

## การตรวจจับโรคใบด่างในไร่มันสำปะหลังโดยใช้การสำรวจระยะไกล ด้วยอากาศยานไร้คนขับ

### Detection of Cassava Mosaic Disease (CMD) in Cassava Plantation by Using UAV Based Remote Sensing

อัครพล ไชยนา<sup>1</sup> และ ศิวา แก้วปลั่ง<sup>1\*</sup>

Akkarapon Chaiyana<sup>1</sup> and Siwa Kaewplang<sup>1\*</sup>

**บทคัดย่อ:** เกษตรกรที่ปลูกมันสำปะหลังทั่วโลกส่วนใหญ่กำลังประสบปัญหาจากการเกิดโรคใบด่าง (CMD) ทำให้ผลผลิตลดลงและจะเพิ่มปริมาณวงกว้างของโรคนี้ไปอีกเรื่อย ๆ ทำให้ผู้วิจัยตระหนักถึงความสำคัญจึงเกิดงานวิจัยขึ้นเพื่อสามารถจำแนกโรคที่เกิดจาก CMD ในลักษณะรายแปลงได้โดยทันต่อสถานการณ์การแก้ปัญหาซึ่งวิธีการสำรวจระยะไกลจากเครื่องมืออากาศยานไร้คนขับ (UAV) ร่วมการเรียนรู้ของเครื่องมือ (Machine Learning) สามารถวิเคราะห์และเฝ้าติดตามปัญหานี้ได้ โดยเลือกใช้ฟังก์ชันทางคณิตศาสตร์ 3 วิธี ได้แก่ General Linear Model (GLM), Deep Learning และ Support Vector Machine (SVM) ที่ความละเอียดจุดภาพ (GSD) 0.02 ,0.05 ,0.1 0.25 , 0.5 และ 0.7 m จากการประเมินประสิทธิภาพของแบบจำลองพบว่า overall accuracy GLM ที่ GSD 0.25 m ให้ค่าความถูกต้องมากที่สุด 91.31 % ค่าความถูกต้องของการแปลงข้อมูลเท่ากับ 0.852 overall accuracy Deep Learning ที่ GSD 0.1 m ให้ค่าความถูกต้องมากที่สุด 94.79 % ค่าความถูกต้องของการแปลงข้อมูลเท่ากับ 0.921 overall accuracy SVM ที่ GSD 0.05 m ให้ค่าความถูกต้องมากที่สุด 93.04 % ค่าความถูกต้องของการแปลงข้อมูลเท่ากับ 0.895 สรุปได้ว่าการประเมินประสิทธิภาพของแบบจำลองโดยความละเอียดจุดภาพ (GSD) ทั้ง 3 วิธีนี้ควรเลือกความละเอียดจุดภาพไม่เกิน 0.25 m ผลการวิจัยสามารถตรวจจับโรคใบด่าง (CMD) ที่เกิดในมันสำปะหลังได้โดยใช้อากาศยานไร้คนขับ (UAV) ให้ประสิทธิภาพมากที่สุด

**คำสำคัญ:** อากาศยานไร้คนขับ, โรคใบด่าง, มันสำปะหลัง, การเรียนรู้ของเครื่องมือ, การสำรวจระยะไกล

**ABSTRACT:** Most of the cassava farmers in the world are experiencing the problem of CMD, resulting in reduction of products and increasing the number of this disease, causing the researchers to realize the importance of this research. This research aims to identify diseases caused by CMD in an individual field in a manner that can keep up in times to solve the problem. The remote sensing method using unmanned aerial vehicles (UAV) combined with Tools Machine Learning is able to analyze and monitor the issue by using 3 mathematical functions; General Linear Model (GLM), Deep Learning and Support Vector Machine (SVM) at the image resolution of (GSD) 0.02, 0.05, 0.1, 0.2, 0.5, and 0.7 m According to the performance evaluation, researchers found that the overall accuracy of GLM model at the GSD of 0.25 provides the highest accuracy at 91.31% and Kappa values are calculated as 0.852, the overall Deep Learning accuracy at the GSD of 0.1 provides the highest accuracy at 94.79% and Kappa values are calculated as 0.921, the overall SVM at the GSD of 0.05 provides the highest accuracy at 93.04% and Kappa values are calculated as 0.895. In summary, 3 types of evaluation of the models' performances should not be over 0.25 m of image resolution (GSD). The result of the study found that using unmanned aerial vehicles (UAV) to detect the CMD in cassava is the most effective.

**Keywords:** UAV, Cassava Mosaic Disease, Cassava, Machine Learning, Remote Sensing

<sup>1</sup> คณะวิศวกรรมศาสตร์ มหาวิทยาลัยมหาสารคาม จังหวัดมหาสารคาม

Faculty of Engineering, Maha Sarakham University, Maha Sarakham Province

\* Corresponding author: siwakaewplang@gmail.com

## บทนำ

พืชเศรษฐกิจของประเทศไทยประกอบไปด้วย ข้าว มันสำปะหลัง อ้อย ยางพารา และปาล์ม โดยเฉพาะอย่างยิ่งมันสำปะหลัง (De Bruijn and Fresco 1989) มีการแปรรูปได้หลายด้านเช่น อาหารสัตว์ แอลกอฮอล์ ไม้อัด กระดาษ สิ่งทอ อาหารและเครื่องดื่ม ผงชูรส สารความหวาน เป็นต้น ทำให้มันสำปะหลังมีความต้องการสูงขึ้นนับตั้งแต่ปี พ.ศ.2552-2561 อัตราการเพาะปลูกมันสำปะหลังมีเนื้อที่ประมาณ 8,583,557-8,624,284 ไร่ แต่ผลผลิตที่ได้มีความผันผวน ซึ่งในปี พ.ศ.2552 มีผลผลิตประมาณ 30 ล้านตัน แต่ผลผลิตที่ได้ในปี พ.ศ.2561 ประมาณ 29.3 ล้านตัน สำนักงานเศรษฐกิจการเกษตร (2561) โดยความต้องการในปี พ.ศ.2561 มีความต้องการด้านผลผลิตประมาณ 41.0 ล้านตัน แต่ผลผลิตที่ได้มีเพียง 29.3 ล้านตัน ทำให้ผลผลิตที่ได้มีไม่เพียงพอต่อความต้องการของตลาดโดยเฉพาะความต้องการระหว่างประเทศ จีน ประเทศจีนมีความต้องการผลผลิตที่แปรรูปเป็นมันสำปะหลังเส้นถึง 99 % ของการส่งออกมันสำปะหลังทั้งหมดของประเทศไทย (ชาวนิวทรี และคณะ 2561)

ในปัจจุบันปัญญาที่พบในรูปแบบใหม่ของประเทศไทยคือโรคใบด่าง (CMD) มีรายงานจากต่างประเทศ (Legg et al., 2015; Calvert and Thresh, 2009) แถบแอฟริกา อินเดีย ศรีลังกา เวียดนาม และกัมพูชา พบการระบาดของโรคใบด่างในมันสำปะหลังทำลายผลผลิตมันสำปะหลังมากถึง 88 % ในประเทศไทยไม่เคยปรากฏการเกิดโรคใบด่างในมันสำปะหลังมาก่อน จนกระทั่งเดือนสิงหาคม 2561 ที่ผ่านมามีการตรวจพบต้นมันสำปะหลังของเกษตรกรมีลักษณะอาการคล้ายโรคใบด่างมันสำปะหลังที่ ตำบลไพรพัฒนา อำเภอภูสิงห์ จังหวัดศรีสะเกษ จำนวน 2 ต้น (นวลศรี โชตินันท์ 2562) หลังจากนั้นโรคใบด่างแพร่กระจายมากขึ้น โดยเฉพาะจังหวัดนครราชสีมาทำให้ผลผลิตเสียหายประมาณ 6,000 ไร่ และจังหวัดนครราชสีมาประกาศเป็นจังหวัดควบคุมโรค

การตรวจเดิมที่กรมวิชาการเกษตรใช้นั้นจะทำการเดินสำรวจเป็นรูปตัวยูโดยมีอัตราการใช้พื้นที่ตัวอย่างตามเกณฑ์ของกรมวิชาการเกษตรกำหนด และหากตรวจพบต้องการทำการสุ่มตรวจพื้นที่บริเวณโดยรอบรัศมี 5 กิโลเมตร ติดตามต่อเนื่องทุก ๆ

2 สัปดาห์ ทำให้เกิดความล่าช้าต่อการสำรวจ สิ้นเปลืองค่าใช้จ่ายและจำนวนแรงงาน (สำนักวิจัยพัฒนาการอารักขาพืช กรมวิชาการเกษตร 2561)

ปัจจุบันมีเทคโนโลยีการสำรวจระยะไกลเข้ามามีบทบาทสำคัญอย่างยิ่งโดยเฉพาะการสำรวจด้านการเกษตรโดยสามารถประเมินความเสียหายหรือวางแผนป้องกันภัยความเสียหายได้อย่างรวดเร็วทันต่อสถานการณ์สามารถลดระยะเวลาและค่าใช้จ่ายแรงงานสำรวจได้ การสำรวจระยะไกลที่ใช้ในการจำแนกโรคใบด่างที่เกิดจากมันสำปะหลังสามารถทำได้หลายวิธี จากรายงานทำการจำแนกโรคใบด่างโดยการนำค่าการสะท้อนแสงของต้นที่ติดโรคและไม่ติดโรคมาทำการจำแนกช่วงคลื่นที่ใช้ 531 และ 571 nm จากเครื่องมือวัด Proximate Sensing ทำการจำแนกโดยวิธี Binominal ให้พื้นที่ใต้กราฟของช่วงเริ่มติดโรค (AUC CMD) 0.92 และพื้นที่ใต้กราฟของช่วงสุดท้ายการติดโรค (AUC CMD) 0.99 (Raji et al., 2015; Raji et al., 2016) ทำการวิเคราะห์โรคใบด่างในมันสำปะหลังด้วยวิธี โดยการถ่ายภาพจากมือถือ (Image processing) ระยะใกล้ วิเคราะห์ด้วยอัลกอริทึม Deep Learning สามารถจำแนกโรคใบด่างได้ความถูกต้องโดยรวม 93 % (Ramcharan et al., 2017) การสำรวจระยะไกลโดยใช้อากาศยานไร้คนขับ (UAV) มีความนิยมมากขึ้นเนื่องจากราคาถูก ใช้งานง่ายและให้ข้อมูลภาพที่มีความละเอียดสูง ดังนั้นงานวิจัยนี้จึงใช้ UAV เพื่อประเมินความถูกต้องการจำแนกโรคใบด่างที่เกิดในมันสำปะหลัง

จากหลายรายงานการศึกษาพบว่ามีความเป็นไปได้ที่จะสามารถใช้อากาศยานไร้คนขับเพื่อจับตำแหน่งโรคใบด่างที่เกิดในมันสำปะหลังและใช้วิธีวิเคราะห์ด้วยอัลกอริทึม 3 ชนิด ได้แก่ GLM Deep Learning SVM บินถ่ายภาพที่ความสูง 50 m ซึ่งลดความละเอียดจุดภาพ (GSD) เป็น 0.02 ,0.05, 0.1, 0.25, 0.5 และ 0.7 m ที่ต่างกันโดยนำค่าการสะท้อนแสงของ CMD, มันสำปะหลัง, ดินที่ได้จากการเก็บข้อมูลทำการสุ่มข้อมูลและสร้างแบบจำลองจากข้อมูล 70 % (Training) และทดสอบแบบจำลอง 30 % (Testing) เพื่อวัดประสิทธิภาพของแบบจำลองและหาความละเอียดจุดภาพที่เหมาะสมและสร้างแผนที่การเกิดโรคใบด่าง

## วิธีการศึกษา

### พื้นที่ศึกษา

พื้นที่ศึกษางานวิจัยนี้ตั้งอยู่ที่อำเภอเสิงสาง จังหวัดนครราชสีมา พิกัด  $14^{\circ} 25' 34''$  N  $102^{\circ} 27' 38''$  E พื้นที่ทั้งหมด 1200.2 ตารางกิโลเมตร ประชากร 70,587 คน เป็นที่ราบสูง ความสูง 247 เมตรจากระดับน้ำทะเลปานกลาง อุณหภูมิเฉลี่ยรายปี 30 องศาเซลเซียส ฝนเฉลี่ยรายปี 2017.1 มม. เกษตรกรส่วนใหญ่ปลูกพืชสวนได้แก่ ข้าวโพด มันสำปะหลัง ข้าว ยางพารา เป็นต้น (Figure 1)



### อุปกรณ์และวิธีการศึกษา

เครื่องมือที่ใช้ในการศึกษาได้แก่ โดรน Phantom 3 Professional (Figure 2) เครื่อง GNSS (Figure 3)

### ลักษณะของโรคใบด่างในมันสำปะหลัง (CMD) ที่เกิดในพื้นที่ศึกษา

จากพื้นที่ศึกษาในครั้งนี้นำการศึกษาที่อำเภอเสิงสาง จังหวัดนครราชสีมาซึ่งลักษณะการแพร่ระบาดของมันสำปะหลังส่วนใหญ่เป็นการแพร่ระบาดที่เกิดจากแมลงหิวข้าวยาสูบเนื่องจากในพื้นที่ศึกษาพบแมลงหิวข้าวยาสูบค่อนข้างมาก




Figure 1 Study area at Soeng Sang District, Nakhon Ratchasima Province



Figure 2 Phantom 3 Professional



Figure 3 GNSS Station

ทำให้การแพร่ระบาดนั้นเป็นวงกว้างเกือบทั้งแปลง และอายุของแปลงที่ศึกษามีอายุการเพาะปลูก ประมาณ 6-7 เดือนและลำต้นสูงประมาณ 50-160 เซนติเมตรลักษณะมันสำปะหลังที่ติดโรคใบต่างนั้น



Figure 4 Sample characteristics of CMD

มีลักษณะอาการใบต่างเหลืองต้นแคระแกร็น ใบเสีย รูปทรง ลดรูป ยอดที่แตกใหม่แสดงอาการต่างเหลือง (สำนักวิจัยพัฒนาการอารักขาพืช กรมวิชาการเกษตร, 2561) (Figure 4 และ Figure 5)



Figure 5 Sample characteristics of CMD

### วิธีการศึกษาและการจำแนกข้อมูล

การจำแนกข้อมูลระหว่างมันสำปะหลังที่ติดโรคใบต่าง มันสำปะหลัง และดินสามารถเลือกใช้วิธีการจำแนกด้วยอัลกอริทึม 3 แบบ ได้แก่ General Linear Model (GLM), Deep Learning และ Support Vector Machine (SVM) ทำการแบ่งข้อมูลของตำแหน่งโดยแบ่งออกเป็น 2 ชุดข้อมูลเพื่อทำการสร้างแบบจำลองและทดสอบแบบจำลอง จากค่าการสะท้อนแสงของตำแหน่งที่ทำการเก็บข้อมูล (Split Test) ข้อมูลของการสร้างแบบจำลอง จะทำการสุ่มตัวอย่างเพื่อสร้างแบบจำลอง 70 % และข้อมูลที่ใช้ทดสอบแบบจำลอง 30 % เพื่อวัดประสิทธิภาพของแบบจำลอง (Confusion Matrix) ที่เหมาะสมที่สุด และทำการทดสอบความถูกต้องของการแปลข้อมูลด้วยวิธี (Kappa Coefficient)

### การรวบรวมข้อมูล

#### ลักษณะภาพถ่าย

จากงานนี้ใช้เครื่องมืออากาศยานไร้คนขับ (UAV) Phantom 3 Professional มีคุณสมบัติสามารถต้านแรงลมและมีความเสถียรของการทรงตัว น้ำหนักของตัวลำประมาณ 1.3 กิโลกรัม รวมน้ำหนักบรรทุก 0.75 กิโลกรัม สามารถในการใช้แบตเตอรี่ ประมาณ 23 นาที ความเร็วสูงสุด 16

เมตร/วินาที ระยะควบคุม 6 กิโลเมตร กล้องที่ใช้เป็นกล้อง RGB Sony EXMOR มาตรฐานและมีความยาวโฟกัส 3.61 มม.ความละเอียด 4 K (FC300X) ใช้ GPS ในการควบคุมโดย GPS/GLONASS (Tien Bui et al., 2018)

#### กระบวนการทำแผนที่

ทำการวางแผนการบินผ่านทาง Application Pix4D โดยตั้งค่าที่ความสูง 50 เมตร Overlap 80% และ Side lap 70% ในการทำแผนที่และสร้างจุดควบคุมภาพ 4 จุด ครอบคลุมพื้นที่ศึกษา ลักษณะการบินเป็นแบบ GRID หลังจากทำการบินถ่ายภาพเสร็จแล้วทำการรวมภาพถ่ายและทำการปรับแก้เชิงตำแหน่งด้วยพิกัดที่รับสัญญาณจากเครื่อง GNSS โดยขนาดจุดภาพที่เลือกใช้นั้นมีขนาด 0.02 ,0.05 ,0.1 0.25 , 0.5 และ 0.7 m

#### การเก็บข้อมูล

การเก็บตำแหน่งของข้อมูลแบ่งออกเป็น 3 ชุด ได้แก่ ตำแหน่งที่เกิดโรคใบต่าง มันสำปะหลังที่ยังไม่ติดโรค และตำแหน่งพื้นดินโดยการเก็บตำแหน่งของข้อมูลนั้นเก็บทั้งหมด 600 จุด ชุดละ 200 จุด (Figure 6,7)





Figure 6 Creating Ground Control Points (GCP) Figure 7 Collection between CMD and non CMD

**แผนภาพการปฏิบัติงาน**

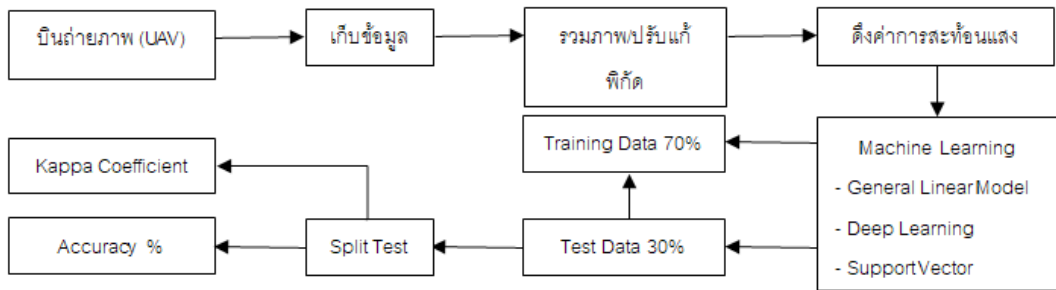


Figure 8 Action plan

**ผลการทดลอง**

ผลการจำแนกด้วยวิธี General Linear Model (GLM), Deep Learning และ Support Vector Machine (SVM) ให้ค่าความถูกต้องรวมเท่ากับ General Linear Model (GLM) ที่ความละเอียดจุดภาพ (GSD) 0.02, 0.05, 0.1, 0.25, 0.5 และ 0.7 m เท่ากับ 88.89, 85.71, 91.49, 85.71, 75.0 และ 75.00% ตามลำดับ Deep Learning ที่ความละเอียดจุดภาพ (GSD) 0.02, 0.05, 0.1, 0.25, 0.5 และ 0.7

m เท่ากับ 91.07, 89.66, 94.34, 86.21, 78.00 และ 74.19% ตามลำดับ Support Vector Machine (SVM) ที่ความละเอียดจุดภาพ (GSD) 0.02, 0.05, 0.1, 0.25, 0.5 m และ 0.7 m เท่ากับ 87.50, 90.79, 94.0, 90.20, 76.92 และ 83.67% ตามลำดับ โดยมีความถูกต้องของการแปลข้อมูล (Kappa coefficient) แต่ละชนิดอัลกอริทึม เท่ากับ 0.852, 0.912 และ 0.895 ตามลำดับ โดยรายละเอียดผลการจำแนกแสดงใน (Figure 9, 10 และ 11)

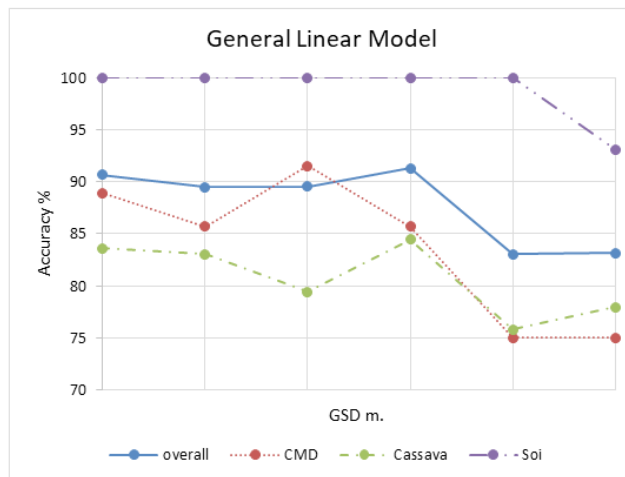


Figure 9 The illustration shows data with general linear models

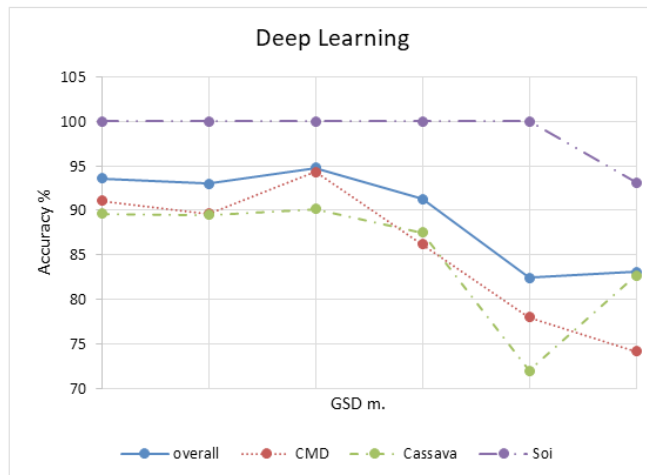


Figure 10 The illustration shows data with Deep learning




Figure 11 The illustration shows data with Support Vector Machine

## แผนที่การเกิดโรคใบด่าง (Figure 12)

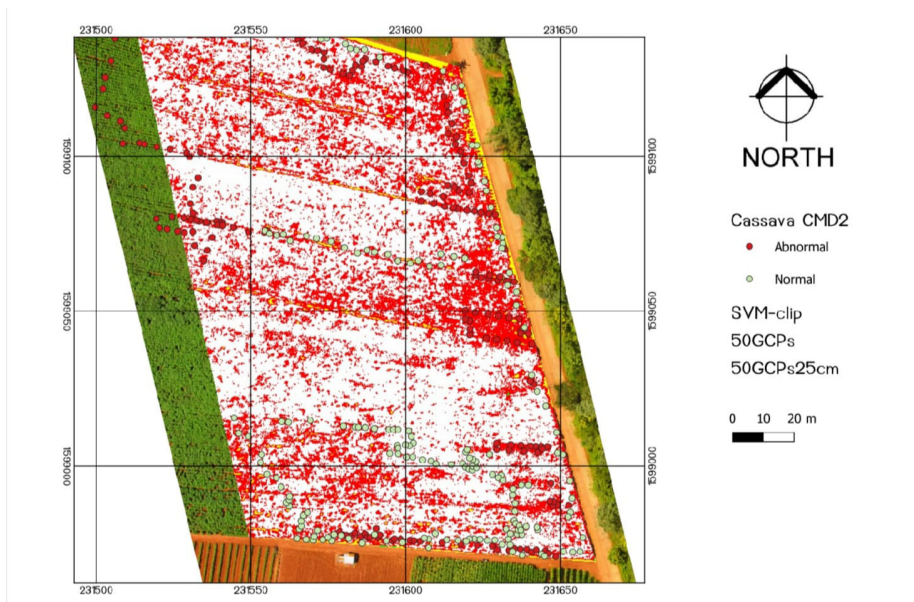


Figure 12 Map showing the classification of CMD

## วิจารณ์

จากการบินถ่ายภาพด้วยอากาศยานไร้คนขับ เพื่อจำแนกโรคใบด่างที่ความสูงบิน 50 m ที่ความละเอียดจุดภาพ (GSD) 0.02, 0.05, 0.1, 0.25, 0.5 และ 0.7 m โดยประเมินประสิทธิภาพการจำแนกโดยรวมด้วยอัลกอริทึม Deep Learning ที่ GSD 0.1 ให้ค่าความถูกต้องโดยรวมมากที่สุด 94.79 % ค่าความถูกต้องของการแปลข้อมูลเท่ากับ 0.921 จากการนำค่าการสะท้อนแสงมาวิเคราะห์ด้วยวิธี Remote Sensing ซึ่งสอดคล้องกับรายงานการวิจัยของ (Raji et al., 2015; Raji et al., 2016; Ramcharan et al., 2017) แต่เป็นวิธีการจำแนกด้วยรูปภาพ (Image Processing) เท่านั้น ซึ่งงานวิจัยนี้เป็นงานวิจัยแรกที่ใช้ค่าการสะท้อนแสงจากอากาศยานไร้คนขับมาจำแนกโรคใบด่างในมันสำปะหลังจากผลการวิเคราะห์ข้อมูลสรุปได้ว่าความถูกต้องโดยรวมของการวัดค่าสะท้อนแสงของดินมันสำปะหลังจะแปรผันตรงตามความละเอียดของจุดภาพและวัตถุเนื่องจากภาพที่ได้จากอากาศยานไร้คนขับขนาดของจุดภาพอาจจะรวมกับวัตถุชนิดอื่นทำให้การกลืนของการสะท้อนไม่ตรงตำแหน่งที่ศึกษาการวิเคราะห์ซึ่งเกิดความคลาดเคลื่อน

## สรุป

จากผลการศึกษาแสดงให้เห็นว่าค่าการสะท้อนแสงจากข้อมูล RGB จากอากาศยานไร้คนขับ (UAV) สามารถนำมาใช้ตรวจจำแนกโรคใบด่างในมันสำปะหลังได้ดี โดยจากผลการศึกษาพบว่าการจำแนกโดยใช้วิธี General Linear Model (GLM), Deep Learning และ Support Vector Machine (SVM) ที่ความละเอียดจุดภาพ (GSD) 0.02, 0.05, 0.1, 0.25, 0.5 และ 0.7 m จากการประเมินประสิทธิภาพของแบบจำลองพบว่า overall accuracy GLM ที่ GSD 0.25 m ให้ค่าความถูกต้องมากที่สุด 91.31 % ค่าความถูกต้องของการแปลข้อมูลเท่ากับ 0.852 overall accuracy Deep Learning ที่ GSD 0.1 m ให้ค่าความถูกต้องมากที่สุด 94.79 % ค่าความถูกต้องของการแปลข้อมูลเท่ากับ 0.921 overall accuracy SVM ที่ GSD 0.05 m ให้ค่าความถูกต้องมากที่สุด 93.04 % ค่าความถูกต้องของการแปลข้อมูลเท่ากับ 0.895 สรุปได้ว่าการประเมินประสิทธิภาพของแบบจำลองโดยความละเอียดจุดภาพ (GSD) ทั้ง 3 วิธีนี้ควรเลือกความละเอียดจุดภาพไม่เกิน 0.25 m ผลการวิจัยสามารถตรวจจำแนกโรคใบด่าง (CMD) ที่เกิดในมันสำปะหลังได้โดยใช้อากาศยานไร้คนขับ

ให้ประสิทธิภาพมากที่สุด จากผลการศึกษาค้นคว้านี้เป็นเพียงการศึกษาและทดลองเพียง 1 แปลงตัวอย่างเท่านั้นหากเพิ่มจำนวนแปลงที่ใช้เก็บตัวอย่างที่หลายช่วงอายุของมันสำปะหลังอาจจะให้ผลที่มีความคลาดเคลื่อนและหากต้องการจำแนกเพื่อระบุถึงตำแหน่งโรคใบด่างที่ให้ความแม่นยำสูงต้องใช้กล้องที่มีช่วงคลื่นในการตรวจวัดแบบ Hyperspectral (Ishida et al., 2018) จะสามารถทำให้ผลการจำแนกสามารถเพิ่มประสิทธิภาพได้มากขึ้น ในช่วงคลื่นที่เท่ากันภาพ Hyperspectral จะมีช่วงคลื่น 100-200 ช่วงคลื่น ในขณะที่ภาพ Multispectral จะมีช่วงคลื่น 5-10 ช่วงคลื่นในขนาดความกว้างของช่วงคลื่นเดียวกันเนื่องจากธรรมชาติของพืชและโรคพืชแต่ละชนิดจะมีการสะท้อน ดูดซับ กระจาย แสงไม่เหมือนกันทำให้ Hyperspectral จำแนกได้ละเอียดกว่า

### เอกสารอ้างอิง

- ชาญวิทย์ เรืองชัยวิเศษ, วชิรินทร์ สุทธิชัย, เสาวลักษณ์ โภคสถิตติอัมพร, ทรงศักดิ์ จีระสมบัติ. (2561). แผนยุทธศาสตร์การค้ำประกันสำปะหลังเส้นของไทยไปยังสาธารณรัฐประชาชนจีน. *ช่อพะยอม* ปี 29 ฉบับที่ 1: 27-36
- นวลศรี ไซตินันท์. (2562) โรคใบด่างมันสำปะหลังมหันตภัยที่ชาวไร่มันต้องช่วยกันเฝ้าระวัง. *สืบค้นเมื่อ 8 ต.ค. 2562*, จาก [https://www.technologychaoban.com/agricultural-technology/article\\_103177](https://www.technologychaoban.com/agricultural-technology/article_103177)
- สำนักวิจัยพัฒนาการอารักขาพืช. (2561). คู่มือการสำรวจและเฝ้าระวังโรคใบด่างของมันสำปะหลัง. *กรมวิชาการเกษตร*. (4), 1-12
- Calvert, L. A., & Thresh, J. M. (2009). The viruses and virus diseases of cassava. In *Cassava: biology, production and utilization*. <https://doi.org/10.1079/9780851995243.0237>
- De Bruijn, G. H., & Fresco, L. O. (1989). The importance of cassava in world food production. *Netherlands Journal of Agricultural Science*.
- Ishida, T., Kurihara, J., Viray, F. A., Namuco, S. B., Paringit, E. C., Perez, G. J., ... Marciano, J. J. (2018). A novel approach for vegetation classification using UAV-based hyperspectral imaging. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2017.11.027>
- Legg, J. P., Lava Kumar, P., Makesh Kumar, T., Tripathi, L., Ferguson, M., Kanju, E., ... Cuellar, W. (2015). Cassava virus diseases: Biology, epidemiology, and management. In *Advances in Virus Research*. <https://doi.org/10.1016/bs.avir.2014.10.001>
- Raji, S. N., Subhash, N., Ravi, V., Saravanan, R., Mohanan, C. N., Makesh Kumar, T., & Nita, S. (2016). Detection and Classification of Mosaic Virus Disease in Cassava Plants by Proximal Sensing of Photochemical Reflectance Index. *Journal of the Indian Society of Remote Sensing*. <https://doi.org/10.1007/s12524-016-0565-6>
- Raji, S. N., Subhash, N., Ravi, V., Saravanan, R., Mohanan, C. N., Nita, S., & Kumar, T. M. (2015). Detection of mosaic virus disease in cassava plants by sunlight-induced fluorescence imaging: a pilot study for proximal sensing. *International Journal of Remote Sensing*. <https://doi.org/10.1080/01431161.2015.1049382>
- Ramcharan, A., Baranowski, K., McCloskey, P., Ahmed, B., Legg, J., & Hughes, D. P. (2017). Deep learning for image-based cassava disease detection. *Frontiers in Plant Science*. <https://doi.org/10.3389/fpls.2017.01852>
- Tien Bui, D., Long, N. Q., Bui, X.-N., Nguyen, V.-N., Van Pham, C., Van Le, C., ... Kristoffersen, B. (2018). Lightweight Unmanned Aerial Vehicle and Structure-from-Motion Photogrammetry for Generating Digital Surface Model for Open-Pit Coal Mine Area and Its Accuracy Assessment. In *Advances and Applications in Geospatial Technology and Earth Resources*. [https://doi.org/10.1007/978-3-319-68240-2\\_2](https://doi.org/10.1007/978-3-319-68240-2_2)