

แบบจำลองการคัดแยกผลไม้แบบหนึ่งชนิดด้วยการเรียนรู้ของเครื่อง เพื่อตรวจจับรูปแอปเปิ้ล

Machine Learning-Based One-Class Fruit Classification Models for Apple Images Detection

ศิริชัย โชติชาติมามา

สาขาวิชาวิทยาการข้อมูล, คณะวิทยาศาสตร์

มหาวิทยาลัยศรีนครินทรวิโรฒ

กรุงเทพมหานคร, ประเทศไทย

Sirichai.chotichatmala@g.swu.ac.th

นุวิทย์ วิวัฒน์วัฒนา

สาขาวิชาวิทยาการข้อมูล, คณะวิทยาศาสตร์

มหาวิทยาลัยศรีนครินทรวิโรฒ

กรุงเทพมหานคร, ประเทศไทย

nuwee@g.swu.ac.th

บทคัดย่อ—งานวิจัยฉบับนี้มีวัตถุประสงค์ เพื่อสร้างแบบจำลองการคัดแยกผลไม้แบบหนึ่งชนิดด้วยการเรียนรู้ของเครื่องเพื่อตรวจจับรูปแอปเปิ้ล โดยใช้เทคนิคการตรวจสอบสิ่งผิดปกติ (Novelty Detection) คือเทคนิคที่เรามีชุดข้อมูลปกติ (Training Data) ซึ่งคือรูปแอปเปิ้ลเพียงชนิดเดียวทั้งหมด และต้องการตรวจจับข้อมูลใหม่หรือข้อมูลผิดปกติในชุดข้อมูลทดสอบ (Test data) ที่อยู่นอกเหนือจากชุดข้อมูลปกติซึ่งก็คือการทำนายว่าข้อมูลใหม่นั้นเป็นหรือไม่ โดยในงานวิจัยนี้แบบจำลองการคัดแยกผลไม้ สร้างจากเทคนิคการตรวจจับสิ่งใหม่ (Novelty Detection) โดยใช้ แบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) และ แบบจำลองต้นไม้ (Isolation Forest) ซึ่งทั้ง 2 แบบจำลองเป็นเทคนิคสำหรับการสร้างแบบจำลองแบบ Unsupervised Learning ซึ่งสามารถนำแบบจำลองที่ได้ไปประยุกต์ใช้ในการคัดแยกผลไม้แอปเปิ้ลได้ต่อไป

Keywords—Support Vector Machine, Isolation Forest, Novelty Detection

I. บทนำ

ปัจจุบันการรับรู้และแยกแยะผลไม้มีหลายชนิดและหลากหลายสายพันธุ์ให้เลือกซื้อในซูเปอร์มาร์เก็ต ซึ่งปัญหาของการคัดแยกผลไม้ชนิดต่างๆเกิดขึ้นเนื่องจาก ขนาดที่ต่างกัน, สีที่ต่างกัน, เนื้อผลไม้ที่ต่างกัน หรือความเหมือนกันทั้งขนาด,สีและเนื้อผลไม้ ในระหว่างการวางสินค้าอาจเกิดปัญหาย่างน้อย 2 ครั้งคือเมื่อมีการคัดแยกผลไม้คัดแยกสายพันธุ์เพื่อนำขึ้นชั้นวาง และเมื่อลูกค้าหยิบแล้วคืนในชั้นวางที่ไม่ใช่ชนิดของผลไม้ในนั้น ซึ่งปัญหาดังกล่าวนี้ใช้ทรัพยากรในแต่ละวันค่อนข้างมาก ทั้งนี้การใช้ทรัพยากรคนอาจจะทำให้เกิดความผิดพลาดในการแยกประเภทของผลไม้เนื่องจาก บางชนิดนั้นมีรูปร่างที่คล้ายกันแต่ไม่ใช่ชนิดเดียวกัน ยกตัวอย่างเช่น ผลไม้สาลี่กับแอปเปิ้ลเขียว เป็นต้น

จากปัญหาข้างต้นปัจจุบันหลายๆที่ยังไม่ได้รับการแก้ไข ส่วนทางกับการบริหารผลไม้ของคนที่มากขึ้นทุกวัน ทำให้ผู้วิจัยเห็นความสำคัญของการสร้างวิธีแยกชนิดของผลไม้โดยลดทรัพยากรคน ในงานวิจัยนี้ต้องการหาคำตอบปัญหาของการที่มีผลไม้ชนิดอื่นปนอยู่บนตะกร้าหรือชั้นวางของด้วยวิธีการเรียนรู้ของเครื่องจักร (Machine Learning) ซึ่งในการคัดแยกผลไม้แอปเปิ้ลในงานวิจัยนี้จะใช้เทคนิคที่เรียกว่าการตรวจจับข้อมูลใหม่ (Novelty Detection) โดยอนุมานว่ามีหุ่นยนต์คอยคัดแยกผลไม้ โดยที่หุ่นยนต์จะตรวจสอบว่ารูปภาพผลไม้ชนิดใดมีแนวโน้มที่จะเป็นแอปเปิ้ล หรือรูปภาพใดที่มีแนวโน้มไม่ใช่แอปเปิ้ลด้วยแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) และแบบจำลองป่าแยก (Isolation Forest) เพื่อให้กระบวนการจัดการคัดแยกผลไม้แอปเปิ้ลและไม่ใช่แอปเปิ้ลเป็นไปโดยอัตโนมัติ จึงจำเป็นที่จะต้องนำเสนอแบบจำลองในการตรวจสอบ โดยจุดประสงค์หลักของงานวิจัยนี้ก็เพื่อแสดงให้เห็นถึงแบบจำลองที่มีประสิทธิภาพที่ใช้ในการจำแนกประเภทผลไม้แอปเปิ้ลและไม่ใช่แอปเปิ้ล เพื่อนำไปประยุกต์ใช้ต่อไป ซึ่งในงานวิจัยนี้จะกล่าวต่อไปนี้ประกอบด้วยหัวข้อที่ 2 งานวิจัยที่เกี่ยวข้อง ระเบียบงานวิจัยที่นำมาอ้างอิงในงานวิจัยนี้โดยจะเน้นไปที่งานวิจัยการทำแบ่งแยกประเภท Classification และงานวิจัยที่เกี่ยวข้องกับการตรวจจับสิ่งใหม่ (Novelty Detection)

หัวข้อที่ 3 ชุดข้อมูลที่นำมาใช้ในงานวิจัยรวมถึงรายละเอียดข้อมูลภาพผลไม้ที่นำมาใช้ในงานวิจัย หัวข้อที่ 4 แบบจำลองและวิธีการ ซึ่งจะกล่าวถึงกระบวนการวิจัยและพัฒนาแบบจำลอง โดยกล่าวถึงทฤษฎีของแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) และแบบจำลองป่าแยก (Isolation Forest) หัวข้อที่ 5 การทดลองและผลลัพธ์ กล่าวถึงการประยุกต์ใช้แบบจำลองกับชุดข้อมูลผลไม้ โดยการเทียบประสิทธิภาพของแบบจำลองทั้ง 2 แบบด้วย Confusion Matrix, F1-Score, Accuracy และ ROC AUC ซึ่งผลลัพธ์คือการเทียบว่าการทำนายภาพแอปเปิ้ลและไม่ใช่ภาพแอปเปิ้ล ถูกหรือผิดได้กี่รูปภาพ หัวข้อที่ 6 สรุปผลการทดลอง กล่าวถึงการสรุปผลของประสิทธิภาพของแบบจำลองทั้ง 2 แบบว่าแบบจำลองใดสามารถจำแนกภาพแอปเปิ้ลและไม่ใช่ภาพแอปเปิ้ลได้ดีกว่า สุดท้ายคือหัวข้อเสนอแนะจะกล่าวถึงอุปสรรคของงานวิจัยและข้อจำกัดต่างๆที่เกิดขึ้น

II. งานวิจัยที่เกี่ยวข้อง

งานของ Perera และคณะ[1] นี้ผู้วิจัยพยายามที่จะสร้าง Deep Novelty ซึ่งเป็น การตรวจจับ (Novelty Detection) ภาพที่ผิดปกติออกไป โดยข้อสรุปจากงานวิจัยนี้ในการเรียนรู้เชิงลึกสำหรับ Novelty Detection โดยในงานวิจัยนี้ทดสอบประสิทธิภาพของวิธีที่นักวิจัยเตรียมมาทดสอบเทียบกับวิธีอื่น เช่น Finetune, One-Class SVM, KNFST pre, KNFST, Local KNFST pre, Local KNFST, K- extremes, OpenMax, Finetune (c+C) , Deep Novelty โดยทั้งหมดที่กล่าวมาข้างต้นจะใช้การดึงคุณลักษณะ (Feature Extraction) ด้วยวิธีเดียวกันคือ VGG16 และ AlexNet ผลปรากฏว่าวิธี Deep Novelty ดีที่สุด

งานของ Jintawatsakoon และคณะ[2] มุ่งเน้นการจัดประเภทขวดเครื่องดื่ม โดยโมเดลที่จะใช้มี 3 โมเดลคือ N-Binary คือวิธีที่พยายามระบุ Class ที่ไม่รู้ใครจะเป็น Positive หรือ Negative , N+Unknown คือวิธีการสร้าง 3 Class ที่เป็นเป้าหมาย ส่วน Class ที่ไม่รู้จักจะถูกแทนด้วยภาพที่ไม่ได้เป็น Class เป้าหมาย และ N+Combination คือวิธีการสร้าง 3 Class ที่เป็นเป้าหมาย ส่วน Class ที่ไม่รู้จักจะถูกแทนด้วยภาพที่เป็น Class เป้าหมาย ซึ่งชุดข้อมูลที่นำมาประเมินประกอบด้วยภาพขวด 11,309 รูป ประกอบด้วย Product1 จำนวน 1,024 รูป, Product2 จำนวน 1,027 รูป และ Product3 จำนวน 1,032 รูป และ Unknown product ประกอบด้วย 8,226 รูป ผลการทดสอบทั้ง 3 วิธีพบว่า ค่าความถูกต้องที่สูงที่สุดคือ N+Unknown ที่ 92%

งานของ Zhu และคณะ[3] กล่าวถึงความสำคัญของการคัดแยกผลไม้ที่มีส่วนสำคัญต่อการผลิตของผลไม้ โดยใช้ข้อมูลการทดสอบคือชุดข้อมูลภาพผลไม้ 360 องค์ โดยในการคัดแยกประเภทของผลไม้ใช้วิธี โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network : CNN) เป็นหลัก โดยเปรียบเทียบค่าความถูกต้องระหว่าง IANET (5 Convolutional Layers, 4 Fully Connection Layers and 1 Output Layer), HoreaCNN, ALexNet และ 13-LayerCNN ประกอบกับการใช้เทคนิค Data Augmentation

พบว่าวิธี IANET พร้อมกับการใช้ Data Augmentation ให้ค่าความถูกต้อง 98.60% ซึ่งเมื่อเทียบกับวิธี IANET และไม่ได้ใช้ Data Augmentation จะได้ค่าความถูกต้องเพียง 98.06%

งานของ Shabbudin และคณะ [4] กล่าวถึงการคัดแยกพันธุ์ของกล้วยาเพื่อประโยชน์ในการดำรงไว้ซึ่งประสิทธิภาพและคุณภาพของกล้วยา โดยเปรียบเทียบประสิทธิภาพระหว่างแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค่าขึ้นประเภทเดียว (One-Class Support Vector Machine) และแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค่าขึ้นประเภทสองชนิด (Binary Support Vector Machine) ซึ่งกำหนดขนาดภาพอยู่ที่ 100 x 100 พิกเซล และกำหนดพารามิเตอร์ดังนี้ Kernel คือ RBF, กำหนดค่าความผิดพลาดในการทำนายพลาด (nu) แยกค่ากันที่ 0.7, 0.9 และ 0.2 พบว่าค่าความถูกต้องของแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค่าขึ้นประเภทเดียว (One-Class Support Vector Machine) มีความแม่นยำกว่า แบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค่าขึ้นประเภทสองชนิด (Binary Support Vector Machine) ทุกรูปแบบ

Hara และคณะ[5] กล่าวถึงการตรวจจับข้อมูลที่มีความผิดปกติจากเครื่องกำเนิดไฟฟ้าพลังน้ำ ซึ่งเปรียบเทียบประสิทธิภาพระหว่างวิธีป่าแยก (Isolation Forest) กับวิธีควบคุมกระบวนการผลิตด้วยหลักสถิติหลายตัวแปร (Multivariate Statistical Process Control : MSPC) โดยกำหนดไฮเปอร์พารามิเตอร์ของวิธีป่าแยก (Isolation Forest) กำหนดค่า Contamination ที่ 0.333 และวิธีควบคุมกระบวนการผลิตด้วยหลักสถิติหลายตัวแปร (Multivariate statistical process control: MSPC) ใช้ค่า Q-Value ที่ 0.997 ซึ่งตัววัดประสิทธิภาพคือพื้นที่ใต้เส้นโค้ง (AUC) โดยแบ่งเป็น 4 แบบคือ ค่าเฉลี่ย (Average), ค่าสูงสุด (Max), ค่าต่ำสุด (Min) และ ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ซึ่งผลปรากฏว่าแบบจำลองป่าแยก (Isolation forest) ให้ค่าความถูกต้องที่มากกว่าในทุกรูป

III. ชุดข้อมูล

ภาพที่นำมาใช้งานวิจัยคือเป็นภาพที่ใช้การถ่ายทำผลไม้ในขณะที่กำลังหมุนภาพแล้วทำการแยกเฟรม โดยจากหลังของผลไม้เป็นสีขาว ขนาดของภาพอยู่ในขนาด 100 x 100 pixels โดยเป็นชุดข้อมูลที่นำมาบางส่วนจากชุดข้อมูลภาพผลไม้ 360 องค์ (Fruit-360) โดยได้รับลิขสิทธิ์จาก (c) 2017-2020 Mihai Oltean, Horea Muresan ประกอบด้วยภาพผักและผลไม้จำนวน 90,380 ภาพ ผ่านการจัดประเภท 131 ชนิดดังตัวอย่างในรูปที่ 1 และรูปที่ 2 โดยทางผู้วิจัยได้จัดแบ่งเป็นแอปเปิ้ลและไม่ใช่แอปเปิ้ลเท่านั้น


จากตารางที่ 1 แสดงให้เห็นถึงจำนวนข้อมูลผลไม้ที่ประกอบด้วยแอปเปิ้ลและอื่นๆที่ไม่ใช่แอปเปิ้ล เช่น ส้ม, มังคุด, องุ่น เป็นต้น ซึ่งมีขนาดทั้งหมด 127 MB จะเห็นได้ว่าผู้วิจัยได้ทำการดึงรูปผลไม้ในข้อมูล Training ที่ไม่ใช่แอปเปิ้ลออก เพื่อสร้างสถานการณ์ของการสร้างแบบจำลองที่ตรวจสอบสิ่งที่ไม่ใช่แอปเปิ้ล โดยฝึกฝนเฉพาะภาพแอปเปิ้ลจึงนำมาซึ่งหัวข้อปัญหาแบบ Novelty Detection

ตารางที่ 1 : ชุดข้อมูลที่นำมาใช้ในงานวิจัย

ข้อมูล	ชุดข้อมูล Training	ชุดข้อมูล Testing
แอปเปิ้ล	6,404 รูป	2,134 รูป
ผลไม้อื่นๆ	-	20,554 รูป
รวม	6,404 รูป	22,688 รูป




รูปที่ 1 : ตัวอย่างข้อมูลรูปภาพชุดข้อมูล Fruit-360 ที่เป็นแอปเปิ้ล



รูปที่ 2 : ตัวอย่างข้อมูลรูปภาพชุดข้อมูล Fruit-360 ที่ไม่ใช่แอปเปิ้ล

IV. แบบจำลอง และวิธีการ



รูปที่ 3 : กระบวนการวิจัย

กระบวนการวิจัยในการสร้างแบบจำลองตรวจจับข้อมูลใหม่ (Novelty Detection) เพื่อตรวจจับเฉพาะรูปแอปเปิ้ลหรือก็คือสามารถทราบได้ว่าสิ่งใดไม่ใช่แอปเปิ้ลประกอบไปด้วยขั้นตอนดังนี้

A. การเตรียมข้อมูล (Data Preprocessing)

ในงานวิจัยนี้ใช้โครงข่ายประสาทเทียมแบบลึกที่เรียกว่า ResNet50 คือแบบจำลองที่มีชั้นของ Layer จำนวน 50 เลเยอร์ ซึ่งสถาปัตยกรรมประกอบด้วย 4 Block ในแต่ละ Block จะมี Convolutional Layer ประกอบด้วย 3, 4, 6 และ 3 คำนวณค่าซึ่งรวม Convolutional Layer ชั้นที่ติดกับข้อมูลที่นำเข้า และชั้นที่ติดกับข้อมูลที่นำออกจากการสถาปัตยกรรม ใช้สำหรับการดึงคุณลักษณะจากภาพออกมาซึ่งจะทำให้มิติหรือว่า Dimension สูงขึ้น ซึ่งทำให้ต้องทำ Standard Scaler เพื่อให้ภาพที่ออกมาจาก ResNet50 อยู่ในมาตรฐานเดียวกัน หลังจากนั้นทำการวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis :

PCA) เป็นการทำให้องค์ประกอบที่สัมพันธ์กันมาอยู่รวมกันทำให้ข้อมูลเล็กลงหรือลดสิ่งรบกวนลง หลักการทำงานคือหาเส้นตรงหรือ Hyperplane เพื่อฉายภาพจากมิติที่สูงกว่าลงมายัง Hyperplane ในมิติที่ต่ำกว่า ในงานวิจัยนี้ใช้สำหรับลดมิติหรือ Dimension ของข้อมูลลงหลังจากผ่านขั้นตอนการเตรียมข้อมูลแล้วขั้นตอนถัดไปคือการนำข้อมูลเข้าแบบจำลองเพื่อฝึกฝน


B. สร้างแบบจำลอง (Model Building)

ในงานวิจัยนี้เลือกใช้แบบจำลอง 2 แบบคือแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine : SVM) และแบบจำลองต้นไม้ (Isolation Forest) เพื่อเปรียบเทียบประสิทธิภาพเนื่องจาก งานวิจัยนี้เป็นงานวิจัยสำหรับตรวจจับข้อมูลใหม่ (Novelty Detection) ซึ่งทั้ง 2 แบบจำลองนี้เป็นแบบจำลองที่สอดคล้องกับหลักการของการตรวจจับข้อมูลใหม่ (Novelty Detection)

แบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine : SVM) เป็นอัลกอริทึมการเรียนรู้ที่แบบ Unsupervised learning ซึ่งได้รับการฝึกฝนเฉพาะกับข้อมูลผลไม่แอปเปิ้ล คือมี Class Label เพียง 1 Class แบบจำลองจะเรียนรู้ขอบเขตของภาพแอปเปิ้ลดังนั้นจึงสามารถจำแนกภาพผลไม้ได้ ๆ ที่อยู่นอกขอบเขตตามที่คาดได้ว่าไม่เป็นภาพแอปเปิ้ล จากรูปที่ 4 หลักการทำงานของ One-Class Support Vector Machine กำหนดให้ x คือค่าของรูปภาพที่ส่งเข้าแบบจำลองและ S คือค่าความน่าจะเป็นที่จะเป็นรูปภาพที่เป็นผลไม่แอปเปิ้ล กรณีที่ถ้าค่า x น้อยกว่า S จะให้ค่า 1 ซึ่งคือเป็นภาพผลไม่แอปเปิ้ล แต่ถ้า x มากกว่า S จะให้ค่า 0 คือไม่ใช่ภาพผลไม่แอปเปิ้ล และจากรูปที่ 5 เส้นขอบแสดงการทำงานของ แบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) แสดงถึงภาพที่ความน่าจะเป็นของรูปภาพผลไม่แอปเปิ้ลจะแสดงค่าอยู่ในวงรี ส่วนรูปภาพผลไม้ที่ไม่ใช่รูปภาพแอปเปิ้ลจะแสดงว่าอยู่นอกวงรี

$$f(x) = f(x) = \begin{cases} 1 & \text{if } x < S \\ 0 & \text{if } x \geq S \end{cases} \quad (1)$$

รูปที่ 4 : หลักการทำงานของ One-Class Support Vector Machine



รูปที่ 5 : เส้นขอบแสดงการทำงานของ แบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine)

แบบจำลองป่าแยก (Isolation Forest) เป็นอัลกอริทึมการเรียนรู้ที่เป็นแบบ Unsupervised Learning เป็นแบบจำลองที่พัฒนามาจาก Decision Tree แตกต่างกันเนื่องจากแบบจำลองป่าแยก (Isolation Forest) คือการเพิ่มจำนวนต้นไม้เป็นหลายๆต้น ทำให้ประสิทธิภาพการทำงานสูงขึ้น สามารถค้นหาผลไม่ที่ไม่ใช่แอปเปิ้ล เป้าหมายการทำงานของแบบจำลองต้นไม้คือการลดค่า Correlation ระหว่างกันจะทำให้แบบจำลองยังมีประสิทธิภาพ โดยในงานวิจัยนี้ผู้วิจัยได้กำหนดพารามิเตอร์ต่างๆที่ส่งผลต่อแบบจำลองดังนี้ Contamination เป็นตัวกำหนดสัดส่วนการทำนายของสิ่งที่ไม่ใช่แอปเปิ้ลบนชุดข้อมูล, max_features จำนวนสูงสุดที่จะดึงคุณสมบัติมาฝึกฝน ต้นไม้แต่ละต้น หากค่ามากจะไปเพิ่ม Correlation, max_samples คือการระบุจำนวนของชุดข้อมูลที่สุ่มขึ้นมาเพื่อใช้ในการฝึกฝนแบบจำลอง และ n_estimators คือการระบุจำนวนต้นไม้ที่จะสร้าง

C. การประเมินผล (Evaluation)

สุดท้ายคือการประเมินผล (Evaluation) ในที่นี่ใช้การประเมินแบบจำลอง 4 วิธี โดยใช้ Confusion Matrix, ค่าความถูกต้อง (Accuracy), ค่า F1-Score แบบ Macro Average และค่า ROC AUC เทียบกันระหว่าง 2 แบบจำลอง

Confusion Matrix คือตารางสำคัญในการวัดความสามารถของแบบจำลองในการแก้ปัญหา Classification จากตารางที่ 2 ประกอบด้วย True Positive (TP) คือ สิ่งที่แบบจำลองทำนายว่า "จริง" และมีค่าเป็น " จริง " , True Negative (TN) คือ สิ่งที่แบบจำลองทำนายว่า "ไม่จริง" และมีค่า " ไม่จริง" , False Positive (FP) คือ สิ่งที่แบบจำลองทำนายว่า "จริง" แต่มีค่าเป็น "ไม่จริง" , False Negative (FN) คือ สิ่งที่แบบจำลองทำนายว่า "ไม่จริง" แต่มีค่าเป็น "จริง"

ตารางที่ 2 : ตาราง Confusion matrix

		Actual Values	
		Positive (1)	Negative(0)
Predicted Values	Positive (1)	True Positive (TP)	False Positive (FP)
	Negative(0)	False Negative (FN)	True Negative (TN)

การประเมินผลด้วยค่าความถูกต้อง (Accuracy) เป็นค่าความถูกต้องที่ได้จากนำชุดข้อมูลทดสอบเข้าแบบจำลองทั้ง 2 แบบ ดังสมการนี้

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2)$$

การประเมินผลด้วยค่า F1-score แบบ Macro Average เกิดจากการนำค่าของ Precision คือ จำนวนที่แบบจำลองสามารถทำนายได้ภาพ(ไม่ใช่)รูปแอปเปิ้ลถูกต้องหารด้วยจำนวนที่แบบจำลองสามารถทำนายได้ภาพ(ไม่ใช่)รูปแอปเปิ้ลถูกต้องหารด้วยจำนวนที่แบบจำลองสามารถทำนายได้ภาพ(ไม่ใช่)รูปแอปเปิ้ลถูกต้องหารด้วยจำนวนที่เป็นรูป(ไม่ใช่)แอปเปิ้ลทั้งหมด โดยนำมาเฉลี่ยทั้ง 2 Class (ใช่และไม่ใช่แอปเปิ้ล) ซึ่งค่า F1-score แบบ Macro Average สามารถบอกถึงความสามารถแบบจำลองในแง่ที่แอปเปิ้ลเป็นคลาสที่สนใจ กับแง่ที่แอปเปิ้ลเป็นคลาสที่ไม่สนใจ ดังสมการที่ (3), (4) และ (5)

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{F1-Score} = \frac{2 * (\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (5)$$

ค่า ROC AUC คือ พื้นที่ใต้กราฟ ระหว่าง False Positive Rateคือแบบจำลองทำนายว่าเป็นผลไม่แอปเปิ้ลแต่ความจริงไม่ใช่ผลไม่แอปเปิ้ล และ True Positive Rate คือแบบจำลองทำนายว่าเป็นรูปภาพแอปเปิ้ลได้ตรงกับรูปภาพแอปเปิ้ลจริง ซึ่งค่าโดยรวมของ ROC AUC จะต้องมีค่ามากซึ่งเป็นตัววัดว่าแบบจำลองมีประสิทธิภาพ

V. การทดลองและผลลัพธ์

วิธีการทดลองคำนวณงานวิจัยในการสร้างแบบจำลองการคัดแยกผลไม่แอปเปิ้ลออกจากผลไม้ การดำเนินการโดยทำบนแพลตฟอร์มของ Kaggle เนื่องจากข้อมูลภาพมีขนาดใหญ่จึงต้องใช้ทรัพยากรที่ค่อนข้างมาก โดยกระทำการคำนวณงานวิจัยมีขั้นตอนดังนี้

ขั้นตอนการเตรียมข้อมูลเพื่อนำเข้าแบบจำลองประกอบด้วย 2 ส่วนหลักๆคือ ResNet50 ใช้สำหรับการดึงคุณลักษณะเด่นของภาพออกมาโดยกำหนดพารามิเตอร์ดังตารางที่ 3


ตารางที่ 3 : กำหนดไฮเปอร์พารามิเตอร์ของ ResNet50

Hyperparameter	Value
ขนาดของภาพ (Image_size)	100 x 100 pixel
จำนวนน้ำหนัก (Weight)	Imagenet เป็น Transfer Learning
กำหนด Fully-Connected layer (Include_top)	False คือกำหนดให้ไม่รวม Fully-Connected layer
รูปแบบการทำ Feature Extraction (Pooling)	Avg เป็น ค่าเฉลี่ยในการดึงรูปภาพ ประยุกต์ใช้กับผลลัพธ์ 2 มิติ


ซึ่งขั้นตอนถัดมาคือ Standard Scaler เพื่อให้ภาพที่ผ่านออกมาจาก ResNet50 อยู่ในมาตรฐานเดียวกัน หลังจากนั้นทำการวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis : PCA) เพื่อลดมิติหรือ Dimension ของข้อมูลลง โดยในงานวิจัยนี้ผู้วิจัยได้กำหนดพารามิเตอร์ที่ผ่านการทดลองเปลี่ยนค่าแล้วให้ผลลัพธ์ที่ดีที่สุดคือ $n_components$ เท่ากับ 512 และ $whiten$ เท่ากับ True โดย $n_components$ คือ จำนวนองค์ประกอบหลักที่ใช้ ส่วน $whiten$ จะทำการสเกลข้อมูล หลังจากผ่านขั้นตอนการเตรียมข้อมูลแล้วขั้นตอนถัดไปคือการนำข้อมูลเข้าแบบจำลองที่เตรียมไว้

จากผลการทดลองพบว่าแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) จากรูปที่ 6 : การทำนายภาพแอปเปิ้ลถูกต้องจำนวน 1,611 รูป , ทำนายรูปที่ไม่ใช่แอปเปิ้ลถูกต้องจำนวน 19,136 รูป , ทำนายรูปที่ไม่ใช่แอปเปิ้ลแต่ความจริงเป็นแอปเปิ้ล 1,418 รูป และทำนายรูปที่เป็นแอปเปิ้ลแต่ความจริงไม่ใช่แอปเปิ้ล จำนวน 523 รูปซึ่งได้ค่าความถูกต้องทั้งหมดร้อยละ 91 โดยกำหนดไฮเปอร์พารามิเตอร์ต่างๆดังนี้ Kernel คือ RBF (ฟังก์ชันฐานแรดรัสมิ) เป็น Kernel ที่ใช้งานทั่วไป ใช้เมื่อไม่เคเห็นข้อมูลและทำงานในมิติที่ไม่จำกัด และเนื่องจากผลการทดลองคือเมื่อกำหนดเป็น RBF จะให้ผลลัพธ์ที่เร็วกว่าการใช้ค่า Polynomial และ Linear , กำหนดค่าความผิดพลาดในการทำนายพลาด (m) เท่ากับ 0.08 คือการกำหนดขอบเขตบนและขอบเขตล่างของข้อผิดพลาดที่ยอมรับได้และจำนวนที่เราคิดว่าน่าจะทำนายไม่ถูกต้อง และพารามิเตอร์ γ เท่ากับ 0.001 เป็นตัวกำหนดความเรียบของเส้นชั้นความสูงและตัวกำหนดความมีอิทธิพลต่อข้อมูลที่อยู่ใกล้เคียงกัน ซึ่งค่าไฮเปอร์พารามิเตอร์ของแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) ทั้งหมดที่กำหนดได้ทดลองเปลี่ยนค่าแล้วพบว่าได้ค่าที่ให้ผลลัพธ์ที่ดีที่สุด

จากผลการทดลองพบว่าแบบจำลองป่าแยก (Isolation Forest) จากรูปที่ 7 : การทำนายภาพแอปเปิ้ลถูกต้องจำนวน 1,657 รูป , ทำนายรูปที่ไม่ใช่แอปเปิ้ลถูกต้องจำนวน 18,924 รูป , ทำนายรูปที่ไม่ใช่แอปเปิ้ลแต่ความจริงเป็นแอปเปิ้ล 1,630 รูป และทำนายรูปที่เป็นแอปเปิ้ลแต่ความจริงไม่ใช่แอปเปิ้ล จำนวน 477 รูปซึ่งได้ค่าความถูกต้องทั้งหมดร้อยละ 91 ซึ่งกำหนดไฮเปอร์พารามิเตอร์ดังนี้ Contamination คือ 0.08, $Max_features$ คือ 1.0, $Max_samples$ คือ 1.0 และ $n_estimators$ คือ 4 ซึ่งค่าไฮเปอร์พารามิเตอร์ทั้งหมดของแบบจำลองป่าแยก (Isolation Forest) ที่กำหนดได้ทดลองเปลี่ยนค่าแล้วพบว่าได้ค่าที่ให้ผลลัพธ์ที่ดีที่สุด



รูปที่ 6: Confusion matrix ของ One-Class support vector machine โดยกำหนดค่า 0 คือ ไม่ใช่รูปผลไม้แอปเปิ้ล และค่า 1 คือรูปผลไม้แอปเปิ้ล



รูปที่ 7 : Confusion matrix ของ Isolation Forest โดยกำหนดค่า 0 คือ ไม่ใช่รูปผลไม้แอปเปิ้ล และค่า 1 คือรูปผลไม้แอปเปิ้ล

ตารางที่ 4 ตารางเปรียบเทียบผลการทดลองของแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) และ แบบจำลองป่าแยก (Isolation Forest)

Measure	One-class SVM	Isolation Forest
Accuracy	91%	91%
F-1 Score, Macro Avg	79%	78%
ROC AUC	84.29%	84.85%

จากตารางที่ 5 สรุปผลได้ว่าค่าความถูกต้อง (Accuracy) ของแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) และแบบจำลองป่าแยก (Isolation Forest) นั้นเท่ากันที่ร้อยละ 91 , ค่า F1-Score, Macro Avg คือค่าเฉลี่ยของ Precision และ Recall ของทั้ง 2 class ผลคือแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) ดีกว่าแบบจำลองป่าแยก (Isolation Forest) เล็กน้อยที่ร้อยละ 79 และร้อยละ 78 ตามลำดับ และสุดท้ายคือการวัดประสิทธิภาพด้วยค่าพื้นที่ใต้กราฟ (ROC AUC) ซึ่งแบบจำลองป่าแยก (Isolation Forest) ให้ผลที่ดีกว่าเล็กน้อยที่ร้อยละ 84.85 และร้อยละ 84.29 ตามลำดับ

VI. สรุปผล และงานวิจัยในอนาคต

ในงานวิจัยนี้ใช้ข้อมูลผลไม้จาก Fruit-360 ประกอบด้วยภาพแอปเปิ้ลในการ Training และทดสอบแบบจำลองจำนวน 6,404 รูปและ 2,134 รูปตามลำดับและรูปภาพที่ไม่ใช่แอปเปิ้ลในการทดสอบจำนวน 20,554 รูป ซึ่งได้นำหลักการของกระบวนการ ResNet50 เพื่อใช้ในการดึงลักษณะเด่นของภาพออกมาเรียกว่าการ Extract feature ซึ่งส่งผลต่อมิติที่เพิ่มขึ้นจึงได้นำหลักการการวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis : PCA) เพื่อลดมิติและนำข้อมูลเข้าแบบจำลองต่อไป โดยทำการ Train รูปแอปเปิ้ลเพียงอย่างเดียวซึ่งผลการทดลองแบบจำลองทั้ง 2 แบบจำลองได้แก่ แบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) และ แบบจำลองป่าแยก (Isolation Forest) สรุปได้ว่าทั้ง 2 แบบจำลองมีประสิทธิภาพที่ใกล้เคียงกันในการวัดประสิทธิภาพแบบจำลองทั้ง 4 แบบ ผู้วิจัยให้ประสิทธิภาพของแบบจำลองป่าแยก (Isolation Forest) ดีกว่าแบบจำลองจำแนกข้อมูลด้วยเครื่องเวกเตอร์ค้ำยันประเภทเดียว (One-Class Support Vector Machine) เนื่องจากมีการทำนายแอปเปิ้ลได้ถูกต้องมากกว่าอยู่ที่ 1,657 และ 1,611 ตามลำดับ

การพัฒนาแบบจำลองทั้ง 2 แบบเพื่อให้ได้ผลลัพธ์การทำนายที่ดีมากขึ้นในอนาคตสามารถทำได้ดังนี้ เช่น เพิ่มจำนวนข้อมูลฝึกฝน (Training data) เพิ่มขึ้น, จำลองข้อมูลเพิ่มมากขึ้นจากข้อมูลที่ได้มาที่อาจจะคิดเพื่อนไปในบางภาพเพื่อใช้ในการฝึกฝนแบบจำลอง และการจำลองรูปแบบของรูปภาพที่มีการหมุน (Rotate) ในทุกแบบ ในส่วนของขอบเขตในงานวิจัยนี้ได้นำการใช้วิธีการเรียนรู้ของเครื่องจักร (Machine Learning) มาประยุกต์ และใช้ข้อมูลจากชุดภาพผลไม้ 360 องศาซึ่งเป็นภาพจากกล้องวงจรปิดในทุกระดับผลไม้นี้ ซึ่งในทางปฏิบัติแล้วผลไม้แอปเปิ้ลอาจจะรวมอยู่กับผลไม้ชนิดอื่นๆ ซึ่งงานวิจัยอนาคตอาจจะมี การนำภาพรูปผลไม้ที่ไม่มีฉากหลังเป็นผลไม้อื่นรวมอยู่ด้วย เพื่อเข้ามาสร้างแบบจำลองให้มีประสิทธิภาพและพร้อมใช้งานมากกว่านี้

- [1] Perera, P., & Patel, V. M. (2019). Deep transfer learning for multiple class novelty detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2019-June, 11536–11544.
- [2] Jintawatsakoon, S., & Charoenruengkit, W. (2019, 20-22 Nov. 2019). Open-Set Bottle Classifying using a Convolution Neural Network. Paper presented at the 2019 17th International Conference on ICT and Knowledge Engineering (ICT&KE).
- [3] Zhu, D., Wang, M., Zou, Q., Shen, D., & Luo, J. (2019, 25- 27Oct. 2019). Research on Fruit Category Classification Based on Convolution Neural Network and Data Augmentation. Paper presented at the 2019IEEE 13th International Conference on Anti-counterfeiting, Security, and Identification (ASID).
- [4] Shahbudin, S., Zamri, M., Kassim, M., Abdullah, S. A. C., & Suliman, S. I. (2017, 9-10 Nov. 2017). Weed classification using one class support vector machine. Paper presented at the 2017 International Conference on Electrical, Electronics and System Engineering (ICEESE).
- [5] Hara, Y., Fukuyama, Y., Murakami, K., Iizaka, T., & Matsui, T. (2020). Fault Detection of Hydroelectric Generators using Isolation Forest. 2020 59th Annual Conference of the Society of Instrument and Control Engineers of Japan, SICE 2020, 864–869.