



FEAT JOURNAL

FARM ENGINEERING AND AUTOMATION TECHNOLOGY JOURNAL

วารสารวิศวกรรมฟาร์มและเทคโนโลยีการควบคุมอัตโนมัติ

การประเมินปริมาณของเมล็ดข้าวในภาพถ่าย โดยใช้เทคนิคประมวลผลภาพ

Evaluation amount of rice grains in photograph using image processing techniques

พีรณัฐ อันสุรีย์^{1,2,3)} กิตติพงษ์ ลาloon^{1,2,3)*} ชัยยันต์ จันทศิริ^{1,2,3)}สมโภชน์ สุดาจันทร^{1,2,3)} และ กันตพงษ์ แซ่โล^{1,2,3)}Peeranat Ansuree^{1,2,3)} Kittipong Laloon^{1,2,3)*} Chaiyan Junsiri^{1,2,3)}Somposh Sudajan^{1,2,3)} and Kantapong Khaeso^{1,2,3)}¹⁾ศูนย์วิจัยเครื่องจักรกลเกษตรและวิทยาการหลังการเก็บเกี่ยว มหาวิทยาลัยขอนแก่น²⁾ศูนย์นวัตกรรมเทคโนโลยีหลังการเก็บเกี่ยว กระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม กรุงเทพมหานคร³⁾ภาควิชาวิศวกรรมเกษตร คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น¹⁾ Agricultural Machinery and Postharvest Technology Center, Khon Kaen University, Khon Kaen, Thailand.²⁾ Postharvest Technology Innovation Center, Ministry of Higher Education, Science, Research and Innovation, Bangkok, Thailand.³⁾ Department of Agricultural Engineering, Faculty of Engineering Khon Kaen University, Khon Kaen, Thailand.

Received: 2 February 2021

Revised: 21 May 2021

Accepted: 23 May 2021

Available online: 14 June 2021

บทคัดย่อ

การเก็บเกี่ยวข้าวด้วยรถเกี่ยวขนาดข้าว มีปัจจัยที่ส่งผลต่อความสูญเสีย ได้แก่ ปัจจัยด้านการปรับแต่งเครื่อง ที่สามารถควบคุมได้ และปัจจัยด้านสภาพพืช ซึ่งไม่สามารถควบคุมได้ ยกตัวอย่างเช่น ความหนาแน่นของพืช เนื่องจากความหนาแน่นของข้าวในแต่ละพื้นที่ไม่เท่ากัน ส่งผลให้ดัชนีล่อโน้มไม่เหมาะสมกับกลุ่มข้าว ผู้วิจัยนำเสนอวิธีการประเมินความหนาแน่นของเมล็ดข้าว โดยพัฒนาอัลกอริทึมคัดแยกเมล็ดข้าวจากภาพถ่ายของกล้องดิจิทัล เพื่อนำไปพัฒนาเป็นระบบหวั่นเกี่ยวข้าวที่ปรับความเร็วของล่อโน้มได้อัตโนมัติ ภาพถ่ายต้นข้าวจากภาคสนาม จะถูกวิเคราะห์ด้วยการจับภาพนิ่งส่วนต่างๆ ของต้นข้าว แบ่งเป็นกลุ่มได้แก่ เมล็ดข้าว, ใบ, ลำต้น, และ ฟัน โดยมีปัจจัยศึกษาได้แก่ ความชื้นของข้าว และระดับความสูงการถ่ายภาพ อัลกอริทึมที่พัฒนาจะ

ใช้ Model Random forest classification เพื่อทำนายกลุ่มพิกเซลในภาพถ่าย ผลทดสอบอัลกอริทึมที่ได้พัฒนาพบว่า Model ให้ความแม่นยำของการทำนายกลุ่มต่างๆจากพิกเซล อยู่ในช่วง 59.43-86.94 เปอร์เซ็นต์ หลังจากการทำนายพบว่า เปอร์เซ็นต์เมล็ดข้าวในรูปภาพอยู่ที่ 3.08-6.92 เปอร์เซ็นต์ ทำให้ทราบถึงปริมาณของพิกเซลเมล็ดข้าวในภาพถ่าย ซึ่งสามารถใช้อ้างอิงเป็นความหนาแน่นของเมล็ดข้าวได้ และสามารถใช้ปริมาณการทำนายนี้ในการอ้างอิงการพัฒนาปรับตั้งระบบหัวเกี่ยวข้าว ที่ปรับความเร็วของล้อโน้มได้อัตโนมัติ เพื่อให้ได้ดัชนีล้อย่อมที่เหมาะสมกับความหนาแน่นข้าว

คำสำคัญ : ประมวลผลภาพ ประเมินความหนาแน่นของเมล็ดข้าว พิกเซลเมล็ดข้าว

Abstract

Threshing the rice from using combine harvesters has direct impacts variously on the rice yield. The problem caused from the machine itself does not a real matter since the users can manage the machine independently. However, the great unmanageable problem to be primarily considered is the condition of rice in the field such as its growing intensity. Due to the partially inconsistent number of the rice growing in a field, a steady speed of reel index of the combine harvesters will damage the grain in a particular part of the rice field. In the study, the researcher introduces rice grain intensity estimating method by using rice grain screening algorithm system by capturing a digital picture through a camera attached at the top of the combine harvesters in order to further develop the rice combine harvester header with a real-time reel index speed adjusting system. Grains, leaves, stalks and soil surface condition are captured and analyzed concerning the rice moisture content and the altitude at which the picture is captured in real time. The developed rice grain screening algorithm system uses model random forest classification to estimate the rice grain quantity by indicating different color of each part of the rice. During the test, the analyzed result from using rice grain screening algorithm system precisely classified each part of the rice between 59.43 to 86.94 percent of the entire photo pixels. After the process of analyzing, the analyzed intensity of rice production ranges between 3.08 to 6.92 percent. Then the readers can use the result in this study for citation to develop the rice combine harvester header with a real-time reel index speed adjusting system.

Keywords: Image processing: Estimate the grain density: Rice grain pixel

1. บทนำ

การเก็บเกี่ยวข้าวของประเทศไทยนั้น ได้มีการพัฒนารูปแบบการเก็บเกี่ยวมาอย่างต่อเนื่อง ซึ่งพัฒนาจากแรงงานสัตว์ เป็นเครื่องมือเครื่องจักร จนพัฒนามาเป็นรถเกี่ยววนวดข้าวในปัจจุบัน โดยรถเกี่ยววนวดข้าวนั้นเป็นที่ยอมรับเนื่องจากให้ความสะดวกสบายและลดการใช้แรงงาน และให้เปอร์เซ็นต์ต้นข้าวที่มากกว่าและความสูญเสียน้อยกว่าแรงงานคน แต่ความสูญเสียก็ยังเกิดขึ้น แต่จะแตกต่างกันตามสายพันธุ์ของข้าว โดยมีการศึกษาการเก็บเกี่ยวข้าวพันธุ์ขาวดอกมะลิ 105 ที่มีความสูญเสียจากหัวเกี่ยว 3.43 เปอร์เซ็นต์ ความสูญเสียจากการคัดแยกและทำความสะอาด 1.60 เปอร์เซ็นต์ และความสูญเสียจากการนวดซึ่งมีค่าน้อยมาก 0.0215 เปอร์เซ็นต์ คิดเป็นความสูญเสียรวม 5.05 เปอร์เซ็นต์ [1] ทั้งนี้เนื่องจากข้าวพันธุ์ขาวดอกมะลิ 105 มีเอกลักษณ์ที่เมล็ดร่วงหล่นได้ง่ายเมื่อสุกแก่ จึงทำให้การนวดนั้นง่าย ส่งผลให้มีความสูญเสียจากหัวเกี่ยวสูงกว่าส่วนอื่น ส่วนข้าวนาปรังที่มีเอกลักษณ์เมล็ดร่วงได้ยากกว่าเมื่อสุกแก่ จึงทำให้มีความสูญเสียจากการคัดแยกและทำความสะอาดสูงกว่าหัวเกี่ยวและขูดนวด [2]

จากการวิจัยพบว่า ปัจจัยที่มีผลต่อความสูญเสียจากระบบการเกี่ยวโดยใช้เครื่องเกี่ยววนวด ประกอบไปด้วย พันธุ์ข้าว ความชื้นเมล็ดข้าว มุมเอียงต้นข้าว อัตราส่วนเมล็ดต่อฟาง และความหนาแน่นของต้นข้าว จากที่กล่าวมา ชี้ให้เห็นว่าสภาพพืชเป็นปัจจัยที่สำคัญที่ส่งผลต่อความสูญเสียจากการเกี่ยวโดยใช้เครื่องเกี่ยววนวด และนอกจากปัจจัยสภาพพืช ก็ยังมีปัจจัยด้านการปรับแต่งเครื่อง ที่ส่งผลต่อความสูญเสียที่เกิดขึ้น [3] นอกจากนี้ยังมีงานวิจัยได้กล่าวไว้ว่า

ดัชนีลื้อโน้มที่เหมาะสมกับข้าวพันธุ์ขาวดอกมะลิอยู่ที่ 1.5-3.0 ซึ่งปัจจัยตัวนี้เป็นตัวที่ส่งผลต่อความสูญเสียที่เกิดขึ้นมากที่สุด อยู่ที่ 33.95 เปอร์เซ็นต์ [4] แต่เนื่องจากว่า สภาพความหนาแน่นของข้าวในความเป็นจริงนั้นแปรปรวน ไม่เท่ากันแต่ละพื้นที่ [5] จึงทำให้ผู้ขับได้ละเอียดในสวนนี้ไป แล้วก็ยอมรับความสูญเสียที่เกิดขึ้น หรือยิ่งถ้าเป็นการรับจ้างเกี่ยว ซึ่งคิดค่าจ้างเป็นราคาต่อพื้นที่ ไม่ใช่ผลผลิต จึงมีการเก็บเกี่ยวที่รวดเร็ว ทำให้ดัชนีลื้อโน้มไม่เหมาะสมกับกลุ่มข้าวในแต่ละจุด ส่งผลต่อความสูญเสีย และผลผลิตที่ควรจะได้รับ

ในช่วงทศวรรษที่ผ่านมา AI, Machine Learning, Deep Learning หรือระบบปฏิบัติการคอมพิวเตอร์ มีบทบาทอย่างมากแก่หลาย ๆ อุตสาหกรรม ซึ่งในทางอุตสาหกรรมเกษตรก็เช่นกัน ได้มีการนำเทคโนโลยีเหล่านี้มาใช้ ยกตัวอย่างเช่น การใช้ Machine Learning หรือ Deep Learning มาใช้ในงานหาความหนาแน่นของพืช [6] การตรวจสอบความเครียดของพืช [7] การจำแนกสายพันธุ์ด้วยระบบ AI [8] การใช้ Robot ในการตรวจจับผลไม้ [9] การใช้ระบบประมวลผลภาพในการติดตามการออกดอก [10] รวมไปถึง ระบบ Smart Farming หรือระบบอัตโนมัติ เช่น แขนกลจับขึ้นงานจากเครื่องคัดแยกวัสดุอัตโนมัติตามสายพาน [11] การพัฒนาระบบควบคุมการบังคับเลี้ยวสำหรับรถแทรกเตอร์อัตโนมัติ [12] และการควบคุมสภาวะแวดล้อมแบบอัตโนมัติไร้สายในโรงเรือนเปิดดอกเห็ดนางฟ้า [13] เป็นต้น จะเห็นได้ว่างานวิจัยต่าง ๆ ที่ยกตัวอย่างมานั้น มีพื้นฐานมาจากการทำงานและประสบการณ์ของมนุษย์ ซึ่งในการทำงานของมนุษย์นั้น อาจจะมีการผิดพลาดและไม่แม่นยำ [14] ดังนั้น ทางผู้วิจัยจึงคิดว่า


หากมีการนำระบบปฏิบัติการคอมพิวเตอร์เข้ามาประยุกต์ใช้กับการเก็บเกี่ยวด้วยรถเกี่ยวนาข้าว โดยจะใช้ระบบประมวลผลภาพ เข้ามาช่วยตรวจจับปริมาณเมล็ดหน้าหัวเกี่ยว เพื่อที่จะได้นำค่าปริมาณของข้าวไปเป็นตัวอ้างอิงในการปรับตั้งนี้ล้อยให้เหมาะสมกับกลุ่มข้าว ก็จะเป็นแนวทางหนึ่งในการลดปัญหาที่เกิดจากความหนาแน่นของสภาพพืชที่มีความแปรปรวนไม่เท่ากันในแต่ละพื้นที่ เป็นการเพิ่มประสิทธิภาพในการทำงานแก่ผู้ใช้งาน ลดความสูญเสียที่เกิดขึ้น ส่งผลต่อผลผลิตที่ควรจะได้มากขึ้น

การศึกษานี้จึงมีวัตถุประสงค์เพื่อศึกษาแนวทางการประเมินสมบัติทางกายภาพของข้าว โดยใช้เทคนิคประมวลผลภาพ เริ่มจากการนำภาพถ่ายมุมสูงในแปลงข้าว มาวิเคราะห์หาเปอร์เซ็นต์ของเมล็ดข้าวในภาพถ่าย ที่ความขึ้น และความสูงการถ่ายที่แตกต่างกัน ซึ่งประโยชน์ที่คาดว่าจะได้รับคือสามารถนำเทคนิคประมวลผลภาพมาประเมินปริมาณเมล็ดข้าวในรูปภาพ เพื่อที่จะนำอัลกอริทึมนี้ไปพัฒนาเป็นระบบตรวจจับเมล็ดข้าว และสามารถนำไปพัฒนาเป็นระบบหัวเกี่ยวข้าวที่สามารถปรับความเร็วของล้อยได้แบบอัตโนมัติ

2. วิธีการวิจัย

สำหรับงานวิจัยนี้ มีวัตถุประสงค์ในการนำวิธีการ Image processing มาประเมินสมบัติทางกายภาพของข้าว เพื่อที่จะนำอัลกอริทึมนี้ไปพัฒนาเป็นระบบตรวจจับเมล็ดข้าว และสามารถนำไปพัฒนาเป็นระบบหัวเกี่ยวข้าวที่สามารถปรับความเร็วของล้อยได้แบบอัตโนมัติ ในการออกแบบการทดสอบนี้ จึงมีบางส่วนอ้างอิงจากการติดตั้งบนรถเกี่ยวนาข้าว ยกตัวอย่างเช่นระดับความสูงการถ่ายภาพ โดยมีภาพรวม

การศึกษาดังแสดงในภาพที่ 1 และมีวิธีการดำเนินการศึกษา ดังต่อไปนี้



รูปที่ 1 การศึกษาการประเมินสมบัติ

ทางกายภาพด้วยเทคนิคประมวลผลภาพ

1) การเก็บตัวอย่างภาคสนาม

ด้วยการใช้กล้อง DSLR (Olympus OM-D E-5 Mark II) ติดตั้งกับฐานกล้องที่สามารถปรับระดับความสูงได้ ทำการถ่ายภาพข้าวในแปลงภาคสนาม ซึ่งกรอบการถ่ายภาพนั้น จะมีการตัดแต่งข้าวรอบกรอบพื้นที่ โดยจะเหลือข้าวไว้แค่ในกรอบขนาด 0.5 ตารางเมตร (ภาพที่ 2) เพื่อเป็นการควบคุมปริมาณตัวอย่างให้เท่ากัน และในทุกการถ่ายภาพเก็บตัวอย่างนั้น จะมีการบันทึกค่าความเข้มแสงไว้ใช้เป็นข้อมูลประกอบ และเมื่อทำการถ่ายภาพเสร็จสิ้น จะทำการเก็บตัวอย่างของข้าว เพื่อที่จะนำไปหาน้ำหนักและแปลงเป็นความชื้นของตัวอย่าง



รูปที่ 2 ลักษณะการเก็บตัวอย่าง


กำหนดปัจจัยในการศึกษาได้แก่ ระดับความสูงการถ่าย 3 ระดับ ได้แก่ 200, 210, 220 เซนติเมตร จากระดับกล้อง ถึงระดับในการเก็บเกี่ยว (ได้คอรวง 30 เซนติเมตร) และ ความชื้นของข้าว 6 ระดับ โดยทำการเก็บตัวอย่างในแต่ละวัน ซึ่งเป็นอายุข้าวตั้งแต่ 24-34 วันหลังออกดอก (เก็บตัวอย่างวันเว้นวัน เพื่อทิ้งให้ความชื้นข้าวลดลง) โดยมีขอบเขตการศึกษาเป็นช่วงของค่าความเข้มแสง และทดสอบกับข้าวพันธุ์ขาวดอกมะลิ 105 ในจังหวัดขอนแก่น

2) การวิเคราะห์ภาพ (Image processing)


หลังจากมีการเก็บตัวอย่างภาคสนาม ในแต่ละชุดตัวอย่างของแต่ละความชื้น จะทำการเลือก Data ภาพถ่ายชุดต่อเนื่อง จำนวน 10 ภาพ เพื่อที่จะนำมาทำ Model โดยจะแบ่งเป็นชุด Training set ซึ่งจะแบ่งเป็น Calibration set = 7 ภาพ และ Validation set = 3 ภาพ (70 เปอร์เซ็นต์) และเลือก Data ภาพถ่าย มาเป็น Test set = 3 ภาพ (หมายเหตุ: Test set เป็นภาพใน Condition เดียวกัน แต่ไม่ใช่ภาพในชุด Cal และ Val) รวมทั้งหมด 13 ภาพต่อ 1 ความชื้น โดยในแต่ละภาพจะใช้โปรแกรม Photoshop PC6 ในการแปรรูปภาพ เพื่อจะแบ่งกลุ่มในภาพ เพื่อที่จะนำกลุ่มค่าสีไปทำการ Classification ด้วยวิธี Random

forest classification โดยจะแบ่งเป็น 4 กลุ่ม ได้แก่ 1) Pixel ข้าว, 2) Pixel ใบ, 3) Pixel ลำต้น, และ 4) Pixel พื้นและอื่น ๆ (ภาพที่ 3)


Rice




Plant



Leaf



Ground



ภาพที่ 3 ตัวอย่างการแปรรูปภาพแบ่งเป็น 4 กลุ่ม

ใช้โปรแกรม Matlab (R2019b and Simulink for KCU staff and students: KCU Licence) ในการวิเคราะห์โดยชุดข้อมูล Calibration set (7 ภาพต่อ 1 ความชื้น) และ Validation set (3 ภาพต่อ 1 ความชื้น) เกิดจากการนำ Data ของแต่ละกลุ่มมาต่อกัน โดยในของชุด Calibration set จะสุ่มข้อมูล 500,000 พิกเซลต่อกลุ่ม จะได้ $X_{cal} = 500,000 \times 4 = 2,000,000$ pixel, $Y_{cal} = 2,000,000$ pixel โดยกำหนด 1-500,000 คือ กลุ่ม 1, 500,001-1,000,000 คือ กลุ่ม 2, 1,000,001-1,500,000 คือ กลุ่ม 3, 1,500,001-2,000,000 คือ กลุ่ม 4 และในชุด Validation set จะทำการสุ่ม Data = 200,000 พิกเซลต่อกลุ่ม จะได้ $X_{val} = 200,000 \times 4 = 800,000$ pixel, $Y_{val} = 800,000$ pixel โดยกำหนด 1-200,000 คือ กลุ่ม 1, 200,001-400,000 คือ กลุ่ม 2, 400,001-600,000 คือ กลุ่ม 3, 600,001-800,000 คือ กลุ่ม 4 (หมายเหตุ: กำหนดจำนวน พิกเซลต่อกลุ่ม ตามจำนวนพิกเซลรวมกันสูงสุดที่แคปได้ทั้งหมด) เมื่อเตรียมข้อมูลเสร็จเรียบร้อยแล้ว จะสร้างแบบจำลอง Random forest classification เพื่อที่จะใช้ทำนายปริมาณพิกเซลของเมล็ด โดยใช้ภาพ Test set หาค่าเฉลี่ยของค่าสี RGB ในแต่ละ Model

ในการตรวจสอบความถูกต้องหรือความแม่นยำของ Model จะนำผลการ Predict มาตรวจสอบความถูกต้องด้วยการใช้วิธีลบกันของตัวเลข Y_{val} ลบกับ ผล Predict ซึ่งจะได้ค่าตัวเลข -3 -2 -1 0 1 2 3 ดังตารางที่ 1 และนำเสนอตัวแปรตามบทความของ Shiny Abraham [15] โดยจะมีการระบุค่าการจำแนกประเภทที่ถูก และไม่ถูกต้องลงในเมทริกซ์โดยมีตัวแปรต่าง ๆ ได้แก่ TP (True Positive), FN (False Negative), FP (False Positive), DP

(Detection Percent), และ QP (Quality Percent) และสมการที่ใช้ มีรายละเอียดดังสมการที่ 1, 2

ตารางที่ 1 ตารางบันทึกผล Y_{val} - ผล Predict

	Val	1	2	3	4
Cal		Rice	Leaf	Plant	Ground
1	Rice	0	-1	-2	-3
2	Leaf	1	0	-1	-2
3	Plant	2	1	0	-1
4	Ground	3	2	1	0

$$DP = \frac{100 \times TP}{TP + FN} \quad (1)$$

$$QP = \frac{100 \times TP}{TP + FN + FP} \quad (2)$$

หมายเหตุ: DP = Detection Percent (เปอร์เซ็นต์ที่ทำนายถูก)

QP = Quality Percent (คุณภาพ หรือความแม่นยำของโมเดล)

TP1 = จำนวนพิกเซล 0 ของ Rice, Rice

TP2 = จำนวนพิกเซล 0 ของ Leaf, Leaf

TP3 = จำนวนพิกเซล 0 ของ Plant, Plant

TP4 = จำนวนพิกเซล 0 ของ Ground, Ground

FN1 = ผลรวมจำนวนพิกเซล -1 -2 -3 ในแถว Rice

FN2 = ผลรวมจำนวนพิกเซล 1 -1 -2 ในแถว Leaf

FN3 = ผลรวมจำนวนพิกเซล 2 1 -1 ในแถว Plant

FN4 = ผลรวมจำนวนพิกเซล 3 2 1 ในแถว Ground

FP1 = ผลรวมจำนวนพิกเซล 1 2 3 ในหลัก Rice

FP2 = ผลรวมจำนวนพิกเซล -1 1 2 ในหลัก Leaf


FP3 = ผลรวมจำนวนพิกเซล -2 -1 1 ในหลัก Plant

FP4 = ผลรวมจำนวนพิกเซล -3 -2 -1 ในหลัก Ground

3. ผลการวิจัยและอภิปราย

1) ผลการเก็บตัวอย่างภาคสนาม

จากการเก็บข้อมูลภาคสนาม ได้ความชื้นของตัวอย่างอยู่ที่ 14.0, 14.9, 20.5, 23.6, 25.6, และ 32.0 เปอร์เซ็นต์มาตรฐานเปียก และค่าความเข้มแสงอยู่ในช่วง 553.00-1121.00 (807.56 ± 160.20) ลักซ์ โดยมีตัวอย่างภาพถ่าย ดังแสดงในภาพที่ 4



รูปที่ 4 ตัวอย่างข้อมูลภาพถ่าย ทั้ง 6 ความชื้น และ ทุกระดับความสูง

2) ผลการวิเคราะห์ภาพ (Image processing)

หลังจากการเก็บข้อมูลภาคสนามเสร็จสิ้น กระบวนการต่อไปในการทำงานคือการวิเคราะห์ภาพ ซึ่งจะเลือกชุดรูปภาพที่โดนผลกระทบจากลมไม่มากเกินไป เพื่อที่จะเป็นการคัดเลือกตัวอย่างที่คงที่ได้ ค่าเฉลี่ยของสี RGB เมล็ดอยู่ที่ 205 ± 22 , 184 ± 28 , 137 ± 40 หากพิจารณาค่าสี RGB จะพบว่าในกรณีที่ค่าแสง (Light) ใกล้เคียงกัน แต่ความชื้นต่างกัน จะส่งผลให้ค่าสี RGB ต่างกัน ยกตัวอย่างเช่น ค่าสี RGB ของเมล็ดใน MC1 - H210 - Light = 941 - RGB = 199 179 106 กับ MC3 - H210 - Light = 944 - RGB = 191 169 120 จะเห็นว่า ค่า R และ G ลดลง และค่า B สูงขึ้น ซึ่งพอให้เห็นความแตกต่าง ดังแสดงในภาพที่ 5 แต่เมื่อพิจารณาอีก 1 คู่ พบว่า ที่ MC2 - H200 - Light = 627 - RGB = 207 186 137 กับ MC6 - H220 - Light = 638 - RGB = 208 183 146

จะเห็นว่า ค่า R และ G ไม่ได้ลดลงอย่างกรณีแรก แต่สิ่งที่เห็นได้ชัดเจนคล้ายกรณีแรกคือ ค่า B สูงขึ้น และเมื่อนำค่าสีมาเปรียบเทียบกับสายตา พบว่า ยิ่งความชื้นของเมล็ดลดลง สีที่ออกมาจะมีความเป็นสีน้ำตาลอ่อนๆ ต่างที่ความชื้นสูง จะมีเฉดสีเป็นสีครีมน้ำตาลอมเขียว ดังแสดงในภาพที่ 6 จึงสามารถตอบได้ว่า ที่ความชื้นของเมล็ดที่ลดลง ส่งผลให้ค่าสีฟ้า (B) สูงขึ้น (ในกรณีที่ค่าความเข้มแสงเท่ากัน)

MC1 - H210 - Light = 941 RGB = 199 179 106	MC3 - H210 - Light = 944 RGB = 191 169 120
---	---

รูปที่ 5 ภาพเปรียบเทียบค่าสี RGB ของความชื้น เมล็ดที่ 1 และ 3 ในระดับค่าความเข้มแสงใกล้เคียงกัน

MC2 - H200 - Light = 627 RGB = 207 186 137	MC6 - H220 - Light = 638 RGB = 208 183 146
---	---

รูปที่ 6 ภาพเปรียบเทียบค่าสี RGB ของความชื้น เมล็ดที่ 2 และ 6 ในระดับค่าความเข้มแสงใกล้เคียงกัน


ในส่วนของการ Model Classification โดยการใช้ Machine Learning – Random forest classification จากการทดสอบ พบว่า ในแต่ละ Condition นั้น จะได้ค่า QP ที่แตกต่างกัน โดย Model ที่ได้ค่า QP ในการทำนายเมล็ดข้าวสูงสุดคือ MC5 – H200 ซึ่งได้ค่า QP ที่ 86.94% และ Model ที่ได้ค่า QP ในการทำนายเมล็ดต่ำสุดคือ MC1 – H200 ซึ่งได้ค่า QP ที่ 59.43% โดยเหตุผลที่ Model ในแต่ละ Condition มีค่า QP ต่างกัน เนื่องจากค่าสี RGB ที่สวามิโนเดรนนั้นต่างกัน ในกรณีที่ QP น้อยนั้นหมายถึงว่า ค่าสี RGB ในแต่ละ Class มีความใกล้เคียงกัน ยกตัวอย่างเช่น ที่ MC1

ที่ได้ QP ของเมล็ดน้อยเนื่องจากว่าค่าสีของเมล็ดนั้นใกล้เคียงกับสีของใบและต้น ดังนั้น Model จึงทำนาย Class ดังกล่าวเป็น เมล็ด ซึ่งเป็นการเพิ่มตัวหารให้แก่ QP จึงทำให้ค่านั้นลดลง ดังแสดงในตารางที่ 2


ตารางที่ 2 ข้อมูลการวิเคราะห์ Random forest classification ใน Condition ต่าง ๆ

MC (%w.b.)	H (cm)	Class	DP (%)	QP (%)
(1) 32.0	200	1	79.88	59.43
		2	68.00	56.76
		3	69.03	53.66
		4	98.00	95.88
	210	1	80.75	60.61
		2	57.74	46.92
		3	71.32	54.24
		4	97.44	92.85
	220	1	80.14	61.61
		2	57.46	45.58
		3	70.55	53.35
		4	95.72	88.82
(2) 25.6	200	1	89.67	79.11
		2	72.67	60.70
		3	81.59	66.52
		4	97.98	95.72
	210	1	89.88	77.91
		2	73.72	63.45
		3	84.50	69.59
		4	97.86	96.83
	220	1	88.86	77.46
		2	75.10	63.61
		3	80.90	65.57
		4	97.76	96.58
(3) 23.6	200	1	84.23	72.20
		2	73.75	59.55
		3	78.53	64.55
		4	98.51	95.82
	210	1	90.65	80.30
		2	75.11	63.08
		3	78.09	62.94
		4	98.61	97.16
	220	1	90.69	78.99
		2	74.00	62.69
		3	78.12	62.64
		4	98.68	97.77
(4) 20.5	200	1	89.64	78.31
		2	66.96	55.32
		3	80.56	62.71
		4	97.93	97.05
	210	1	90.49	79.53
		2	68.75	55.44
		3	77.44	61.36
		4	98.21	97.12
	220	1	85.68	72.79
		2	66.79	54.92
		3	81.30	63.78
		4	98.52	97.61
(5) 14.9	200	1	95.63	86.94
		2	76.00	61.91
		3	75.86	63.48
		4	97.68	95.23
	210	1	93.81	83.30
		2	67.30	56.18
		3	78.98	61.91
		4	97.86	95.87
	220	1	91.70	82.55
		2	73.87	61.07
		3	81.74	67.41
		4	98.21	97.07
(6) 14.0	200	1	91.28	79.45
		2	77.61	65.50
		3	81.39	69.15
		4	97.81	97.00
	210	1	89.65	76.83
		2	74.74	61.38
		3	76.55	62.85
		4	98.11	97.43
	220	1	91.13	76.74
		2	77.47	64.12
		3	77.56	67.44
		4	98.03	96.84

หลังจากได้ Model Random forest classification ของแต่ละ Condition แล้ว จึงมีการนำภาพ Test set มาทำการทำนายกลุ่มจาก Model ของ Condition นั้น ๆ เพื่อตรวจหากกลุ่มต่าง ๆ ในภาพจริง พบว่า เปอร์เซ็นต์เมล็ดข้าวในภาพถ่าย อยู่ในช่วง 3.26- 6.92 เปอร์เซ็นต์ และจากปัจจัยการศึกษาที่ระดับความสูงที่ต่างกันนั้น พบว่า เปอร์เซ็นต์ข้าวที่ตรวจจับได้ (%Rice Detect) ในแต่ละระดับความสูงจะเห็นได้ว่า ระดับความสูงนั้น ส่งผลให้เปอร์เซ็นต์ที่ตรวจจับได้นั้นต่างกัน โดยจะมากที่สุดที่ระดับความสูง 200 เซนติเมตรจากพื้นดิน ต่อมาเป็น 210 และ 220 เซนติเมตร ตามลำดับ (ภาพที่ 7) เนื่องจากการถ่ายภาพที่ระยะใกล้กว่านั้น ส่งผลให้ภาพวัตถุที่เราถ่ายมานั้นมีขนาดใหญ่ในภาพ เมื่อทำการตรวจจับวัตถุนั้น ๆ จึงทำให้ค่า pixel นั้นสูง จึงสามารถตอบได้ว่า ระดับความสูงการถ่ายภาพนั้น ไม่ส่งผลต่อความแม่นยำ (%Accuracy) ในการสร้าง Model แต่จะส่งผลให้วัตถุในภาพนั้นแตกต่างกัน ตามระดับความสูง โดยมีตัวอย่างผลแสดงการทำนายโดยใช้ภาพจริง ดังแสดงในภาพที่ 8



รูปที่ 7 ความสัมพันธ์ระหว่างเปอร์เซ็นต์ความขึ้น (%w.b.) กับเปอร์เซ็นต์ข้าวที่ตรวจจับได้ (%Rice Detect) ในแต่ละระดับความสูง



รูปที่ 8 ตัวอย่างผลแสดงการทำนายโดยใช้ภาพจริง

4. สรุป

Model Random forest classification ให้ผลการทำนายที่มีความแม่นยำสูงถึง 86.94 เปอร์เซ็นต์ แต่ก็ขึ้นอยู่กับความขึ้นของตัวอย่างด้วย เนื่องจากความขึ้นที่ต่ำ ตัวอย่างจะมีสีที่ใกล้เคียงกัน (เมล็ด, ใบ, ลำต้น) แต่เมื่อความขึ้นลดลง ในส่วนของเมล็ดจะมีสีออกน้ำตาล จะเริ่มแตกต่างออกจาก ใบ และลำต้น

จึงทำให้ Model มีประสิทธิภาพในการทำงานที่สูงขึ้น และหลังจากการทำนายโดยใช้ Model แล้ว พบว่าเปอร์เซ็นต์เมล็ดข้าวในรูปภาพอยู่ที่ 3.08-6.92 เปอร์เซ็นต์ ทำให้ทราบถึงปริมาณของเมล็ดข้าวในภาพถ่าย และสามารถใช้ค่านี้ ในการอ้างอิงปรับตั้งดัชนีลือโน้มให้เหมาะสม

ในการทำ Random forest classification จะเห็นความแตกต่างในแต่ละ Condition จากข้อมูลในการสร้างโมเดล หากข้อมูลมีความแตกต่างกันมาก QP ที่ได้ จะมีค่าสูง แต่หากข้อมูลในการสร้างโมเดลนั้น มีความใกล้เคียงกันในแต่ละ Feature จะทำให้ได้ QP ที่ต่ำ เมื่อทำการเปรียบเทียบกับงานวิจัยอื่น ที่ใช้ Random forest classification มีผลการเปรียบเทียบดังตารางที่ 3

ตารางที่ 3 เปรียบเทียบงานวิจัยที่ใช้ Random forest classification

ชื่องานวิจัย	ชื่อนักวิจัย	ปี	Classification	ผล
การประเมินสมบัติทางกายภาพของข้าวโดยใช้เทคนิคประมวลผลภาพ	กันตพงษ์ แซ่โล	2562	เมล็ดข้าวในภาพถ่าย	59.43-86.94%
An assessment of the effectiveness of a random forest classifier for land-cover classification [16]	V.F.Rodriguez-Galiano et. al.	2012	จำแนกพื้นผิวดินที่มีความซับซ้อน	92%
Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier [17]	Inacio H. et al	2016	วัชพืชในแปลงอ้อย	82%
Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images [18]	Edwin Racsko and Bogdan Zagajewski	2017	จำแนกต้นไม้ในป่าจากการถ่ายภาพด้วย Airborne Prism EXperiment sensor	62%
Classification of Soils into Hydrologic Groups Using Machine Learning	Shiny Abraham, Chau Huynh and Huy Vu	2019	จำแนกเนื้อดินตามสามเหลี่ยม Soil textural class	83%

ซึ่งจะเห็นได้ว่า การใช้ Random forest classification สามารถใช้งานได้หลากหลายรูปแบบ และผลในการวิจัยของงานวิจัยอื่น ๆ ก็มีความแม่นยำในการทำนายใกล้เคียงกัน จึงสามารถยอมรับผลในการวิเคราะห์ของงานวิจัยนี้ได้

5. กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนการสนับสนุนวิจัยจาก ศูนย์นวัตกรรมเทคโนโลยีหลังการเก็บเกี่ยว กระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม กทม. และขอขอบคุณ ศูนย์เครื่องจักรกลเกษตรและวิทยาการหลังการเก็บเกี่ยว ภาควิชาวิศวกรรมเกษตร คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น ที่สนับสนุนสถานที่รวมถึงสนับสนุนอุปกรณ์และเครื่องมือในการทำวิจัย

6. เอกสารอ้างอิง

- [1] วินิต ชินสุวรรณ, สมชาย ขวณอุดม, วสุ อุดมเพทายกุล, วราจิต พะยอม, ณรงค์ ปัญญา. ความสูญเสียในการเก็บเกี่ยวข้าวหอมมะลิโดยใช้แรงงานคนและใช้เครื่องเกี่ยวนวด. วารสารวิจัย มหาวิทยาลัยขอนแก่น. 2542; 4(2): 4-7.
- [2] วินิต ชินสุวรรณ, นิพนธ์ ป้องจันทร์, สมชาย ขวณอุดม, วราจิต พะยอม. ผลของอัตราป้อนและความเร็วลูกรีดที่มีต่อสมรรถนะการนวดของเครื่องเกี่ยวนวดข้าวแบบไหลตามแกน. วารสารสมาคมวิศวกรรมเกษตรแห่งประเทศไทย. 2546; 10(1): 9-14.
- [3] ชัยยันต์ จันทศิริ และ วินิต ชินสุวรรณ. ผลของปัจจัยการทำงานของเครื่องเกี่ยวนวดที่มีต่อความสูญเสียจากชุดหัวเกี่ยวเมื่อเก็บเกี่ยวข้าวพันธุ์ชัยนาท 1. การประชุมวิชาการวิทยาการหลังการเก็บเกี่ยวแห่งชาติ ครั้งที่ 5, 28-29 มิถุนายน 2550, กรุงเทพมหานคร; 2550.
- [4] ชัยยันต์ จันทศิริ. การทำนายความสูญเสียจากระบบการเกี่ยวของเครื่องเกี่ยวนวดข้าวในประเทศไทย. [วิทยานิพนธ์ปริญญาวิทยาศาสตรบัณฑิต]. ขอนแก่น : มหาวิทยาลัยขอนแก่น 2553.
- [5] ชัยยันต์ จันทศิริ. พารามิเตอร์การทำงานของเครื่องเกี่ยวนวดที่มีผลต่อความสูญเสียจากชุดหัวเกี่ยวสำหรับข้าวพันธุ์ข้าวดอกมะลิ 105. วารสารวิจัย มหาวิทยาลัยขอนแก่น. 2551; 13(5): 613-20.
- [6] Ribera J, Chen Y, Boomsma C, Delp EJ. Counting plants using deep learning. IEEE Global Conference on Signal and Information Processing. 2017; 1344-8.
- [7] Ghosal S, Blystone D, Singh AK, Ganapathysubramanian B, Singh A, Sarkar S. An explainable deep machine vision framework for plant stress phenotyping. Proceedings of the National Academy of Sciences. 2018; 115(18): 4613-8.
- [8] Ise T, Minagawa M, Onishi M. Identifying 3 moss species by deep learning, using the "chopped picture" method. Open Journal of Ecology; 2017; 8(3): 166-73.
- [9] Sa I, Ge Z, Dayoub F, Upcroft B, Perez T, McCool C. Deepfruits: a fruit detection system using deep neural networks. Sensors. 2016; 16(8): 1222.

- [10] Xiong X, Duan L, Liu L, Tu H, Yang P, Wu D, et al. Panicle-seg: a robust image segmentation method for rice panicles in the field based on deep learning and superpixel optimization. *Plant Methods*. 2017;13(1):104.
- [11] ปิยะวัฒน์ ศรีธรรม. แขนกลจับขึ้นงานจากเครื่องคัดแยกวัสดุอัตโนมัติตามสายพาน. *วารสารวิศวกรรมฟาร์มและเทคโนโลยีการควบคุมอัตโนมัติ*. 2561; 4(1): 19-27.
- [12] ธีรวัฒน์ เจเื่อน, ฉัตริน เรืองจอหอ, มงคล คุหาพันธ์, กมลชนน วงศ์สถาน, พยงค์ศักดิ์ จุลยเสน. การพัฒนาระบบควบคุมการบังคับเลี้ยวสำหรับรถแทรกเตอร์อัตโนมัติ. *วารสารวิศวกรรมฟาร์มและเทคโนโลยีการควบคุมอัตโนมัติ*. 2562; 5(1): 1-11.
- [13] จาริณี จงปลื้มปิติ, พลเทพ เวงสูงเนิน, สาวิตรี ประภาการ, ณัฐดนัย พรรณเจริญวงศ์, พลกฤต ปูนนอก. การควบคุมจากค่าปรับตั้งที่ใช้ในการควบคุมสถานะแวดล้อม แบบอัตโนมัติไร้สายภายในโรงเรือนเปิดดอกเห็ดนางฟ้า. *วารสารวิศวกรรมฟาร์มและเทคโนโลยีการควบคุมอัตโนมัติ*. 2563; 6(1): 40-9.
- [14] Desai, SV, Balasubramanian VN, Fukatsu T., Ninomiya S, Guo W. Automatic estimation of heading date of paddy rice using deep learning. *Plant Methods*. 2019; 15(1): 76.
- [15] Abraham S, Huynh C, Vu H. Classification of Soils into Hydrologic Groups Using Machine Learning. *MDPI Data*. 2019; 5(1): 2.
- [16] Rodriguez-Galiano VF, Ghimireb B, Roganb J, Chica-Olmoa M, Rigol-Sanchez JP. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2012; 67: 93–104.
- [17] Yano IH, Alves JR, Santiago WE, Mederos BJT. Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier. *ScienceDirect IFAC-PapersOnLine*. 2016; 49(16): 415–20.
- [18] Raczko E, Zagajewski B. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. *European Journal of Remote Sensing*. 2017; 50(1): 144-54.