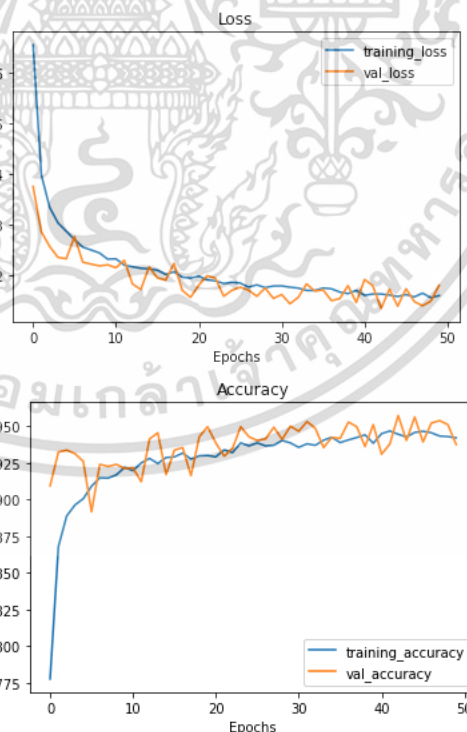
ตารางที่ 4.5 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficentnetB0) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไข	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไข	705	0	4	11
	ข้าวสีแดง	0	712	5	2
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	48	1	642	29
	ข้าวขาว	47	3	4	665

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการทดลองขั้นตอนที่ 3 จะมีการกำหนดค่าไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งประกอบด้วย (Learning Rate) ที่ค่า 0.0001 และ Batch Size ที่ค่า 32 และทำการทดสอบ (Image Flipped Augmentation) กำหนดค่า การหมุน 0.2 และการกลับด้านแนวนอน และรวมถึงการ แช่แข็งโมเดล (Freezing Layer) โดยไม่มีการ Update ค่า โดยทดลองเทรนชุดละ 50 Epochs

ผลลัพธ์ที่ได้จากการทดลองนี้ให้ความสัมพันธ์ออกมาในขณะที่เทรนโมเดล 50 Epochs มีลักษณะความสัมพันธ์ ของค่าเทรนสูญเสีย (Training Loss) คือค่าสูญเสียที่เกิดจากเทรนโมเดลและค่าเสียจากข้อมูลทดสอบ (Validation Loss) คือค่าที่เกิดจากการคำนวณจากข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่งมีความสัมพันธ์กันตามรูปกราฟด้านบน และค่าความแม่นยำจากการเทรน (Training Accuracy) คือความแม่นยำของโมเดลที่กำลังเทรน ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) คือความแม่นยำจากการใช้โมเดลทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่งความสัมพันธ์ระหว่าง ค่าความแม่นยำจากการเทรน (Training Accuracy) และ ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) มีลักษณะความสัมพันธ์ตามรูปกราฟด้านล่าง 4.4 ซึ่งผลสุดท้ายให้ค่าความแม่นยำในการทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อนในชุดข้อมูล (Validation) ซึ่งให้ค่า (Accuracy) อยู่ที่ 93.75%



รูปที่ 4.4 ลักษณะความสัมพันธ์ค่าความแม่นยำและค่า Training loss

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากนั้นนำเอาโมเดลมาทำนายชุดข้อมูล Test ซึ่งเป็นข้อมูลที่เก็บไว้เป็นตัวอย่าง ทดสอบซึ่งผลลัพธ์ที่ได้นั้นได้ค่า (Accuracy) อยู่ที่ 85.86% และลักษณะ (Confusion Metric) ตามตารางข้อมูลที่ 4.6

ตารางที่ 4.6 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficientnetB0) ในชุดข้อมูล (Test)

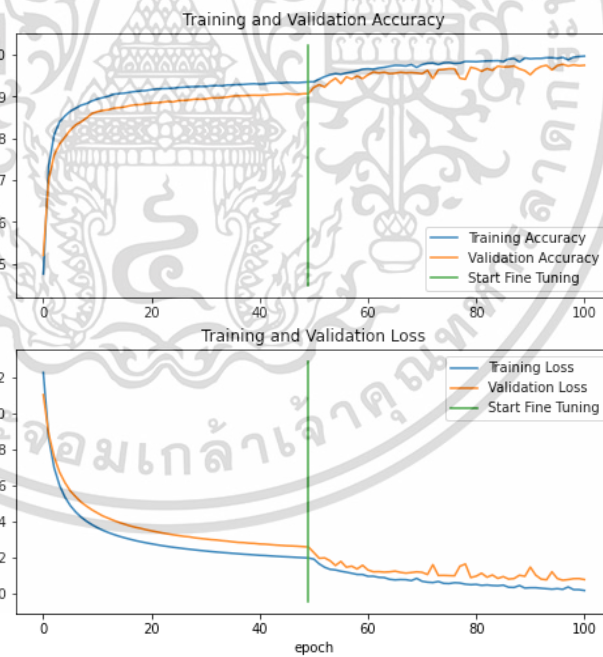
การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไข	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไข	715	0	5	38
	ข้าวสีแดง	0	702	13	2
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	40	3	666	11
	ข้าวขาว	129	0	202	388

ในการทดลองขั้นตอนที่ 4 จะมีการกำหนดค่าไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งประกอบด้วย (Learning Rate) ที่ค่า 0.0001 และ (Batch Size) ที่ค่า 32 และไม่มีการทำ (Image Flipped Augmentation) และทดลองปลดล็อกการแช่แข็งโมเดล (Unfreezing Layer) โดยให้มีการ Update ค่า โดยการปลดล็อกที่ 5 ชั้นสุดท้าย และ 10 ชั้นสุดท้าย โดยทดลองเทรนชุดละ 50 Epochs

ผลลัพธ์ที่ได้จากการทดลองนี้ให้ความสัมพันธ์ออกมาในขณะที่เทรนโมเดล 50 Epochs มีลักษณะความสัมพันธ์ ของค่าเทรนสูญเสีย (Training Loss) คือค่าศูนย์เสียที่เกิดจากเทรนโมเดลและค่าเสียจากข้อมูลทดสอบ (Validation Loss) คือค่าที่เกิดจากการคำนวณจากข้อมูลที่โมเดลไม่เคยเห็นมาก่อน ซึ่งมีความสัมพันธ์กันตามรูปกราฟด้านบน และค่าความแม่นยำจากการเทรน (Training Accuracy) คือความแม่นยำของโมเดลที่กำลังเทรน ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) คือความแม่นยำจากการใช้โมเดลทำนายชุดข้อมูลที่โมเดลไม่เคยเห็นมาก่อน ซึ่งความสัมพันธ์ระหว่าง ค่าความแม่นยำจากการเทรน (Training Accuracy) และ ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) มีลักษณะความสัมพันธ์ตามรูปกราฟด้านล่าง ซึ่งผลสุดท้ายให้ค่าความแม่นยำในการทำนายชุดข้อมูลที่โมเดลไม่เคยเห็นมาก่อน ในกรณีของปลดล็อกที่ 5 ชั้นบนสุด ให้ค่า (Accuracy) อยู่ที่ 96.28% และในกรณีของปลดล็อกที่ 10 ชั้นบนสุด ให้ค่า (Accuracy) อยู่ที่ 97.50% ตามรูปกราฟที่ 4.5 และ 4.6 ตามลำดับ



รูปที่ 4.5 ลักษณะความสัมพันธ์ค่าความแม่นยำและค่า Training loss



รูปที่ 4.6 ลักษณะความสัมพันธ์ค่าความแม่นยำและค่า Training loss

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากนั้นนำเอาโมเดลมาทำนายชุดข้อมูล Test ซึ่งเป็นข้อมูลที่เก็บไว้เป็นตัวอย่าง ทดสอบซึ่งผลลัพธ์ที่ได้นั้นได้ค่าแม่นยำจากการทำนายในกรณีของปลดล๊อค (Unfreezing Layers) ที่ 5 ชั้นสุดท้ายซึ่งได้ผลลัพธ์ค่า (Accuracy) อยู่ที่ 98.43% มีลักษณะ Confusion Metric ตามตารางข้อมูลที่ และในกรณีของปลดล๊อค (Unfreezing Layers) ที่ 10 ชั้นสุดท้าย ให้ค่า (Accuracy) อยู่ที่ 97.36% และลักษณะ (Confusion Metric) ตามตารางข้อมูลที่ 4.7 และ 4.8 ตามลำดับ

ตารางที่ 4.7 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficentnetB0) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไข	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไข	690	0	10	20
	ข้าวสีแดง	0	717	1	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	1	0	715	4
	ข้าวขาว	1	4	3	711

ตารางที่ 4.8 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficentnetB0) ในชุดข้อมูล (Test)

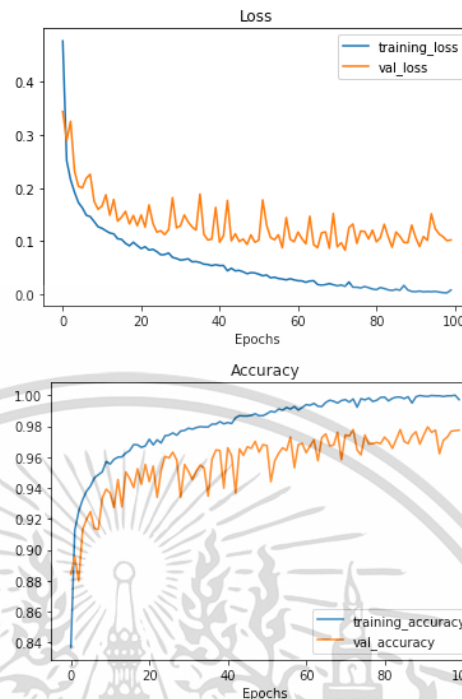
การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไข	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไข	684	0	6	30
	ข้าวสีแดง	0	718	0	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	4	0	685	31
	ข้าวขาว	0	4	0	715

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.3 นำผลลัพธ์จากข้อที่ 4.2.2 มาหาโมเดลที่ให้ค่าความแม่นยำสูงสุด

เมื่อได้ผลลัพธ์จากข้อที่ 4.2.2 ทำทราบว่าควรจะมีการกำหนดค่าไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งประกอบด้วย (Learning Rate) ที่ค่า 0.0001 และ (Batch Size) ที่ค่า 32 และไม่มีการทำ (Image Flipped Augmentation) และปลดล็อกการแช่แข็งโมเดล (Unfreezing Layer) โดยให้มีการ Update ค่า โดยการปลดล็อกที่ 10 ชั้นบนสุด โดยทดลองเทรนทั้งหมด 100 Epochs

ผลลัพธ์ที่ได้จากการทดลองนี้ให้ความสัมพันธ์ออกมาในขณะที่เทรนโมเดล 100 Epochs มีลักษณะความสัมพันธ์ ของค่าเทรนสูญเสีย (Training Loss) คือค่าสูญเสียที่เกิดจากเทรนโมเดลและค่าเสียจากข้อมูลทดสอบ (Validation Loss) คือค่าที่เกิดจากการคำนวณจากข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่งมีความสัมพันธ์กันตามกราฟด้านบน และค่าความแม่นยำจากการเทรน (Training Accuracy) คือความแม่นยำของโมเดลที่กำลังเทรน ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) คือความแม่นยำจากการใช้โมเดลทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อน ซึ่งความสัมพันธ์ระหว่าง ค่าความแม่นยำจากการเทรน (Training Accuracy) และ ค่าความแม่นยำชุดทดสอบ (Validation Accuracy) มีลักษณะความสัมพันธ์ตามกราฟด้านล่าง ซึ่งผลสุดท้ายให้ค่า (Accuracy) ในการทำนายชุดข้อมูลที่ไม่เคยเห็นมาก่อนในชุดข้อมูล (Validation) ในกรณีของ (Unfreezing Layer) ที่ 5 ชั้นสุดท้าย ให้ค่า (Accuracy) อยู่ที่ 97.74% ตามกราฟที่ 4.7



รูปที่ 4.7 ลักษณะความสัมพันธ์ค่าความแม่นยำและค่า Training loss

จากนั้นนำเอาโมเดลมาทำนายชุดข้อมูล (Test) ซึ่งเป็นข้อมูลที่เก็บไว้เป็นตัวทดสอบซึ่งผลลัพธ์ที่ได้นั้นได้ค่า (Accuracy) จากการทำนายกรณีของการทำ (Unfreezing Layer) ที่ 5 ชั้นบนสุด ให้ (Accuracy) อยู่ที่ 98.82% มีลักษณะ (Confusion Metric) ตามตารางข้อมูลที่

ตารางที่ 4.9 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficientnetB0) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไข	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไข	698	0	5	17
	ข้าวสีแดง	0	717	1	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	4	0	716	0
	ข้าวขาว	0	4	2	713

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3 การปรับปรุงประสิทธิภาพจากการวิเคราะห์ความผิดพลาด

จากการทดลองในข้อที่ 4.2 ทั้งการใช้ (Support Vector Machine) และการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficientnetB0) ในการทำนายของบัพกรณ์ของข้าวซึ่งประกอบด้วย เมล็ดสีแดง เมล็ดสีขาว ข้าวขัดสีต่ำกว่ามาตรฐาน และข้าวท้องไข ทำให้ทราบว่าการใช้ (Support Vector Machine Radius Basis Function) ซึ่งค่าพารามิเตอร์ $C = 100000$ และ $G = 0.0001$ ที่ให้ผลลัพธ์ที่มีค่า (Accuracy) อยู่ที่ 88.74% ซึ่งมีลักษณะของ (Confusion Metric) ตามตารางที่ และการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model Efficientnet B0) กำหนดค่าไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งประกอบด้วย (Learning Rate) ที่ค่า 0.0001 และ (Batch Size) ที่ค่า 32 และไม่มีการทำ (Image Flipped Augmentation) และปลดล๊อคการแช่แข็งโมเดล (Unfreezing Layer) โดยให้มีการ Update ค่า โดยการปลดล๊อคที่ 10 ชั้นบนสุด ให้ค่า (Accuracy) อยู่ที่ 98.82% มีลักษณะ (Confusion Metric) ตามตารางข้อมูลที่ เมื่อเปรียบเทียบระหว่าง (Support Vector Machine) และการเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficientnetB0) การใช้การเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficientnetB0) จะให้ (Accuracy) มากกว่ามาก แต่ก็ยังมีค่าความผิดพลาดเกิดขึ้นโดยเฉพาะข้าวท้องไขกับข้าวขาวแตเมื่อนำรูปที่วิเคราะห์ผิดพลาดมาสังเกตดูก็จะทราบว่ามีความใกล้เคียงกันจริง แต่เมื่อนำภาพมาขยายให้ใหญ่ขึ้นก็จะเห็นความแตกต่างได้ชัดเจนยิ่งขึ้นจึงนำมาสู่กระบวนการปรับปรุง (Accuracy) ของโมเดลโดยควรใช้ขนาดภาพที่ใหญ่ขึ้นและความถี่การเรียนรู้ของเครื่องจักรชั้นสูงโมเดล (Deep Learning Model EfficientnetB1-B7) เพราะว่าโมเดล (Deep Learning Model EfficientnetB1-B7) จะเหมาะสมกับขนาดของภาพที่ขยายใหญ่ขึ้น และควรจะมีการเพิ่มจำนวนของที่ใช้ในการสอนการเรียนรู้ของเครื่องจักรชั้นสูงโมเดลในจำนวนที่มากขึ้นก็จะช่วยให้โมเดลมี (Accuracy) มากยิ่งขึ้น

ตารางที่ 4.10 การประเมินผลการทำนายแบบ (Linear Support Vector Machine) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไข	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไข	641	0	26	53
	ข้าวสีแดง	0	693	9	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	42	88	543	47
	ข้าวขาว	9	1	6	677

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.11 การประเมินผลการทำนายแบบการเรียนรู้ของเครื่องจักรขั้นสูงโมเดล (Deep Learning Model EfficentnetB0) ในชุดข้อมูล (Test)

การจำแนกข้อบกพร่องข้าว		ความเป็นจริง			
		ข้าวท้องไร่	ข้าวสีแดง	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	ข้าวขาว
การทำนาย	ข้าวท้องไร่	698	0	5	17
	ข้าวสีแดง	0	717	1	1
	ข้าวเมล็ดสีต่ำกว่ามาตรฐาน	4	0	716	0
	ข้าวขาว	0	4	2	713

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5 บทสรุป

5.1 บทสรุปการทดลอง

วิทยานิพนธ์นี้ได้นำเสนอแนวทางการตรวจสอบคุณภาพข้าวโดยใช้การมองเห็นของเครื่องจักรโดยใช้วิธีการเรียนรู้ของเครื่องจักรทั้ง (Support Vector Machine) ในการดูการกระจายของข้อมูลที่ต้องการจำแนกว่าเป็นการกระจายแบบเชิงเส้นโดย (Linear Support Vector Machine) และ ดูการกระจายข้อมูลแบบไม่เป็นเชิงเส้นโดย (Radius Basin Function Support Vector Machine) ซึ่งผลลัพธ์ที่ได้คือค่า (Accuracy) ที่ได้จาก (Radius Basin Function Support Vector Machine) ให้ค่า (Accuracy) ที่มากกว่าทำให้สามารถสรุปได้เบื้องต้นว่าข้อมูลกระจายในแบบไม่เป็นเชิงเส้น ดังนั้นผู้วิจัยจึงใช้โมเดลแบบไม่เป็นเชิงเส้น ซึ่งมีประสิทธิภาพสูงในปัจจุบันคือ (Deep Learning Model EfficentnetB0) โดยงานวิจัยนี้ได้รับข้อมูลข้าวจากทางผู้เชี่ยวชาญในการตรวจสอบคุณภาพข้าวคณะกรรมการผู้ตรวจสอบคุณภาพข้าว สภาหอการค้าแห่งประเทศไทย โดยได้รับตัวอย่างข้าวทั้งหมด 3 ชุด ประกอบด้วยชุดการฝึกข้อมูล (Training) จำนวน 4,915 เมล็ด (ประกอบด้วยข้าวเมล็ดสีแดง จำนวน 1,438 เมล็ดและข้าวสีขาวจำนวน 1,438 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 719 เมล็ดและข้าวท้องไข 1,320 เมล็ด) ชุดการประเมินผล (Validation) จำนวน 2,878 เมล็ด (ประกอบด้วยข้าวเมล็ดสีแดง จำนวน 719 เมล็ดและข้าวสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข 720 เมล็ด) และชุดการทดสอบ (Test) จำนวน 2,878 เมล็ด (ประกอบด้วยข้าวเมล็ดสีแดง จำนวน 719 เมล็ดและข้าวเมล็ดสีขาวจำนวน 719 เมล็ด และข้าวขัดสีต่ำกว่ามาตรฐานจำนวน 720 เมล็ดและข้าวท้องไข 720 เมล็ด) โดยรวมทั้งหมด 10,671 เมล็ด

จากนั้นผู้วิจัยได้ทำการสอบถามจากผู้เชี่ยวชาญของคณะกรรมการผู้ตรวจสอบคุณภาพข้าว สภาหอการค้าแห่งประเทศไทย ว่าใช้หลักเกณฑ์ในการจำแนกข้อบกพร่องข้าวโดยการใช้ลักษณะสีในการจำแนก ซึ่งผู้วิจัยได้ตั้งสมมุติฐานในการจำแนกข้อบกพร่องข้าวด้วยข้อมูลสี จึงทำให้ผู้วิจัยได้ทำการเลือกชุดข้อมูลสีโดยเลือกชุดข้อมูล (Histogram) ของโดเมนสี (HSV) มาเป็นชุดข้อมูลในการเทรนโมเดล (Linear Support Vector Machine) และ (Radius Basin Function Support Vector Machine) เพื่อใช้ในการจำแนกข้อบกพร่องสีของข้าว โดยผลลัพธ์ที่ได้โมเดล (Linear Support Vector Machine) ให้ผลลัพธ์ที่มีค่า (Accuracy) เท่ากับ 85.79 % ซึ่ง (Accuracy) น้อยกว่า (Radius Basis Function Support Vector Machine) ที่ให้ผลลัพธ์ค่า (Accuracy) เท่ากับ 88.74% จึงสามารถสรุปได้เบื้องต้นว่าข้อมูลในการจำแนกข้อบกพร่องข้าวอยู่ในรูปแบบไม่เป็นเชิงเส้น

จากนั้นผู้วิจัยจะได้เลือกโมเดลที่ไม่เป็นเชิงเส้นที่มีประสิทธิภาพสูงในปัจจุบันคือโมเดล (Deep Learning Model EfficentnetB0) ในการจำแนกข้อบกพร่องข้าวโดยมีการทดลองในการ

ปรับ ไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งประกอบด้วย (Learning Rate) และ (Batch Size) และการทำ (Image Flipped Augmentation) และปลดล็อกการแช่แข็งโมเดล (Unfreezing Layer) โดยให้มีการ Update ค่า ซึ่งได้ผลลัพธ์คือการปรับ ไฮเปอร์พารามิเตอร์ (Hyperparameter) ซึ่งประกอบด้วย (Learning Rate) ที่ค่า 0.0001 และ (Batch Size) ที่ค่า 32 และไม่มีการทำ (Image Flipped Augmentation) และปลดล็อกการแช่แข็งโมเดล (Unfreezing Layer) โดยให้มีการ Update ค่า โดยการปลดล็อกที่ 10 ชั้นบนสุด ให้ค่า (Accuracy) อยู่ที่ 98.82% ซึ่งเพียงพอต่อการนำมาใช้งานจริงในอุตสาหกรรมได้

5.2 การวิเคราะห์เพื่อปรับปรุงผลและการนำมาใช้จริงในอุตสาหกรรม

การที่จะเพิ่มประสิทธิภาพโมเดลในอนาคตและลดค่าต้นทุนในการประมวลผลเป็นเรื่องที่สำคัญ ซึ่งในงานวิจัยก็สามารถบ่งชี้ได้ว่าหากต้องการ (Accuracy) ที่มากขึ้นก็สามารถเพิ่มขนาดของภาพ Input และเพิ่มขนาดของโมเดลโดยใช้ (Deep Learning Model EfficientnetB1-B7) ดังรูปที่ 5.1 ซึ่งจะเป็นการเพิ่มรายละเอียดภาพ (Input) และการเพิ่มจำนวนข้อมูลตัวอย่างซึ่งกระบวนการดังกล่าวจะช่วยเพิ่มประสิทธิภาพแต่ในขณะเดียวกันต้นทุนการประมวลผลก็เป็นเรื่องที่สำคัญในการทำ (Machine Learning Implementation) ซึ่งงานวิจัยก็สามารถบอกได้ว่าการใช้ภาพขนาดเล็กก็สามารถได้ค่า (Accuracy) เพียงพอที่จะใช้งานจริงในอุตสาหกรรมแต่ก็สามารถที่จะลดขนาดภาพลงเพื่อประหยัดต้นทุนในการประมวลผลและสามารถทดลองใช้ Tensorflow ในการที่จะ Optimization ทรัพยากรในการประมวลผลอย่าง CPU ในการแบ่ง Core ประมวลผล และ ทดลองในการเอาชั้น (Layer) บางชั้นออก ในสถาปัตยกรรมโมเดล Deep Learning Model EfficientnetB0 เพื่อให้ประหยัดต้นทุนการประมวลผลมากขึ้นแต่ต้องได้ค่า (Accuracy) ที่ทางอุตสาหกรรมยอมรับควบคู่กัน

Base model	resolution
EfficientNetB0	224
EfficientNetB1	240
EfficientNetB2	260
EfficientNetB3	300
EfficientNetB4	380
EfficientNetB5	456
EfficientNetB6	528
EfficientNetB7	600

รูปที่ 5.1 เพิ่มขนาดของภาพ Input ของโมเดล (Deep Learning Model EfficientnetB1-B7)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] Thai Standard of Rice , Ministry of Commerce Thailand, 2016.
- [2] V.S.Kolkure, B.N.Shaikh, “Identification And Quality Testing Of Rice Grains Using Image Processing and Neural network”, International Journal of Recent Trends in Engineering & Research (IJRTER), 2017.
- [3] Dollawat Ngampak and Punpiti Piamsa-nga, “Image Analysis of Broken Rice Grains of Khao Dawk Mali Rice”, Knowledge and Smart Technology (KST), 2015.
- [4] P. Kongsawat, S. Chivapreecha and T. Sato, “ Quality Assessment of Thai Rice Kernels Using Low Cost Digital Image Processing System”, International Workshop on Advanced Image Technology (IWAIT), 2018.
- [5] Bhupinder Verma, “Image Processing Techniques for Grading & Classification of Rice,” Computer and Communication Technology (ICCCT), 2010
- [6] Harpreet Kaur, Baljit Singh, “Classification and Grading Rice Using Multi-Class SVM”, International Journal of Scientific and Research Publications, Volume 3, Issue 4, April 2013.
- [7] H.K. Mebatsion, J. Paliwal, D.S. Jayas, “Automatic classification of non-touching cereal grains in digital images using limited morphological and color features” Elsevier ,Computers and Electronics in Agriculture 90,2013.
- [8] L.A.I.Pabamalie, H.L.Premaratne, “A Grain Quality Classification System”, Institute of Electrical and Electronics Engineers, 2010.
- [9] Vala, H.J., “ A review on Otsu image segmentation algorithm”, Int. J. Adv. Res. Comput. Eng. Technol. (IJARCET) 2(2), 387–389 , 2013.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [10] Gonzalez, Eddins and Wood, Digital Image Processing Using Matlab (2nd Edition), GATESMARK. 2009.
- [11] Jamileh Yousefi, “ Image Binarization using Otsu Thresholding Algorithm ”, April 2011
- [12] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” in Proceedings of the 36th International Conference on Machine Learning, PMLR, vol. 97, may 2019, pp. 6105–6114.
- [13] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” in 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), jul 2017, pp. 2261–2269.
- [14] EfficientNet: การคิดใหม่การปรับขนาดโมเดลสำหรับ Convolutional Neural Networks (การจำแนกภาพ), [Online] Available : <https://ichi.pro/th/efficientnet-kar-khid-him-kar-prab-khnad-model-sahrab-convolutional-neural-networks-kar-canaek-phaph-263228629273165>
- [15] J. Deng, W. Dong, R. Socher, L.-J. Li, Kai Li, and Li Fei-Fei, “ImageNet: A large-scale hierarchical image database,” in 2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), jun 2009, pp. 248–255.
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, dec 2018, pp. 4510–4520, Digital Image Processing Using Matlab (2nd Edition), GATESMARK. 2009.
- [17] Li F., Johnson J. and Yeung S. "Convolutional Neural Networks for Visual Recognition." [Online]. Available: <http://ip.cadence.com/uploads/901/cnn-wp-pdf>. 2015.
- [18] Young I. T., Gerbrands J. J. and Van Vliet L. J. Fundamentals of image processing. Delft University of Technology Delft. 1998.

ภาคผนวก ก

ข้อบกพร่องข้าวที่ส่งผลต่อราคาข้าว

ตามประกาศของสมาคมผู้ส่งออกข้าวไทยราคาข้าวที่ส่งออกจะขึ้นอยู่กับสามปัจจัยหลัก (เมล็ดข้าวแตกหัก, ขนาดของเมล็ดข้าว, ข้อบกพร่อง) โดยภายในวิทยานิพนธ์ฉบับนี้จะให้ความสนใจกับปัจจัยด้านข้อบกพร่องของเมล็ดข้าว เนื่องด้วยปัจจัยการขายที่สำคัญคือข้อบกพร่องสีแดง (Red Defect) ซึ่งปัจจัยนี้จะส่งผลให้ราคาขายลดลงถึง 6% ของราคาขาย ดังนั้นแล้วการเลือกที่จะให้ความสำคัญกับปัจจัยนี้จึงมีความสำคัญอย่างยิ่งต่อการพิจารณาเพื่อให้ได้มาซึ่งราคาส่งออกข้าวที่เหมาะสม

ตารางที่ 1 ราคาข้าวขาวส่งออก

	ราคาข้าวขาว		
	ชนิด	ร้อยละของการปนเปื้อน ขั้นต่ำ	ราคาในหน่วย USD
1	ข้าวขาว 100%	0.5	500
2	ข้าวขาว 25%	7	471

อ้างอิงจากเว็บไซต์ <http://www.thairiceexporters.or.th/price.htm> สืบค้น ณ วันที่ 15 มิถุนายน พ.ศ.2564

ภาคผนวก ข

เอกสารประกอบการดำเนินการสอบวิทยานิพนธ์

1. P. Kongsawat, A. Lasakull, B. Purahong, N. Jamroenrak, T. Archevapanich, "Red Defect Detection For Rice Quality Assurance By Using Machine Learning", Ninth International Conference on Advances in Computing, Electronics and Communication- ACEC, APR 2019.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Red defect detection for rice quality assurance by using Machine Learning

Phuvin Kongsawat, Nawapat Jamroenrak, Tuanjai Archevapanich, Boonchana Purahong and Attasit Lasakul
Department of Information Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang,
Bangkok 10520, Thailand
Faculty of Engineering and Architecture, Rajamangala University of Technology Suvarnabhumi, Thailand

This article presents an inspection system to detect red kernel defect, normally contaminating in white rice product. This contamination causes a reduction in the price rice of 6% approximately. To detect Red defect successfully, a method proposed in this paper was built up on Machine Vision techniques. The method contains three processing steps as follows. Firstly, noise elimination and localization were executed through image processing techniques. After that, RGB image would be transformed to HSV in order to obtain discriminative features. Finally, the pre-processed data was then passed into model training by using both linear and non-linear Support Vector Machines. Apart from that, Logistic regression was then employed to challenge margin maximization ability of the SVMs. The experimental result shows that linear-SVM still yields the highest performance at 86.3% of classification accuracy.

Keywords: Thailand standard for rice, Machine Vision, HSV, Support Vector Machine.

1. Introduction

Thailand has the second most export volume of rice into the global Rice market. The success factor is that there is the Rice standard declared by the ministry of commerce Thailand call [1] "Thailand standard for rice". On the other hand, the existing method being utilized to evaluate rice quality is human judgment which cause time-consuming and mistakes. To solve these problems, machine vision are crucial and required.

In the science techniques there are many methods of machine vision to inspect and assess rice quality which have developed in a few years ago for example [2] the machine vision was used to assess rice quality by using feature extraction which select Major axis, Minor axis, Area and eccentricity then put features to Neural Network PNN Probabilistic Neural Network model in order to train and predict rice quality, [3] presents an assessment of grain quality emphasizing on broken rice, head rice, small broken rice, and large-sized rice discarded in rice production by Least-Square Support Vector Machine (LS-SVM) and Radius Basis Function (RBF) with the accuracy of 98.20%, [4] used machine vision to measure sizing of rice. The article provides accurate result than existing methods both Scion and Feret diameter, [5] apply machine vision and image processing for Chalky kernel detection. The article extracts geometrical features then put the features to train and predict by using Back-propagation Neural Network which come up with 90% of accuracy, [6] utilize Support Vector Machine to classify

rice grade (Premium, Grade A, Grade B and Grade C), [7] the machine vision applied to classify cereal grains (barley, rye, oats and wheat) the article extract color features which achieved a classification accuracy of 98.5% for barley, 99.97% for CWRS, 99.93% for oat, and 100% for rye. [8] focused on classify foreign matters, type admixture and brown grain content by using Back-propagation Neural Network. Tests on the system for the training and test sets show accuracy in between 94% to 68% for the four grades. The institute classifies rice into four quality categories according to several parameters.

This article presents the Machine Vision method to detect Red defect Fig 1 which contaminate in white rice Fig 2. The method contains three processing steps as follows. Firstly, noise elimination and localization were executed through image processing techniques. After that, RGB image would be transformed to HSV in order to obtain discriminative features. Then, the pre-processed data was then passed into model training phase. In this phase aim to find appropriate both the amount of data training and classified model. Hence, comparing of accurate result in case of Linear Support Vector Machine and Radius Basis Function Support Vector Machine in order to find separable pattern is either linear or non-linear.



Figure 1. Red Defect Kernels



Figure 2. White Kernels

II. Methodology

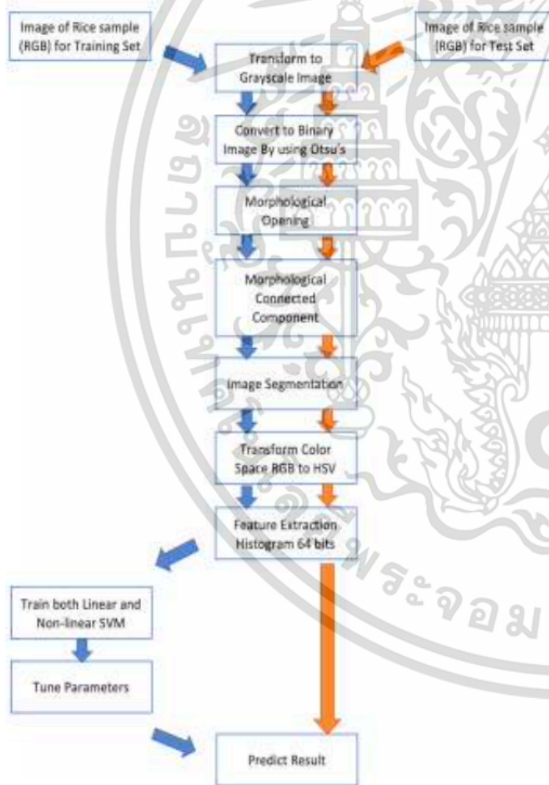


Figure 3. Dataflow diagram for the proposed approach

A. Equipment Preparation

The first step in machine vision acquire properly and certainly input image in order to gain accurate results. Hence, flatbed scanner is required. This article used Canon LIDE 120 flatbed scanner by selecting resolution 600 dpi. The scanner is independence from external light and provide best quality image which appropriate for classification task. The uniform background which is black in color. The rice kernels are

spread on a scanner glass randomly. Although the rice kernels were putted into the scanner randomly, and then make sure that they are not overlap and joint each other. The images were captured and stored in JPEG format automatically.

B. Preprocessing

This procedure focus on prepare proper data to train the machine learning. The procedure as follows.

- Transform RGB color space transform to grayscale image Fig 1.
- Transform grayscale image to binary image by Otsu's method [9]
- Morphological opening [10] method was utilized for noise eliminating.
- Morphological labeling component [10] was used to find each position of rice kernel in image.
- Cropping RGB image of each rice kernel from their position was delivered from previous morphological method rice.
- Transform RGB image to HSV image
- Transform HSV to histogram 64 bits

C. Feature Extraction

There are various features in image such as color, geometrical and etc. However, we selected features from 3 histogram intensity 64 bits including Hue: H, Saturation: S and Value: V. And then normalization by divide each bit by their summation of each histogram

D. Support Vector Machine Preliminary

A Support Vector Machine: SVM is a discriminative classifier. It was defined by decision boundary as a separating hyperplane. In other words, given labeled training data (Supervised Learning) and Non-parametric model. To optimize the decision boundary with maximum margin of separation between 2 class which made from the support vectors Fig 4. The decision boundary is perpendicular with vector w . It implies that $W^T X^+ + b = +1$ and $W^T X^- + b = -1$. X^+ denote a positive point with functional margin of 1. X^- denote a negative point respectively. b denotes the distance of projection between point and W vector.

The functional margin of resulting classifier M follow equation (1) which aim to maximize margin.

$$M = \frac{2}{\|W\|} \quad (1)$$



Asst.Prof.Dr. Tuanjai Archevapanich. As a Lecturer of Faculty of Engineering and Architecture, Rajamangala University of Technology Suvarnabhumi. Interesting about Antenna and Engineering Education.



Asst.Prof. Boonchana Purahong. As a Lecturer of Information Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang. Interesting about Machine Learning, Robotics, Image Processing and Embedded System.

Assco.Prof.Dr. Attasit Lasakul. As a Lecturer of Information Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang. Interesting about Machine Learning, Signal and Image Processing and Microprocessor

ประวัติผู้เขียน

- ชื่อ – นามสกุล นาย ภูวินทร์ คงสวัสดิ์
- วัน เดือน ปี เกิด 26 พฤศจิกายน 2534
- ที่อยู่ 72/289 ประภาวรรณ ถนนสุวินทวงศ์ แขวง แสนแสบ เขต มีนบุรี กรุงเทพมหานคร 10510
- ประวัติการทำงาน กรรมการผู้จัดการบริษัท อีซีไรซ์ ดิจิทัล เทคโนโลยี จำกัด
หัวหน้าทีมฝ่ายปฏิบัติพัฒนาเครื่องตรวจสอบคุณภาพข้าวปัญญาประดิษฐ์ (2561-2562) โครงการ U.reka Deep Tech Discovery
- ประวัติการศึกษา 2559 วิศวกรรมศาสตรบัณฑิต สาขาโทรคมนาคม สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้