

การคาดการณ์ผลผลิตมันสำปะหลังด้วยภาพถ่ายจากอากาศยานไร้คนขับ
และการเรียนรู้เชิงลึก



นายอนาวิต เพ็ชรบุรณิล

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมเครื่องกลและระบบกระบวนการ
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2566

CASSAVA YIELD ESTIMATION USING UAV-BASED IMAGERY
AND DEEP LEARNING



ANAWIN PECHBOORANIN

A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Mechanical and
Process System Engineering
Suranaree University of Technology
Academic Year 2023

การคาดการณ์ผลผลิตมันสำปะหลังด้วยภาพถ่ายจากอากาศยานไร้คนขับ
และการเรียนรู้เชิงลึก

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์

(รศ. ดร.จิระพล ศรีเสรีวงษ์)

ประธานกรรมการ

(ผศ. ดร.สุรเดช ตัญตรัยรัตน์)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)

(ผศ. ดร.ธีทัต ดลวิชัย)

กรรมการ

(ผศ. ดร.ฐิติพร มะชิโกวา)

กรรมการ

(อ. ดร.รงชาติ เกิดผล)

กรรมการ

(รศ. ดร.ยุพาพร รักสกุลวัฒน์)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ

(รศ. ดร.พรศิริ จงกล)

รักษาการแทนคณบดีสำนักวิชาวิศวกรรมศาสตร์

อนาวิล เพ็ชรบุรณิล : การคาดการณ์ผลผลิตมันสำปะหลังด้วยภาพถ่ายจากอากาศยานไร้
คนขับและการเรียนรู้เชิงลึก (CASSAVA YIELD ESTIMATION USING UAV-BASED
IMAGERY AND DEEP LEARNING)

อาจารย์ที่ปรึกษา : ผู้ช่วยศาสตราจารย์ ดร.สุรเดช ตัญตรัยรัตน์, 306 หน้า

คำสำคัญ: มันสำปะหลัง/อากาศยานไร้คนขับ/ดัชนีพืชพรรณ/การเรียนรู้เชิงลึก

มันสำปะหลังเป็นพืชเศรษฐกิจที่สำคัญชนิดหนึ่งของประเทศไทยมาอย่างยาวนาน ไม่เพียงแต่เป็นแหล่งอาหารที่อุดมไปด้วยคาร์โบไฮเดรตเท่านั้น ผลผลิตมันสำปะหลังและผลิตภัณฑ์ที่ได้จากการแปรรูปมันสำปะหลังยังมีบทบาทสำคัญในอุตสาหกรรมหลายประเภท ด้วยมูลค่าทางเศรษฐกิจที่สำคัญผลผลิตมันสำปะหลังจึงต้องได้รับการคาดการณ์ปริมาณผลผลิตที่แม่นยำ อย่างไรก็ตามการคาดการณ์ผลผลิตพืชผลในปัจจุบันยังคงอาศัยประสบการณ์ของเกษตรกรเพียงอย่างเดียวและอาจเกิดความผิดพลาดได้สูง การพัฒนาเทคโนโลยีปัญญาประดิษฐ์ (AI) ในปัจจุบันจึงถูกนำมาใช้เป็นวิธีการหนึ่งสำหรับการทำนายผลผลิตที่มีความแม่นยำมากกว่าวิธีการแบบเดิม งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อสร้างแบบจำลองที่มีความเหมาะสมที่สุดสำหรับการทำนายปริมาณผลผลิตมันสำปะหลังพันธุ์ระยอง 72 ที่ปลูกด้วยระบบน้ำหยด

การศึกษานี้ใช้ค่าดัชนีพืชพรรณซึ่งเป็นค่าที่บ่งบอกถึงความอุดมสมบูรณ์และการเจริญเติบโตของพืช ได้แก่ ExG, GRVI และ NDVI จากกล้องถ่ายภาพ RGB และกล้องถ่ายภาพแบบหลายช่วงคลื่นที่ติดตั้งบนอากาศยานไร้คนขับ (UAV) เพื่อนำมาใช้เป็นข้อมูลในการทำนายข้อมูลปริมาณผลผลิตมันสำปะหลัง 2 ชนิด คือน้ำหนักผลผลิต (กิโลกรัม/ตารางเมตร) และปริมาณแป้ง (%) โดยใช้แบบจำลองการถดถอยเชิงเส้นและโครงข่ายประสาทเทียม แบบจำลองการทำนายที่ใช้ในการศึกษาจะถูกประเมินความแม่นยำด้วยค่าสัมประสิทธิ์แสดงการตัดสินใจ (R^2) และประเมินความผิดพลาดโดยใช้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) และค่ารากที่สองความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) เป็นค่าค่าฟังก์ชันความสูญเสีย จากผลการวิเคราะห์สมการถดถอยและค่าสหสัมพันธ์แสดงให้เห็นว่าดัชนี NDVI มีความเหมาะสมในการทำนายผลผลิตมันสำปะหลังมากกว่าดัชนีอื่น สำหรับการทำนายน้ำหนักผลผลิตแบบจำลองโครงข่ายประสาทเทียมที่มี 7 ชั้นซ่อน โดยใช้อัลกอริทึม Levenberg-Marquardt (LM) มีประสิทธิภาพสูงสุด และมีความซับซ้อนของแบบจำลองเหมาะสำหรับการทำนายน้ำหนักมันสำปะหลัง โดยมีค่า MSE ต่ำสุดและค่า R^2 สูงสุดคือ 0.0098 และ 0.8241 ตามลำดับ อีกทั้งยังมีความคลาดเคลื่อนในการทำนายน้ำหนักมันสำปะหลังที่ประมาณ 0.01 กิโลกรัม/ตารางเมตร

ในทางกลับกันผลการทำนายปริมาณแป้งของแบบจำลองให้ค่าความแม่นยำที่ต่ำกว่าที่กำหนดไว้ และมีค่าฟังก์ชันความสูญเสียที่สูง โดยแบบจำลองที่ใช้อัลกอริทึม BR มีประสิทธิภาพดีที่สุดเมื่อประเมินจากการใช้ข้อมูลทั้งหมดโดยมีค่า R^2 เท่ากับ 0.7242 มีความผิดพลาดในการทำนายปริมาณแป้งที่ 1.446% ขณะที่อัลกอริทึม SCG มีประสิทธิภาพดีที่สุดกับข้อมูลชุดทดสอบมีค่า R^2 เท่ากับ 0.7885 และความผิดพลาดในการทำนายปริมาณแป้งที่ 0.9406% ทั้งนี้เนื่องจากอาจมีปัจจัยด้านสิ่งแวดล้อมอื่นที่มีผลต่อปริมาณแป้งภายในหัวมันสำปะหลัง

วิธีการทำนายผลผลิตมันสำปะหลังที่พัฒนาขึ้นในการศึกษานี้ไม่เพียงแต่แสดงให้เห็นถึงความสัมพันธ์ระหว่างค่าดัชนีพืชพรรณกับปริมาณผลผลิตเท่านั้น แต่ยังเน้นย้ำถึงแนวโน้มที่เป็นไปได้ของการใช้แบบจำลองการเรียนรู้เชิงลึกในการทำนายปริมาณผลผลิตมันสำปะหลัง หรือผลผลิตทางการเกษตรอื่นที่แม่นยำ สามารถช่วยในการตัดสินใจสำหรับภาคการเกษตร และภาคอุตสาหกรรม



ANAWIN PECHBOORANIN : CASSAVA YIELD ESTIMATION USING UAV-BASED
IMAGERY AND DEEP LEARNING.

THESIS ADVISOR : ASST. PROF. SURADET TANTRIRATN, Ph.D., 306 PP.

Keywords: Cassava/Unmanned Aerial Vehicle/Vegetation Index/Deep Learning

Cassava has long been one of the most important economic crops in Thailand. Not only does it serve as a good source of carbohydrates, cassava derivatives and byproducts play a major role in many industrial processes. With its significant economic value, cassava yield must be closely monitored and accurately predicted. While crop yield forecast in the past relied solely on farmer experience and can be highly erroneous, the recent emergence of artificial intelligence (AI) has brought about novel yield prediction techniques that are more accurate than ever before. The objective of this study was to develop prediction models for the yield of cassava cv. Rayong 72 under drip irrigation system.

In this study, Vegetation indices such as ExG, GRVI and NDVI from RGB and multispectral sensors collected by unmanned aerial vehicles (UAV) are used to anticipate cassava yields included yield weight (kg/m^2) and percent starch (%) using linear regression, artificial neural network (ANN) and deep neural network (DNN) models. The optimal model and parameters for yield prediction are determined based on the values of coefficient of determination (R^2) mean squared error (MSE) and root mean squared error (RMSE). The regression and correlation results show that NDVI was suitable for predict cassava yield than another index. For predict yield weight, the 7-hidden-layer DNN model with Levenberg-Marquardt (LM) algorithm has the highest efficiency, and the complexity of the model was suitable for predicting cassava yield. According to the yield prediction analysis, the DNN model outperformed other models, with the lowest MSE value and the highest R^2 value of 0.0098 and 0.8241, respectively. There is also an error in predicting the weight of cassava at approximately $0.01 \text{ kg}/\text{m}^2$.

On the other hand, the model's percent starch prediction results gave lower accuracy values than expected and has a high loss function value. The model using the BR algorithm had the best performance when evaluated using all data with an R^2 value of 0.7242 and a prediction error of 1.446%, while the SCG algorithm had the best performance. With the test set data, there was an R^2 value of 0.7885 and an error in predicting the percent starch of 0.9406%. This is because there may be other environmental factors that affect the percent starch within the cassava roots.

The cassava yield prediction method developed in this study not only shows the relationship between the vegetation index and the yield prediction. However, it also emphasizes the potential trend of employing deep learning models to predict cassava yields, which might support industrial and agricultural decision-making.



School of Mechanical Engineering
Academic Year 2023

Student's Signature.....
Advisor's Signature..... สุรเดช คุ้มทรัพย์

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จด้วย ข้าพเจ้าขอขอบพระคุณอาจารย์ที่ปรึกษาวิทยานิพนธ์ ผู้ช่วยศาสตราจารย์ ดร.สุรเดช ตัญญูรัตน ที่ได้กรุณาแนะนำและช่วยเหลืออย่างดียิ่งในด้านวิชาการ และด้านการดำเนินการวิจัย ตลอดจนการสนับสนุนค่าใช้จ่ายต่าง ๆ ในการวิจัย

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.อัฐพล อริยฤทธิ์ และอาจารย์ ดร.อรลักษณ์ พิชิตกุล คณาจารย์สาขาวิชาวิศวกรรมเครื่องกล สำนักวิชาวิศวกรรมศาสตร์ ที่ให้คำแนะนำในการส่งบทความทางวิชาการ และตรวจแก้ผลงานทางวิชาการ เพื่อให้ข้าพเจ้าสำเร็จการศึกษาได้

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.ฐิติพร มะณีโกวา และเจ้าหน้าที่สาขาวิชาเทคโนโลยีการผลิตพืช สำนักวิชาเทคโนโลยีการเกษตร ที่ให้การสนับสนุนความรู้ทางด้านการเกษตร สถานที่และวัสดุอุปกรณ์ในการเก็บข้อมูลแปลงตัวอย่างในงานวิจัย

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.พันทิพย์ ปิยะทัศนานนท์ สาขาวิชาภูมิสารสนเทศ สำนักวิชาวิทยาศาสตร์ และคุณชิงชัย หุมห่อง จากบริษัท Mapedia จำกัด ที่ให้คำแนะนำด้านเทคโนโลยีภูมิสารสนเทศ การทำแผนที่ภาพถ่ายทางอากาศ และการใช้งานซอฟต์แวร์

ขอขอบพระคุณ คุณรัชพล พรชีโวติ คุณดลยฤทธิ์ ชาภิรม คุณดนัย เบอร์เด็น และห้องปฏิบัติการ Autonomous control and system engineering laboratory (ACSE) อาคารเครื่องมือ 5 และอาคารเครื่องมือ 11 ที่ให้การสนับสนุนการใช้งานกล้องถ่ายภาพหลายช่วงคลื่นรุ่น Parrot SEQUOIA ตลอดจนให้การช่วยเหลือและแนะนำการใช้งานอากาศยานไร้คนขับ

ขอขอบคุณ โครงการพัฒนาวิสาหกิจเริ่มต้นด้านการเกษตรที่ประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ (AgTechAI) โดยสมาคมปัญญาประดิษฐ์ประเทศไทย และสำนักงานนวัตกรรมแห่งชาติ (องค์การมหาชน) ที่ให้การสนับสนุนงบประมาณ และขอขอบคุณทีม CERES ที่ช่วยให้โครงการนี้ผ่านการคัดเลือก และได้รับการสนับสนุนการดำเนินงานวิจัยนี้ไปต่อยอดในภาคธุรกิจ

ขอขอบคุณ คุณกรรณามิตร แสนสุริวงศ์ คุณวิภาดา โบราณสาร คุณวงศธร อ่างเข้ม คุณสิริภรณ์ สากลาง คุณวิไลลักษณ์ วรรณะ คุณปิตินา หงษ์ทอง คุณสรธร นพคุณโพธิ์สว่าง คุณสุชิรญาณ กล้วยชัยภูมิ และท่านอื่น ๆ ที่ให้ความช่วยเหลือในด้านงานวิจัย ด้านกำลังใจ และให้ความช่วยเหลือข้าพเจ้าตลอดช่วงเวลาที่กำลังศึกษา

ท้ายนี้ ขอกราบขอบพระคุณ ครอบครัว บิดา มารดา ที่ให้การอบรมเลี้ยงดู ส่งเสริมการศึกษา เป็นอย่างดี และเป็นกำลังใจให้ข้าพเจ้าเสมอมาตลอดจนสำเร็จการศึกษา

อนาวิล เพ็ชรบุรณิล

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ค
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฎ
สารบัญรูป.....	ฏ
คำอธิบายสัญลักษณ์และคำย่อ	ถ
บทที่	
1 บทนำ.....	1
1.1 ความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์.....	7
1.3 ขอบเขต.....	7
1.4 ประโยชน์ที่คาดว่าจะได้รับ	8
2 ปรัชญ์วรรณกรรมและงานที่เกี่ยวข้อง.....	9
2.1 มันทำปะหลัง	9
2.1.1 ประวัติความเป็นมาของมันทำปะหลัง	9
2.1.2 การปรับตัวต่อสภาพแวดล้อมของมันทำปะหลัง	13
2.1.3 พันธุ์มันทำปะหลัง	14
2.1.4 การเจริญเติบโตของมันทำปะหลัง	16
2.1.5 การปลูกและอารักขาพืช	16
2.1.6 การเก็บเกี่ยวมันทำปะหลัง	20
2.1.7 การวัดปริมาณแป้งในหัวมันทำปะหลังสด.....	20
2.2 ทฤษฎีการสุมัดภายในแปลง.....	21
2.2.1 วิธีการสุมัดตัวอย่างพืช	22

สารบัญ (ต่อ)

หน้า

2.2.2	วิธีการเก็บตัวอย่างดิน.....	22
2.2.3	การสู่มอย่างง่าย.....	24
2.3	เทคโนโลยีภูมิสารสนเทศ.....	24
2.3.1	ระบบสารสนเทศภูมิศาสตร์.....	25
2.3.2	ระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม.....	29
2.3.3	การรับรู้ระยะไกล.....	30
2.3.4	ระบบอากาศยานไร้คนขับ.....	34
2.3.5	การสำรวจด้วยอากาศยานไร้คนขับ.....	35
2.3.6	การประมวลผลภาพ.....	41
2.3.7	ดัชนีพืชพรรณ.....	44
2.4	ปัญญาประดิษฐ์.....	47
2.4.1	นิยามของปัญญาประดิษฐ์.....	47
2.4.2	การเรียนรู้ของเครื่อง.....	49
2.4.3	เครื่องมือสำหรับการเรียนรู้ของเครื่อง.....	52
2.4.4	ข้อมูลและการเตรียมข้อมูล.....	54
2.4.5	การแบ่งประเภทการเรียนรู้ของเครื่อง.....	57
2.4.6	การถดถอยเชิงเส้น.....	58
2.4.7	โครงข่ายประสาทเทียมและการเรียนรู้เชิงลึก.....	60
2.4.8	การประเมินประสิทธิภาพของแบบจำลอง.....	65
2.4.9	การปรับปรุงประสิทธิภาพของแบบจำลอง.....	70
2.5	งานวิจัยที่เกี่ยวข้อง.....	73
3	วิธีดำเนินการวิจัย.....	78
3.1	ขั้นตอนการศึกษาวิจัย.....	78
3.1.1	ศึกษาวิธีการทำนายผลผลิตด้วยภาพถ่ายจาก อากาศยานไร้คนขับ.....	78
3.1.2	เก็บข้อมูลในแปลงมันสำปะหลังตัวอย่าง.....	78
3.1.3	การประมวลผลข้อมูลภาพ.....	78

สารบัญ (ต่อ)

หน้า

3.1.4	การเตรียมชุดข้อมูลสำหรับแบบจำลอง	78
3.1.5	การเลือกค่าดัชนีพืชพรรณที่ใช้ในการทำนายผลผลิตมันสำปะหลัง	78
3.1.6	การสร้างแบบจำลองเพื่อทำนายน้ำหนักและปริมาณแป้งมันสำปะหลัง	79
3.1.7	วิเคราะห์สรุปผล และจัดทำเล่มรายงาน	79
3.2	พื้นที่ศึกษาวิจัย	80
3.3	เครื่องมือและอุปกรณ์ในการศึกษาวิจัย	81
3.3.1	เครื่องมือที่ใช้ในการศึกษาวิจัย	81
3.3.2	ซอฟต์แวร์ที่ใช้ในการศึกษาวิจัย	83
3.4	การเก็บข้อมูลภาพถ่ายด้วยอากาศยานไร้คนขับ	84
3.4.1	การวางแผนการบิน	84
3.4.2	การถ่ายภาพด้วยกล้องถ่ายภาพแบบหลายช่วงคลื่น	85
3.4.3	ความถี่ในการเก็บข้อมูลภาพถ่าย	87
3.5	การเก็บข้อมูลปริมาณผลผลิต	88
3.6	การประมวลผลข้อมูลภาพ	90
3.6.1	ขั้นตอน Initial processing	90
3.6.2	ขั้นตอน Point cloud and Mesh	91
3.6.3	ขั้นตอน DSM, Orth-mosaic and Index	91
3.7	การคำนวณดัชนีพืชพรรณ	93
3.8	การเตรียมชุดข้อมูล การออกแบบโครงสร้างของแบบจำลอง และการประเมินประสิทธิภาพของแบบจำลอง	94
3.8.1	การเตรียมชุดข้อมูล	94
3.8.2	การเลือกใช้ค่าดัชนีพืชพรรณ	95
3.8.3	การเตรียมชุดข้อมูล และออกแบบโครงสร้างของแบบจำลอง	95
3.8.4	การประเมินประสิทธิภาพของแบบจำลอง	97
4	การวิเคราะห์การถดถอยและสหสัมพันธ์ระหว่างดัชนีพืชพรรณกับ ปริมาณผลผลิตมันสำปะหลัง	98
4.1	การวิเคราะห์สหสัมพันธ์	98

สารบัญ (ต่อ)

หน้า

4.2	การวิเคราะห์การถดถอย	99
4.3	ผลและอภิปรายการศึกษา	100
4.4	สรุปผลการศึกษา.....	105
5	การสร้างแบบจำลองการทำนายน้ำหนักของหัวมันสำปะหลังสด	
	ด้วยการเรียนรู้เชิงลึก	106
5.1	การสร้างแบบจำลองด้วยการเขียนโปรแกรมภาษาไพธอน	106
5.1.1	ผลการเปลี่ยนแปลงจำนวนโหนด	107
5.1.2	ผลการเปลี่ยนแปลงจำนวนชั้นซ่อน	109
5.1.3	ผลการเพิ่มประสิทธิภาพของแบบจำลอง.....	112
5.1.4	สรุปผลการศึกษา.....	115
5.2	การสร้างแบบจำลองโดยใช้ซอฟต์แวร์ MATLAB.....	116
5.2.1	ผลการเปลี่ยนแปลงชนิดอัลกอริทึมของแบบจำลอง	116
5.2.2	ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง.....	118
5.3	ผลการทำนายน้ำหนักมันสำปะหลังจากแบบจำลอง.....	124
5.4	สรุปผลการวิจัย.....	125
6	การสร้างแบบจำลองการทำนายปริมาณแป้งในหัวมันสำปะหลังสด.....	126
6.1	การสร้างแบบจำลองด้วยการเขียนโปรแกรมภาษาไพธอน	126
6.1.1	ผลการเปลี่ยนแปลงจำนวนโหนดของแบบจำลอง.....	127
6.1.2	ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง.....	129
6.1.3	ผลการเพิ่มประสิทธิภาพของแบบจำลอง.....	131
6.1.4	สรุปผลการศึกษา.....	133
6.2	การสร้างแบบจำลองโดยใช้ซอฟต์แวร์ MATLAB.....	133
6.2.1	ผลการเปลี่ยนแปลงชนิดอัลกอริทึมของแบบจำลอง	133
6.2.2	ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง.....	135
6.3	ผลการทำนายปริมาณแป้งจากแบบจำลอง	141
6.4	สรุปผลการวิจัย.....	142
7	สรุปผลการวิจัย และข้อเสนอแนะ.....	144

สารบัญ (ต่อ)

	หน้า
7.1 สรุปผลการวิจัย.....	144
7.2 ข้อเสนอแนะ.....	146
รายการอ้างอิง.....	148
ภาคผนวก	
ภาคผนวก ก อภิธานศัพท์.....	157
ภาคผนวก ข การใช้งานซอฟต์แวร์ Pix4D และกล้องถ่ายภาพหลายช่วงคลื่น.....	161
ภาคผนวก ค ตัวอย่างรายงานการประมวลผล	184
ภาคผนวก ง การคำนวณดัชนีพืชพรรณด้วยซอฟต์แวร์ QGIS	200
ภาคผนวก จ ตารางชุดข้อมูลในงานวิจัย.....	213
ภาคผนวก ฉ การเขียนโปรแกรมภาษาไพธอนในงานวิจัย.....	232
ภาคผนวก ช การใช้งานซอฟต์แวร์ MATLAB ในงานวิจัย.....	238
ภาคผนวก ซ ตารางผลการวิจัย	246
ภาคผนวก ฌ ผลงานวิจัยที่ได้รับการเผยแพร่ในระหว่างการศึกษา.....	280
ประวัติผู้เขียน.....	306

สารบัญตาราง

ตารางที่	หน้า
2.1	เนื้อที่เพาะปลูก และเนื้อที่เก็บเกี่ยวจำแนกตามพันธุ์มันสำปะหลังปี พ.ศ.256315
3.1	การวิเคราะห์ดินในแปลงตัวอย่าง.....80
3.2	เครื่องมือที่ใช้ในการดำเนินงานวิจัย.....81
3.3	สมรรถนะ ส่วนประกอบของอากาศยาน และกล้องที่ติดตั้งบนอากาศยาน.....82
3.4	ซอฟต์แวร์ที่ใช้ในการดำเนินงานวิจัย.....83
3.5	การตั้งค่าการถ่ายภาพบน Parrot SEQUOIA HTML Interface.....86
3.6	ระยะเวลาการเก็บข้อมูล และจำนวนภาพถ่ายจากแปลงตัวอย่างในแต่ละรอบ.....87
3.7	การออกแบบโครงสร้างแบบจำลองด้วยการเขียนโปรแกรมภาษาไพธอน.....95
3.8	การออกแบบโครงสร้างแบบจำลองด้วยการใช้ซอฟต์แวร์ MATLAB® R2018a.....97
4.1	การแปลความหมายค่าสัมประสิทธิ์สหสัมพันธ์.....99
4.2	เปรียบเทียบค่าสหสัมพันธ์ระหว่างดัชนีพืชพรรณ ExG, GRVI และ NDVI กับข้อมูลน้ำหนักหัวมันสำปะหลังสด และปริมาณแป้งในหัวมันสำปะหลังสด.....101
4.3	ประสิทธิภาพของแบบจำลองสมการถดถอยเชิงเส้นอย่างง่ายกับดัชนีพืชพรรณ ExG, GRVI และ NDVI กับข้อมูลน้ำหนักหัวมันสำปะหลัง.....102
4.4	ประสิทธิภาพของแบบจำลองสมการถดถอยเชิงเส้นอย่างง่ายกับดัชนีพืชพรรณ ExG, GRVI และ NDVI กับข้อมูลปริมาณแป้งในหัวมันสำปะหลังสด.....104
5.1	ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลง จำนวนโหนดของแบบจำลองสำหรับทำนายน้ำหนักมันสำปะหลังด้วยข้อมูลชุดฝึกฝน.....107
5.2	ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลง จำนวนโหนดของแบบจำลองสำหรับทำนายน้ำหนักมันสำปะหลังด้วยข้อมูลชุดทดสอบ.....108
5.3	ผลการเปรียบเทียบค่า R^2 MSE และ RMSE ของแบบจำลองสำหรับทำนาย น้ำหนักมันสำปะหลังก่อนและหลังการวิเคราะห์สัญญาณตกหาย.....115
5.4	การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูลชุดฝึกฝน.....116
5.5	การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมในแต่ละชุดข้อมูล.....117

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
5.6	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบ กับข้อมูลทั้งหมด.....121
6.1	ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลง จำนวนโหนดของแบบจำลองสำหรับทำนายปริมาณแบ่งด้วยข้อมูลชุดฝึกฝน.....127
6.2	ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลง จำนวนโหนดของแบบจำลองสำหรับทำนายปริมาณแบ่งด้วยข้อมูลชุดทดสอบ.....129
6.3	ผลการเปรียบเทียบค่า R^2 MSE และ RMSE ของแบบจำลองสำหรับทำนาย ปริมาณแบ่งก่อนและหลังการวิเคราะห์สัญญาณตกหาย.....133
6.4	การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูลชุดฝึกฝน.....134
6.5	การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมในแต่ละชุดข้อมูล.....134
6.6	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบกับข้อมูลทั้งหมด.....139
ก.1	คำศัพท์ที่ใช้ในงานวิจัยและคำแปล.....158
ข.1	การตั้งค่าการบินในการศึกษาวิจัย.....168
ข.1	การตั้งค่าก่อนการประมวลผลในซอฟต์แวร์ Pix4D Mapper.....174
จ.1	ชุดข้อมูลในงานวิจัย.....214
ช.1	ผลการประเมินประสิทธิภาพแบบจำลองทำนายน้ำหนักร่วมกับการเขียนโปรแกรม ภาษาไพธอน.....247
ช.2	ผลการประเมินประสิทธิภาพแบบจำลองทำนายปริมาณแบ่งด้วยการเขียนโปรแกรม ภาษาไพธอน.....263
ช.3	ผลการประเมินประสิทธิภาพแบบจำลองทำนายน้ำหนักร่วมด้วยซอฟต์แวร์ MATLAB.....274
ช.4	ผลการประเมินประสิทธิภาพแบบจำลองทำนายปริมาณแบ่งด้วยซอฟต์แวร์ MATLAB.....277

สารบัญรูป

รูปที่	หน้า
1.1	พื้นที่ปลูกมันสำปะหลังในรายจังหวัด 10 อันดับแรกของปี พ.ศ.2565.....1
1.2	ปริมาณการผลิต นำเข้า และส่งออก ผลผลิตมันสำปะหลัง (ล้านตัน) ทั่วโลกปี พ.ศ. 2563.....2
1.3	โรคใบด่างมันสำปะหลัง.....3
1.4	ปริมาณการนำเข้าผลิตภัณณ์มันสำปะหลังทั่วโลก ค.ศ. 2003–2021 (พ.ศ. 2546-2564).....3
1.5	ปริมาณและมูลค่าการส่งออกมันสำปะหลังของประเทศไทยระหว่างปี พ.ศ. 2556-2565.....4
2.1	ประติมากรรม Moche Yuca.....10
2.2	ปริมาณการส่งออกผลิตภัณณ์มันสำปะหลังระหว่างปี ค.ศ. 2000–2021 (พ.ศ. 2543-2564).....12
2.3	ปริมาณการส่งออกและนำเข้าผลผลิตมันสำปะหลังปี พ.ศ. 2564.....13
2.4	(a) การไถด้วยพล 3 และ (b) พรวนด้วยพล 7.....17
2.5	ลักษณะของท่อนพันธุ์มันสำปะหลัง.....18
2.6	แมลงหิวข้าว.....19
2.7	เครื่องชุดมันสำปะหลัง หรือผานชุดมัน.....20
2.8	Reimann scale balance.....21
2.9	การสุ่มตัวอย่างพืชแบบกระจายสำหรับพื้นที่ขนาดใหญ่.....22
2.10	แบบแผนวิธีการเก็บตัวอย่างดิน (a) เก็บแบบกระจาย (b) เก็บแบบแบ่งโซน.....23
2.11	การชุดเก็บตัวอย่างดิน.....24
2.12	องค์ประกอบของเทคโนโลยีภูมิสารสนเทศ.....25
2.13	ข้อมูลเชิงพื้นที่.....27
2.14	ตัวอย่างข้อมูลราสเตอร์.....27
2.15	ซอฟต์แวร์ QGIS.....29
2.16	GNSS ระบบต่าง ๆ (a) GPS (b) GLONASS (c) Galileo (d) BeiDou.....29

สารบัญรูป (ต่อ)

รูปที่	หน้า
2.17 GNSS principles.....	30
2.18 การรับรู้ระยะไกล.....	32
2.19 ดาวเทียม THEOS-2.....	33
2.20 การหาความสูงการบินเหนือจุดที่บิน.....	37
2.21 ส่วนซ้อน และส่วนเกย.....	38
2.22 (a) รูปแบบการบินทั่วไป และ (b) รูปแบบการบินแบบ Double grid.....	39
2.23 Image Tie-pointing และ Point Cloud.....	42
2.24 ตัวอย่างแผนที่ภาพถ่ายความละเอียดสูง.....	43
2.25 แบบจำลองพื้นผิวภูมิประเทศเชิงเลข (DSM).....	44
2.26 DSM และ DTM.....	44
2.27 การพัฒนาเครื่องถอดรหัส Bombe.....	48
2.28 การพัฒนาซอฟต์แวร์ Checker บนคอมพิวเตอร์ IBM 701.....	49
2.29 การเขียนโปรแกรมแบบดั้งเดิม และการเรียนรู้ของเครื่อง.....	49
2.30 ขอบข่ายการศึกษาใน Computer science.....	50
2.31 Anaconda Navigator และแอปพลิเคชันภายใน.....	53
2.32 สมุดบันทึกของ Google Colaboratory.....	54
2.33 โครงสร้างของ Single layer perceptron.....	61
2.34 FFNN ที่มีชั้นซ้อน 3 ชั้น.....	64
2.34 แผนภาพอัลกอริทึมของโครงข่ายประสาทเทียมแบบวนกลับ.....	65
2.35 Learning curve ของแบบจำลองที่มีความเหมาะสมกับข้อมูลมากเกินไป.....	67
2.36 Learning curve ของแบบจำลองที่มีความเหมาะสมกับข้อมูลต่ำเกินไป.....	67
2.37 Learning curve ของแบบจำลองที่มีความเหมาะสมกับข้อมูลพอดี.....	68
2.38 การวิเคราะห์สัญญาณตกหาย.....	72
3.1 ขั้นตอนการศึกษาวิจัย.....	79
3.2 พื้นที่ศึกษาวิจัย อำเภอบรรพตพิสัย จังหวัดนครราชสีมา.....	80

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.3	อากาศยานไร้คนขับรุ่น DJI Phantom 4 Pro ที่มีการติดตั้งกล้องถ่ายภาพแบบหลายช่วงคลื่นและ Sunshine sensor และ Remote controller.....82
3.4	กล้องถ่ายภาพแบบหลายช่วงคลื่น รุ่น Parrot SEQUOIA และ Sunshine Sensor.....83
3.5	การกำหนดเส้นทางการบิน.....85
3.6	การสอบเทียบค่าแสง.....87
3.7	Reiman Scale Balance.....88
3.8	การแบ่งพื้นที่ศึกษาวิจัยออกเป็นแปลงย่อย.....89
3.9	การเก็บข้อมูลในหนึ่งจุดของกลุ่มตัวอย่าง.....90
3.10	ขั้นตอนการประมวลผลภาพถ่ายด้วย Pix4D Mapper.....91
3.11	แผนที่ภาพถ่ายความละเอียดสูง และแบบจำลองพื้นผิวภูมิประเทศเชิงเลขของภาพที่ได้จากกล้องถ่ายภาพ RGB.....92
3.12	แผนที่ภาพถ่ายความละเอียดสูงของแต่ละช่วงคลื่น และแบบจำลองพื้นผิวภูมิประเทศเชิงเลขของภาพที่ได้จากกล้องถ่ายภาพแบบหลายช่วงคลื่น.....92
3.13	แผนที่ภาพถ่ายความละเอียดสูงของ (a) ภาพถ่าย RGB และดัชนีพืชพรรณ (b) ExG (c) GRVI (d) NDVI.....94
3.14	การสร้างแบบจำลองบน Google Colaboratory.....96
4.1	ตารางค่าสหสัมพันธ์แสดงความสัมพันธ์ระหว่างดัชนีพืชพรรณ ExG, GRVI และ NDVI กับน้ำหนักของหัวมันสำปะหลังสด (Yield_weight) และปริมาณแป้งในหัวมันสำปะหลังสด (Percent_starch).....101
5.1	Loss curve ของแบบจำลองที่มีจำนวน 64 โหนด.....109
5.2	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า MSE.....110
5.3	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า R^2111
5.4	Loss curve ของแบบจำลองที่มี 6 ชั้นซ่อน.....112
5.5	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า MSE.....113
5.6	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า R^2114
5.7	Loss curve ของแบบจำลองที่มี 7 ชั้นซ่อนที่มีการวิเคราะห์สัญญาณตกหาย.....114
5.8	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า MSE.....118

สารบัญรูป (ต่อ)

รูปที่	หน้า
5.9	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า R^2119
5.10	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า MSE.....120
5.11	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า R^2120
5.12	ค่า MSE ของแบบจำลองที่ใช้อัลกอริทึม LM.....122
5.13	ความต่างระหว่างค่าข้อมูลจริงและค่าจากการทำนายของแบบจำลอง.....122
5.14	การถดถอยของแบบจำลองในข้อมูลชุดต่าง ๆ.....123
5.15	การเปรียบเทียบค่าน้ำหนักของหัวมนสำปะหลังสดจากข้อมูลจริงภายในแปลง กับข้อมูลจากการทำนายโดยใช้อัลกอริทึม SCG LM และ BR.....124
6.1	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนขึ้นช่อนต่อค่า MSE.....130
6.2	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนขึ้นช่อนต่อค่า R^2130
6.3	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนขึ้นช่อนต่อค่า MSE.....132
6.4	ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนขึ้นช่อนต่อค่า R^2132
6.5	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า MSE.....136
6.6	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า R^2136
6.7	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า MSE.....137
6.8	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า R^2137
6.9	การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลทั้งหมดด้วยค่า R^2139
6.10	ค่า MSE ของแบบจำลองที่ใช้อัลกอริทึม BR.....140
6.11	ความต่างระหว่างค่าข้อมูลจริงและค่าจากการทำนายของแบบจำลอง.....140
6.12	การถดถอยของแบบจำลองในข้อมูลชุดต่าง ๆ.....141
6.13	การเปรียบเทียบค่าปริมาณแบ่งในหัวมนสำปะหลังสดจากข้อมูลจริงภายในแปลง กับข้อมูลจากการทำนายโดยใช้การใช้อัลกอริทึม SCG LM และ BR.....142
ข.1	แอปพลิเคชัน DJI GO4 และ Pix4D Capture.....162
ข.2	หน้าเริ่มต้น แสดงการเชื่อมต่อกับอากาศยานไร้คนขับ.....163
ข.3	หน้าแสดงอากาศยานที่รองรับการใช้งานได้.....163
ข.4	หน้าจอหลัก.....164
ข.5	สถานะของอากาศยาน.....164

สารบัญรูป (ต่อ)


รูปที่	หน้า
ข.6	การปิดการทำงานของเซนเซอร์.....165
ข.7	หน้าเริ่มต้น Pix4D Mapper.....166
ข.8	รุ่นของอากาศยาน และกล้อง.....166
ข.9	หน้าต่างวางแผนการบิน.....167
ข.10	หน้าต่างการตั้งค่าการบินแบบ Advanced.....168
ข.11	การเช็คสถานะก่อนทำการบิน.....169
ข.12	อากาศยานขณะบินตามภารกิจในแผนที่ที่วางไว้.....169
ข.13	หน้าเริ่มต้น Pix4D Mapper.....170
ข.14	การสร้าง Project ใหม่.....171
ข.15	การนำเข้ารูปภาพ.....171
ข.16	Image properties.....172
ข.17	Select Output Coordinate System.....172
ข.18	Processing Option Template.....173
ข.19	หน้าต่าง Processing.....173
ข.20	Initial processing.....175
ข.21	Point Cloud and Mesh.....175
ข.22	DSM Orthomosaic and Index.....176
ข.23	ไฟล์ที่ได้ภายหลังการประมวลผล.....176
ข.24	การพิมพ์ชิ้นส่วนฐานกล้องถ่ายภาพหลายช่วงคลื่น.....177
ข.25	การพิมพ์ชิ้นส่วนฐานกล้อง Sunshine sensor และอุปกรณ์จับยึด.....177
ข.26	การพิมพ์ชิ้นส่วนขาตั้งอากาศยาน.....178
ข.27	การติดตั้งอุปกรณ์จับยึดกับ UAV และชุดกล้อง Parrot SEQUOIA และแบตเตอรี่.....178
ข.28	การตั้งค่าในการถ่ายภาพบน Parrot SEQUOIA HTML Interface.....179
ข.29	การคำนวณ Timelapse interval.....179
ข.30	การวางแผนสอบเทียบ.....180
ข.31	การทำ Radiometric calibration.....181
ข.32	หน้าเริ่มต้นการสอบเทียบค่าใน Pix4D.....181

สารบัญรูป (ต่อ)

รูปที่	หน้า
ข.33	การกำหนดพื้นที่สอบเทียบ.....182
ข.34	การกำหนดการสอบเทียบสำเร็จ.....182
ข.35	การตั้งค่าการคำนวณดัชนี NDVI บน Pix4D.....183
ง.1	หน้าต่างเริ่มต้นของซอฟต์แวร์ QGIS.....201
ง.2	การนำเข้าไฟล์ .tiff.....202
ง.3	คำสั่ง Raster Calculator.....202
ง.4	การคำนวณค่าดัชนีพืชพรรณ ExG.....203
ง.5	แผนที่ความละเอียดสูงของดัชนีพืชพรรณ ExG.....204
ง.6	เลือกชุดคำสั่ง Properties.....204
ง.7	การผสมสีแบบ Singleband pseudocolor.....205
ง.8	การประมาณค่าเชิงพื้นที่แบบ Linear ทั้งแปลง.....206
ง.9	การประมาณค่าเชิงพื้นที่แบบ Discrete ทั้งแปลง.....206
ง.10	การประมาณค่าเชิงพื้นที่แบบ Linear เฉพาะส่วน.....207
ง.11	การประมาณค่าเชิงพื้นที่แบบ Discrete เฉพาะส่วน.....207
ง.12	การกำหนดค่าขีดแบ่ง.....208
ง.13	แผนที่ภายหลังการกำหนดค่าขีดแบ่ง.....209
ง.14	รายละเอียดแผนที่ภายหลังการกำหนดค่าขีดแบ่ง.....209
ง.15	การตัดเอาเฉพาะส่วนที่เป็นพืช.....210
ง.16	ผลลัพธ์การตัดเอาเฉพาะพืช.....211
ง.17	แผนที่ความละเอียดสูงของพืชพรรณ.....211
ง.18	คำสั่งเลือกดูค่าดัชนีพืชพรรณรายจุด.....212
ง.19	ค่าดัชนีพืชพรรณรายจุด.....212
ข.1	หน้าต่างเริ่มต้นของซอฟต์แวร์ MATLAB.....239
ข.2	การเพิ่มข้อมูล และตั้งชื่อชุดข้อมูล.....239
ข.3	การสร้างชุดข้อมูล.....240
ข.4	การสร้างฟังก์ชันสำหรับการทำ Normalization.....240
ข.5	การเรียกใช้ Neural Network Tool box.....241

สารบัญรูป (ต่อ)

รูปที่	หน้า
ช.6	การเรียกใช้ Neural Fitting app.....241
ช.7	การเลือกชุดข้อมูล.....242
ช.8	การแบ่งชุดข้อมูล.....242
ช.9	การแบ่งชุดข้อมูล.....243
ช.10	กำหนดอัลกอริทึมสำหรับฝึกฝนแบบจำลอง.....243
ช.11	หน้าต่าง Neural Network Training.....244
ช.12	ผลลัพธ์ภายหลังการฝึกฝนแบบจำลอง.....244
ช.13	Plot Fit, Plot Error Histogram ,Plot Regression และ Performance.....245



คำอธิบายสัญลักษณ์และคำย่อ


GNSS	=	ระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม
UAV	=	อากาศยานไร้คนขับ
GSD	=	ระยะระหว่างจุดศูนย์กลางจุดภาพบนพื้นดิน
DSM	=	แบบจำลองพื้นผิวภูมิประเทศเชิงเลข
RGB	=	แสงช่วงคลื่นที่ตามองเห็น
NIR	=	อินฟราเรดย่านใกล้
NDVI	=	Normalized Difference Vegetation Index
ExG	=	Excess Green index
GRVI	=	Green Red Vegetation Index
pH	=	ค่าแสดงความเป็นกรดเบส
EC	=	ค่าความนำไฟฟ้าในดิน
%OM	=	ร้อยละของสารประกอบอินทรีย์
ppm	=	ส่วนในล้านส่วน
ANN	=	โครงข่ายประสาทเทียม
MLP, DNN	=	โครงข่ายประสาทเทียมแบบหลายชั้น, โครงข่ายประสาทเทียมเชิงลึก
FFNN	=	โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า
ReLU	=	ฟังก์ชันกระตุ้นชนิด Rectified Linear Unit
R^2	=	ค่าสัมประสิทธิ์แสดงการตัดสินใจ
MAE	=	ค่าความผิดพลาดสัมบูรณ์เฉลี่ย
MSE	=	ค่าความผิดพลาดกำลังสองเฉลี่ย
RMSE	=	ค่ารากที่สองของความผิดพลาดกำลังสองเฉลี่ย
BR	=	Bayesian regularization
SCG	=	Scaled conjugate gradient
LM	=	Levenberg-Marquardt algorithm

บทที่ 1

บทนำ


1.1 ความสำคัญของปัญหา

มันสำปะหลังเป็นพืชเศรษฐกิจที่สำคัญของประเทศไทยและเป็นพืชอาหารที่สำคัญของโลก เนื่องด้วยมันสำปะหลังเป็นแหล่งคาร์โบไฮเดรตที่มีราคาถูกกว่าผลผลิตแป้งชนิดชนิดอื่น มันสำปะหลังถูกแปรรูปในอุตสาหกรรมอาหาร อาหารสัตว์ ยา กระดาษ เคมีภัณฑ์ และพลังงานชีวภาพ มันสำปะหลังเป็นพืชอาหารที่มีคนบริโภคมากเป็นอันดับ 5 ของโลก รองจาก ข้าวโพด ข้าวสาลี ข้าวเจ้า และมันฝรั่ง (ชัยวัช โสวเจริญสุข, 2566; วชิริน มีรอด, กุลวรารักษ์ สุวรรณศรี และกฤษฎา บำรุงวงศ์, 2558) สำหรับประเทศไทยมันสำปะหลังเป็น 1 ใน 5 ของพืชเศรษฐกิจที่สำคัญของไทยเช่นเดียวกับ ข้าว ยางพารา ปาล์ม และอ้อย โดยมีเกษตรกรผู้ปลูกมันสำปะหลังประมาณ 738,153 ครัวเรือนส่วนใหญ่เป็นเกษตรกรรายย่อย พื้นที่เพาะปลูกมันสำปะหลังเฉลี่ยต่อครัวเรือนอยู่ที่ 23,552 ตารางเมตรต่อครัวเรือน โดยมีพื้นที่ปลูกทั้งประเทศจำนวน 17,379.16 ตารางกิโลเมตร พื้นที่ปลูกส่วนใหญ่อยู่ในภาคตะวันออกเฉียงเหนือจำนวน 9,414.8384 ตารางกิโลเมตร (กระทรวงเกษตรและสหกรณ์, สำนักงานเศรษฐกิจการเกษตร, 2566) รูปที่ 1.1 แสดงจังหวัดที่มีการเพาะปลูกมันสำปะหลังมากที่สุด



รูปที่ 1.1 พื้นที่ปลูกมันสำปะหลังในรายจังหวัด 10 อันดับแรกของปี พ.ศ.2565

(กระทรวงเกษตรและสหกรณ์, สำนักงานเศรษฐกิจการเกษตร, 2566)




รูปที่ 1.2 ปริมาณการผลิต นำเข้า และส่งออก ผลผลิตมันสำปะหลัง (ล้านตัน) ทั่วโลกปี พ.ศ. 2563
(ชัยวัช โสวเจริญสุข, 2566)

ประเทศไทยผลิตมันสำปะหลังอันดับที่ 3 ของโลก และอันดับที่ 1 ของภูมิภาคเอเชียตะวันออกเฉียงใต้ (รูปที่ 1.2) มีปริมาณส่งออกโดยเฉลี่ย 29 ล้านตัน คิดเป็นสัดส่วนทางการตลาดที่ร้อยละ 9.6 ของประเทศผู้ส่งออกทั่วโลกและปริมาณผลผลิตสูงสุดที่ผลิตได้คือ 35 ล้านตันในปี 2564 - 2565

แม้ว่าประเทศไทยจะเป็นหนึ่งในผู้นำด้านการส่งออกผลิตภัณฑ์มันสำปะหลังของโลก อย่างไรก็ตามในภาพรวมยังพบปัญหา และข้อจำกัดสำคัญบางประการที่ต้องแก้ไขเพื่อเพิ่มขีดความสามารถของอุตสาหกรรมมันสำปะหลัง หนึ่งในปัญหาที่สำคัญที่พบ คือ ปัญหาในเชิงนโยบายของรัฐ และข้อมูลที่ไม่เพียงพอต่อการตัดสินใจที่มีประสิทธิภาพ และยังพบปัญหาจากปัจจัยภายนอกที่เกิดจากการเปลี่ยนแปลงอย่างรวดเร็ว (Mega Trend) ซึ่งส่งผลต่ออุตสาหกรรมทั้งทางตรงและทางอ้อม ได้แก่ การก้าวสู่สังคมสูงวัย (Aging Society) โดยเกษตรกรไทยปลูกมันสำปะหลัง มีอายุเฉลี่ย 53 ปี ส่วนใหญ่ยังคงทำไร่มันสำปะหลังโดยพึ่งพาแรงงานเกือบทั้งหมด ส่งผลให้เกิดการขาดแคลนแรงงาน และต้นทุนการจ้างงานสูงขึ้น ด้วยเหตุนี้จึงส่งผลให้ผลผลิตภาพการผลิต (Productivity) ลดลงเพราะเกษตรกรมีข้อจำกัดในการเข้าถึงเทคโนโลยี และคนรุ่นใหม่ไม่นิยมประกอบอาชีพเกษตรกร และอีกปัญหาหนึ่งที่พบคือ การเปลี่ยนแปลงของสภาพอากาศ (Climate Change) อาทิ น้ำท่วม ภัยแล้ง โรคเพลี้ยแป้งสีชมพู และโรคใบด่างมันสำปะหลัง (รูปที่ 1.3) ส่งผลให้ผลผลิตเสียหายและการวางแผนเพาะปลูกทำได้ยากขึ้น (ศรินดา ปรีชา, ภัทรภรณ์ หิรัญวงศ์ และอภิษฐา จิงตระกูล, 2563)




รูปที่ 1.3 โรคใบด่างมันสำปะหลัง



รูปที่ 1.4 ปริมาณการนำเข้าผลิตภัณฑ์มันสำปะหลังทั่วโลก ค.ศ. 2003–2021 (พ.ศ. 2546-2564)
(ชัยวัช โสวเจริญสุข, 2566)

ความต้องการมันสำปะหลังเพิ่มขึ้นอย่างต่อเนื่องทั้งตลาดภายในประเทศ และตลาดส่งออก (รูปที่ 1.5) เนื่องมาจากการขยายตัวอย่างต่อเนื่องของอุตสาหกรรมในประเทศจีน โดยมีความต้องการใช้มันสำปะหลังในการผลิตเอทานอล อาหารสัตว์ และแอลกอฮอล์เนื่องมาจากการระบาดของ COVID-19 นอกจากนี้ความต้องการมันสำปะหลังสำหรับการแปรรูปเพื่อบริโภคเป็นอาหารยังคงเพิ่มขึ้น เนื่องจากสถานการณ์ความขัดแย้งระหว่างยูเครนและรัสเซีย โดยคาดว่าปริมาณการส่งออกโดยรวมจะเพิ่มขึ้นเฉลี่ยร้อยละ 2 - 3 ต่อปี (รูปที่ 1.4) อย่างไรก็ตามปริมาณผลผลิตที่ไม่แน่นอนเนื่องจากสภาพอากาศ และการระบาดของโรคใบด่างมันสำปะหลังยังคงเป็นอุปสรรคสำคัญของอุตสาหกรรมมันสำปะหลัง (ชัยวัช โสวเจริญสุข, 2566)



รูปที่ 1.5 ปริมาณและมูลค่าการส่งออกมันสำปะหลังของประเทศไทยระหว่างปี พ.ศ. 2556-2565
(กระทรวงเกษตรและสหกรณ์, สำนักงานเศรษฐกิจการเกษตร, 2566)

ปัญหาความไม่สมดุลระหว่างผลผลิตที่ผลิตได้และปริมาณความต้องการทำให้เกิดปัญหามันสำปะหลังขาดแคลนหรือล้นตลาดในบางช่วงเวลาส่งผลเสียโดยตรงต่ออุตสาหกรรมที่ใช้มันสำปะหลังเป็นวัตถุดิบหลัก (มูลนิธิสถาบันมันสำปะหลังแห่งประเทศไทย, 2557) โดยกลุ่มที่ได้รับผลกระทบมากที่สุดคือเกษตรกรชาวไร่มันสำปะหลังรายย่อยซึ่งเป็นกลุ่มอุตสาหกรรมต้นน้ำ หากมีการคาดการณ์ปริมาณผลผลิตที่แม่นยำจะส่งผลดีต่อการวางแผนการผลิต

ปัจจุบันการคาดการณ์ปริมาณผลผลิตมันสำปะหลังยังมีข้อจำกัดหลายประการ เนื่องจากวิธีการตรวจวัดภาคสนามภายในแปลงขนาดใหญ่มีความยุ่งยากสูงทำให้เกษตรกรยังคงใช้วิธีการคาดคะเนด้วยประสบการณ์โดยปัญหาที่พบคือ ยิ่งแปลงมีขนาดใหญ่มาก ยิ่งเกิดโอกาสประเมินผิดพลาดได้มาก เช่น มีบริเวณที่มันสำปะหลังไม่เจริญเติบโต เกิดโรค และมีน้ำท่วมขัง (Chu, Starek, Brewer, Murray and Pruter, 2017) เทคโนโลยีการรับรู้ระยะไกล (Remote Sensing) จึงเป็นเครื่องมือที่มีบทบาทสำคัญด้านการตรวจวัดและวิเคราะห์ข้อมูลภายในแปลงโดยช่วยเพิ่มความแม่นยำลดระยะเวลาและประหยัดทรัพยากรในการสำรวจพื้นที่ทางการเกษตรขนาดใหญ่ (Jensen, 2007)

เทคโนโลยีการรับรู้ระยะไกลมีส่วนช่วยอย่างมากการรวบรวมข้อมูลจากภาพถ่ายทางอากาศซึ่งถ่ายด้วยช่วงคลื่นจำเพาะจากกล้องที่ติดตั้งบนดาวเทียม เพื่อเก็บรวบรวมข้อมูลภาพถ่ายสำหรับการประมวลผลด้วยระบบสารสนเทศภูมิศาสตร์ (Geographic Information system) หรือ GIS เพื่อช่วย

ด้านการตรวจวัดและตรวจวิเคราะห์สภาพแวดล้อมภายในแปลง เช่น การแสดงข้อมูลสภาพการเพาะปลูก ความอุดมสมบูรณ์ของดิน การวัดปริมาณผลผลิต และดัชนีพืชพรรณ โดยมีงานวิจัยที่เสนอการประเมินผลผลิตจากภาพถ่ายดาวเทียมในแปลงข้าวโพด (Fieuzal, Sicre, and Baup, 2017; Sun et al., 2020) ถั่วเหลือง (Sun, Di, Sun, Shen and Lai, 2019; Terliksiz and Altılyar, 2019) อ้อย (Mutanga, Schoor, Olorunju, Gonah and Ramoelo, 2013) และมันสำปะหลัง (วลัยพร ศะศิประภา, นริลักษณ์ วรรณสาย, สุภาพร ราจันทิก และนิชา โปทอง, 2555)

การรับรู้ระยะไกลโดยใช้ข้อมูลจากภาพถ่ายดาวเทียมสำหรับงานด้านการเกษตรยังมีข้อจำกัดที่ช่วงเวลาในการโคจรต่อรอบที่จำเพาะช่วงเวลาและภาพมีความละเอียดจุดภาพที่ต่ำ ส่งผลให้ความละเอียดของภาพไม่เพียงพอต่อการวิเคราะห์ข้อมูลที่ต้องการ เทคโนโลยีอากาศยานไร้คนขับ (Unmanned Aerial Vehicle) หรือ UAV จึงเป็นทางเลือกที่เหมาะสมกว่าในการเก็บข้อมูลภายในแปลงด้วยความสะดวกรวดเร็ว มีความละเอียดข้อมูลสูง และมีต้นทุนที่ต่ำกว่า (Zhao and Lee, 2020)

ในปัจจุบันเนื่องจากอากาศยานไร้คนขับมีการนำมาใช้ประโยชน์ในงานเกษตรกรรมอย่างแพร่หลาย อาทิ การนำไปสำรวจแปลงขนาดใหญ่ เพื่อวิเคราะห์พื้นที่เพาะปลูก รวมไปถึงการวางแผนเก็บเกี่ยวให้แม่นยำมากขึ้น หรือการใช้งานในเฉพาะด้าน เช่น การฉีดพ่นสารเคมีทางการเกษตรแบบเฉพาะจุด การตรวจความสมบูรณ์ของต้นพืช การประมาณค่าชีวมวลเหนือพื้นดิน เป็นต้น ทำให้เกษตรกรรมแบบดั้งเดิมเปลี่ยนไปเป็นเกษตรแม่นยำสูง (Precision Agriculture) ซึ่งมีความแม่นยำมากขึ้น ลดต้นทุนการผลิต แต่ได้ประสิทธิภาพเพิ่มขึ้น (ศูนย์วิจัยกสิกรรมไทย, 2560)

การทำนายปริมาณผลผลิตทางการเกษตรโดยใช้ข้อมูลภาพถ่ายทางอากาศจากเซนเซอร์ที่ติดตั้งบนอากาศยานไร้คนขับเป็นอีกแนวทางหนึ่งของการเป็นเกษตรแม่นยำสูง โดยข้อมูลภาพที่ได้จะเป็นข้อมูลที่ได้จากการสะท้อนของวัตถุด้วยภาพ RGB และภาพถ่ายหลายช่วงคลื่น (Multispectral Images) ข้อมูลค่าการสะท้อนจะถูกนำมาคำนวณด้วยสมการเพื่อหาค่าดัชนีพืชพรรณ (Vegetation Index) ที่ถูกใช้ในการระบุความหนาแน่น ความสมบูรณ์ของพืชพรรณ และติดตามการเจริญเติบโตของพืช (Jiang, Gao and Gao, 2020) มีการใช้ดัชนีพืชพรรณในการทำนายผลผลิตทางการเกษตรของพืชเศรษฐกิจในประเทศไทยจำนวนมาก อาทิ อ้อย (จิรวัดน์ โนดไธสง, ขวัญตรี แสงประชาธนา รักษา, เกษภา โพธิ์สม และคณะ, 2562; โพธิ์วุฒิ บุญเรือง, ชยันต์ ภักดีไทย และศิวา แก้วปลั่ง, 2564) ข้าว (พรหมชัย สุพรรณ, ธนัช เอกเกื้อกุล, เนติ ศรีหาหนู และศิวา แก้วปลั่ง, 2561) และมันสำปะหลัง (วลัยพร ศะศิประภา และคณะ, 2555) โดยอาจพัฒนาแบบจำลองการทำนายด้วยแบบจำลองทางสถิติ หรือการใช้แบบจำลองปัญญาประดิษฐ์ เช่น แบบจำลองการเรียนรู้ของเครื่อง และแบบจำลองการเรียนรู้เชิงลึก เป็นต้น

แบบจำลองการเรียนรู้ของเครื่องถูกนำมาใช้ในการทำนายปริมาณผลผลิตทางการเกษตรร่วมกับข้อมูลที่ได้จากภาพถ่ายทางอากาศ โดยใช้แบบจำลองทางคณิตศาสตร์ของความสัมพันธ์ในเชิงเส้นตรง หรือแบบจำลองสมการถดถอยเชิงเส้น โดยได้มีผู้ใช้แบบจำลองดังกล่าวในการทำนายปริมาณผลผลิตของอ้อยจากค่าการสะท้อนแสงสีแดง สีน้ำเงิน และค่าความสูงของต้นอ้อย (โพธิ์วุฒิ บุญเรือง และคณะ, 2564) อีกทั้งยังมีการใช้ค่าดัชนีพืชพรรณในการทำนายปริมาณผลผลิตของข้าว (พงษ์ หลวงมูล และถาวร อ่อนประไพ, 2564) อ้อย (Khuimphukhieo, Marconi, Enciso and Silva, 2023) ข้าวโพด (Fieuzal et al., 2017) และมันสำปะหลัง (วลัยพร ศะศิประภา และคณะ, 2555)

แบบจำลองโครงข่ายประสาทเทียมเป็นหนึ่งในเทคนิคของการเรียนรู้เชิงลึกถูกนำมาใช้ในการทำนายปริมาณผลผลิตของพืชโดยมีงานวิจัยก่อนหน้านี้ที่ใช้ข้อมูลสภาพอากาศ และภาพถ่ายจากอากาศยานไร้คนบินในการทำนายปริมาณผลผลิต ข้าว (Basir, Chowdhury, Islam and Rabbani, 2021) ข้าวโพดเลี้ยงสัตว์ (Wahab, Hall and Jirström, 2018) ข้าวสาลี ข้าวบาร์เลย์ และข้าวโอ๊ต (Nevavuori, Narra, Linna, and Lipping, 2020) และมันฝรั่ง (Sun et al., 2020) พบว่ามีความคลาดเคลื่อนที่ยอมรับได้ โดยข้อได้เปรียบของวิธีการโครงข่ายประสาทเทียมคือ สามารถพยากรณ์ค่าข้อมูลตัวเลขได้ดีมีประสิทธิภาพในการทำนายสูง และสามารถวิเคราะห์ข้อมูลที่มีหลากหลายตัวแปรได้ดี อย่างไรก็ตามยังไม่มีงานวิจัยการเสนอวิธีการทำนายปริมาณผลผลิตมันสำปะหลังโดยใช้ภาพถ่ายจากอากาศยานไร้คนขับ และเทคโนโลยีการเรียนรู้เชิงลึก งานวิจัยนี้จึงเป็นเสมือนแนวทางเริ่มแรกในการพัฒนาแบบจำลองเพื่อแก้ปัญหาของเกษตรกร และภาคอุตสาหกรรมต่อไป

จากปัญหาและโอกาสดังที่ได้กล่าวมาข้างต้น เทคนิควิธีการทำนายปริมาณผลผลิตทางการเกษตรจึงถูกนำมาพัฒนาแบบจำลองด้วยวิธีการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) สำหรับประยุกต์ใช้ในการทำนายปริมาณผลผลิตมันสำปะหลัง งานวิจัยนี้มีวัตถุประสงค์เพื่อหาแนวทางการทำนายน้ำหนัก และปริมาณแป้งในหัวมันสำปะหลังสดต่อหน่วยพื้นที่จากข้อมูลดัชนีพืชพรรณที่คำนวณได้ภาพถ่ายหลายช่วงคลื่นด้วยกล้อง RGB และกล้องถ่ายภาพหลายช่วงคลื่นที่ติดตั้งบนอากาศยานไร้คนขับในพื้นที่แปลงตัวอย่าง งานวิจัยนี้มีขอบเขตที่การประมาณปริมาณผลผลิตในช่วง 4 เดือนก่อนระยะเก็บเกี่ยว หรือในช่วง 8 – 12 เดือนหลังปลูก สำหรับมันสำปะหลังพันธุ์ระยอง 72 ที่ปลูกบนชุดดินนครบุรี ด้วยแบบจำลองสมการถดถอยเชิงเส้นเพื่อหาค่าดัชนีพืชพรรณที่มีความเหมาะสมที่สุดในการทำนายปริมาณผลผลิตด้วยแบบจำลองโครงข่ายประสาทเทียม และหาแบบจำลองโครงข่ายประสาทเทียมที่มีความเหมาะสมที่สุดต่อการทำนายปริมาณผลผลิตมันสำปะหลังโดยการประเมินประสิทธิภาพของแบบจำลองจากค่าสัมประสิทธิ์แสดงการตัดสินใจ (Coefficient of determination, R^2) ค่าความผิดพลาดกำลังสองเฉลี่ย (Mean squared error) และค่ารากที่สองของความผิดพลาดกำลังสองเฉลี่ย (Root mean squared error)

1.2 วัตถุประสงค์

1.2.1 เพื่อหาชนิดของดัชนีพืชพรรณที่มีความเหมาะสมที่สุดในการทำนายปริมาณผลผลิตมันสำปะหลัง

1.2.2 เพื่อหาแบบจำลองการเรียนรู้เชิงลึกที่มีความเหมาะสมมากที่สุดในการทำนายน้ำหนักของหัวมันสำปะหลังสดภายในแปลงด้วยข้อมูลภาพถ่ายจากอากาศยานไร้คนบิน

1.2.3 เพื่อหาแบบจำลองการเรียนรู้เชิงลึกที่มีความเหมาะสมมากที่สุดในการทำนายปริมาณแป้งของหัวมันสำปะหลังสดภายในแปลงด้วยข้อมูลภาพถ่ายจากอากาศยานไร้คนบิน

1.3 ขอบเขต

1.3.1 ศึกษาบนแปลงมันสำปะหลังตัวอย่างพันธุ์ระยอง 72 จำนวน 1 แปลงที่มีการให้น้ำในระบบน้ำหยด ขนาดพื้นที่ 12,800 ตารางเมตร ในพื้นที่ตำบลเฉลียง อำเภอบางบาล จังหวัดนครราชสีมา มีรอบการปลูกระหว่างเดือน พฤษภาคม พ.ศ.2564 - เมษายน พ.ศ.2565 โดยศึกษาการทำนายปริมาณผลผลิตในระยะเก็บเกี่ยว (8 – 12 เดือนหลังปลูก)

1.3.2 ใช้ข้อมูลภาพถ่ายจากอากาศยานไร้คนขับในระดับ Survey Grade ที่มีระดับความเชื่อมั่นไม่ต่ำกว่า 95% หรือมีค่าเฉลี่ย GSD ไม่เกิน 3 เซนติเมตร

1.3.3 ใช้ข้อมูลดัชนีพืชพรรณ ExG, GRVI และ NDVI เป็นข้อมูลรับเข้า (Input data)

1.3.4 ใช้ข้อมูลน้ำหนักของหัวมันสำปะหลัง (กิโลกรัม/ตารางเมตร) และปริมาณแป้งในหัวมันสำปะหลัง (%) เป็นข้อมูลส่งออก (Output data)

1.3.5 ใช้แบบจำลองการเรียนรู้ของเครื่องด้วยวิธีการถดถอยเชิงเส้นและค่าสหสัมพันธ์เพื่อหาชนิดของดัชนีพืชพรรณที่มีความเหมาะสมที่สุดในการทำนายปริมาณผลผลิตด้วยวิธีการเรียนรู้เชิงลึก

1.3.6 ใช้แบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นในการทำนายข้อมูลส่งออก จากข้อมูลนำเข้า

1.3.7 ใช้การเขียนโปรแกรมภาษาไพธอน และซอฟต์แวร์ MATLAB® R2018a ในการพัฒนาแบบจำลอง

1.3.8 ใช้จำนวนชั้นซ่อนของแบบจำลองระหว่าง 1 – 10 ชั้นซ่อน

1.3.9 ค่าการทำนายปริมาณผลผลิตต้องมีค่า R^2 ไม่ต่ำกว่า 0.80 มีค่า MSE ไม่ต่ำกว่า 0.01 และมีค่า RMSE ไม่ต่ำกว่า 0.1 กิโลกรัม/ตารางเมตร สำหรับน้ำหนัก และร้อยละ 0.1 หรือ 0.1% สำหรับปริมาณแป้ง

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 สามารถแสดงความสัมพันธ์ระหว่างภาพถ่ายหลายช่วงคลื่นของใบมันสำปะหลังกับน้ำหนัก และปริมาณแป้งในหัวมันสำปะหลังสดได้

1.4.2 สามารถพัฒนาแบบจำลองทำนายปริมาณผลผลิตมันสำปะหลังที่มีความแม่นยำสูงเพื่อใช้เป็นแนวทางในการพัฒนาต่อยอดแบบจำลองทำนายผลผลิตล่วงหน้าสำหรับการวางแผนการผลิต และส่งออกในภาคอุตสาหกรรม

1.4.3 สามารถพัฒนาต่อยอดงานวิจัยออกสู่ตลาด เพื่อพัฒนาผลิตภัณฑ์ หรือบริการที่ช่วยแก้ไขปัญหาของเกษตรกร และโรงงานแปรรูปผลผลิตมันสำปะหลัง



บทที่ 2

ปรัทัศนัวรรณกรรมและงานวิจัยที่เกี่ยวข้อง

เนื้อหาในส่วนนี้เป็นการกล่าวถึงความรู้พื้นฐานที่จำเป็นและเกี่ยวข้องโดยตรงกับการศึกษาวิจัย ได้แก่ ประวัติความเป็นมาของมันสำปะหลัง ภาพรวมของอุตสาหกรรมมันสำปะหลัง การปลูกมันสำปะหลัง ช่วงอายุการเจริญเติบโตของมันสำปะหลัง ทฤษฎีการสุ่มวัดภายในแปลง เทคโนโลยีภูมิสารสนเทศระบบสารสนเทศภูมิศาสตร์ ระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม การรับรู้ระยะไกลรวมไปถึงการถ่ายภาพด้วยอากาศยานไร้คนขับ และเทคโนโลยีปัญญาประดิษฐ์ที่ใช้ในงานวิจัย ตลอดจนงานวิจัยที่เกี่ยวข้องในการศึกษาวิจัยนี้

2.1 มันสำปะหลัง

2.1.1 ประวัติความเป็นมาของมันสำปะหลัง

มันสำปะหลังจัดเป็นพืชหัวชนิดหนึ่ง ชื่อวิทยาศาสตร์คือ *Manihot esculenta* Crantz. มีชื่อสามัญเรียกหลายชื่อตามภาษาต่างประเทศเช่น ได้แก่ Cassava, Yuca, Mandioca, Manioc และ Topioca มันสำปะหลังมีหลักฐานแสดงแหล่งกำเนิดราว 6,000 ปีก่อน โบราณวัตถุ Moche Yuca (รูปที่ 2.1) ซึ่งจัดแสดงอยู่ที่พิพิธภัณฑ์ Larco Museum Collection ณ เมืองลิมา ประเทศเปรู ่งบอกว่า ได้มีการใช้ประโยชน์จากมันสำปะหลังในแถบทวีปอเมริกา เม็กซิโก บราซิล และโบลิเวีย



รูปที่ 2.1 ประติมากรรม Moche Yuca (มูลนิธิสถาบันมันสำปะหลังแห่งประเทศไทย, 2560)

ในศตวรรษที่ 17-18 ประเทศในยุโรป เช่น โปรตุเกสและสเปน ได้ส่งกองกำลัง และผู้สอนศาสนาขยายอิทธิพลไปยังประเทศแถบแอฟริกา อเมริกาใต้ โดยเฉพาะประเทศในแถบอเมริกา กลางและอเมริกาใต้ ซึ่งเป็นแหล่งกำเนิดของมันสำปะหลัง มันสำปะหลังมีชื่อในภาษาโปรตุเกสที่เรียก ในบราซิลว่า Mandioca ในโคลอมเบีย กัวเตมาลา เม็กซิโก จะเรียกตามภาษาสเปนว่า Yuca

การแพร่กระจายของลัทธิจักรวรรดินิยมส่งผลให้มีการนำมันสำปะหลังไปปลูกใน ดินแดนอาณานิคมต่าง ๆ เช่น โปรตุเกสได้นำไปปลูกในอินโดนีเซีย และสเปนได้นำไปปลูกในฟิลิปปินส์ ส่วนอังกฤษเผยแพร่โดยนักค้าทาสชาวอังกฤษ ซึ่งกวาดต้อนทาสในแอฟริกา ได้นำพันธุ์มันสำปะหลัง ไปปลูกในประเทศที่ตนเองมีอิทธิพล เช่น ไนจีเรีย และในเอเชีย เช่น อินเดีย ชาวอังกฤษเรียกต้นและ หัวมันสำปะหลังว่า Cassava และเรียกผลิตภัณฑ์ได้จากการแปรรูปหัวมันสำปะหลังว่า Tapioca

ชาวโปรตุเกสได้นำมันสำปะหลังไปอินโดนีเซียเป็นครั้งแรก แต่เมื่ออิทธิพลของ โปรตุเกสเสื่อมลงชาวฮอลันดาได้เข้ามาครอบครองเกาะชวาแทน มันสำปะหลังจึงได้ชื่อตามแหล่งที่ ปลูกในท้องถิ่นภาษาชวาว่า Sampeu หรือ Sampore ชาวอินโดนีเซียจึงได้อาศัยมันสำปะหลังเป็นพืช อาหารประจำวันเช่นเดียวกับประเทศในแถบแอฟริกา

มันสำปะหลังที่แพร่ไปยังประเทศต่าง ๆ ได้กลายเป็นอาหารหลักของประชากร โดยตรง อาทิ ประเทศในแถบอเมริกาใต้ ไนจีเรีย และประเทศในแถบแอฟริกา แม้แต่ในอินโดนีเซีย ต่อมามันสำปะหลังจากเกาะชวาได้แพร่หลายเข้ามาสู่แหลมมลายู เข้าสู่ประเทศไทยตอนใต้ในช่วงก่อน สงครามโลกครั้งที่ 2 มันสำปะหลังในขณะนั้นแบ่งเป็น 2 ชนิดคือ ชนิดขม ใช้ทำแป้งมัน (Starch) และ สาคุ และชนิดหวานใช้บริโภคโดยตรง เช่น ต้ม ปิ้ง เป็นต้น

เนื่องจากประเทศไทยมีธัญญาหารที่อุดมสมบูรณ์ พืชหัวเช่นมันสำปะหลัง และเผือก จึงไม่เป็นที่นิยมบริโภคโดยตรง แต่ใช้ทำเป็นของหวาน หรือแปรรูปเป็นผลิตภัณฑ์ของใช้ เช่น กาวเพื่อ พับดูกระดาษหนังสือพิมพ์ เมื่อถึงช่วงสงครามโลกครั้งที่ 2 เกิดภาวะขาดแคลนข้าวในประเทศ จึงมี การปลูกมันสำปะหลังในครัวเรือนเป็นแปลงขนาดเล็กมากขึ้น เพื่อนำไปผสมกับข้าวเพื่อบริโภคใน ชีวิตประจำวัน แต่เมื่อสถานการณ์เข้าสู่สภาวะปกติมันสำปะหลังจึงไม่เป็นที่นิยมบริโภค นอกจากใช้ทำ ของหวาน และถูกมองว่าเป็นพืชชั้นต่ำ มีคุณค่าทางโภชนาการน้อย ผู้ยากไร้เท่านั้นที่จะกินเผือกกับ มันสำปะหลัง เพราะแม้แต่หมูยังถูกเลี้ยงด้วยรำข้าว

ในช่วงก่อนสงครามโลกครั้งที่ 2 มันสำปะหลังขยายตัวจากภาคใต้สู่ภาคตะวันออกใน แถบจังหวัดชลบุรี และระยอง ที่มีสภาพภูมิอากาศคล้ายกันและมีพื้นที่ว่างเปล่าจากการตัดไม้ไปใช้ใน อุตสาหกรรมพบว่าสามารถปลูกได้ดี การทำไร่มันสำปะหลังเป็นเกษตรอุตสาหกรรมจึงได้เริ่มต้นขึ้น เพื่อการผลิตแป้งมันดิบใช้ในประเทศทดแทนการนำเข้าจากอินโดนีเซีย

เมื่อมีผู้นำมันสำปะหลังไปสับเป็นชิ้นๆ ตากแห้ง เรียกว่า มันเส้น (Chip) สามารถ นำไปเลี้ยงสัตว์ จึงมีการริเริ่มทดลองนำมันเส้นไปเลี้ยงหมูในยุโรป ผสมกับพืชชนิดอื่นที่มีโปรตีนสูง

เช่น กากถั่วเหลือง พบว่ามีคุณค่าทางอาหารสูงเท่าเทียมข้าวโพดแต่ราคาถูกกว่า มันสำปะหลังจึงเป็นสินค้าส่งออกไปในประชาคมยุโรปเพื่อทดแทนธัญพืช และทำให้การปลูกมันสำปะหลังได้ขยายตัวออกสู่ภาคตะวันออกเฉียงเหนือ (กรมวิชาการเกษตร, 2547)

เนื่องจากประเทศในแถบแอฟริกาไม่สามารถจะส่งออกมันสำปะหลังได้เนื่องจากใช้บริโภคในประเทศจนหมด ประเทศไทยซึ่งประชาชนไม่นิยมบริโภคมันสำปะหลังจึงมีศักยภาพในการส่งออกเพื่อเป็นสิ่งที่ทดแทนธัญพืชผสมในอาหารสัตว์ในรูปของมันเส้น ตั้งแต่ พ.ศ. 2500 เป็นต้นมา จนถึงปี พ.ศ. 2530 ตัวเลขการส่งออกมันสำปะหลังเพิ่มขึ้นจากหลักแสนตันสู่ล้านตัน และการปลูกได้ขยายตัวอย่างมาก จากภาคใต้ สู่ภาคตะวันออก และภาคตะวันออกเฉียงเหนือตามลำดับ การส่งออกมันเส้น (Chip) และมันเม็ด (Pellet) ที่เกิดจากการนำมันเส้นไปอัดเป็นแท่งสั้น ๆ คล้ายแท่งซอส์ ต่อมาได้กลายเป็นมันอัดเม็ดแข็ง (Hard Pellet) เพื่อมิให้แตกหักปนเป็นฝุ่นระหว่างการขนถ่าย ลดมลภาวะที่ทำเรือ และประหยัดการขนส่ง

ผู้ส่งออกได้พัฒนาระบบการขนส่งทางบก ทางน้ำ และทางทะเลอย่างรวดเร็ว ทำให้สามารถส่งออกสินค้ามันสำปะหลังได้คราวละแสนตัน ระบบการลำเลียงสินค้าจากภาคตะวันออกเฉียงเหนือลงสู่ภาคกลาง สู่ท่าเรือเกาะสีชังในจังหวัดชลบุรี เพื่อลงเรือขนาดใหญ่ขนส่งไปยังเมืองท่ารอตเตอร์ดัมของเนเธอร์แลนด์ ทำให้ประเทศไทยก้าวสู่การเป็นผู้ส่งออกอันดับ 1 ของโลก ครองตลาดกว่าร้อยละ 90 (มูลนิธิสถาบันมันสำปะหลังแห่งประเทศไทย, 2560)

จากการส่งออกมันเม็ดไปยังประชาคมยุโรปอย่างรวดเร็ว แต่การจัดการระบบการขนส่งยังไม่ดีเท่าที่ควร ทำให้ราคาผลิตภัณฑ์มันสำปะหลังภายในประเทศ และประชาคมยุโรปผันผวนอย่างรุนแรง ส่งผลกระทบต่อผู้นำเข้า และส่งออก อีกทั้งประชาคมยุโรปได้เปลี่ยนนโยบายการเกษตร โดยส่งเสริมให้มีการปลูกธัญพืชในประชาคมยุโรปได้เสรีมากขึ้น ส่งผลให้ราคาธัญพืชลดลง กระทั่งต่อการปริมาณการส่งออกมันสำปะหลังที่ไทยส่งออกสู่ประชาคมยุโรปเพียงตลาดเดียวจึงลดลง ส่งผลกระทบเป็นวงกว้างต่อภาคเกษตรอุตสาหกรรม


จากวิกฤตการณ์ดังกล่าวจึงมีการปฏิรูปการปลูกและการผลิตในปี พ.ศ. 2535 โดยกำหนดนโยบายในการพัฒนาปรับปรุงพันธุ์ การแปรรูปผลิตภัณฑ์ให้หลากหลาย การลดต้นทุนการผลิต และพัฒนาผลิตภัณฑ์ที่หลากหลายรูปแบบไปสู่หลายตลาด เช่น จีน เกาหลีใต้ ญี่ปุ่น และได้หวัน เป็นต้น

ปัจจุบันประเทศไทยได้เป็นผู้ผลิตมันสำปะหลังที่สำคัญแห่งหนึ่งของโลก มีลานมันสำหรับผลิตมันเส้นและมันอัดเม็ดมากกว่า 1,000 แห่ง มีโรงงานแป้งมัน (Starch) และมันดัดแปรกว่า 100 โรง ตอบสนองความต้องการของผู้ใช้งานทั่วโลก ครอบคลุมส่วนแบ่งทางการตลาดของโลกมากกว่าร้อยละ 72 อุตสาหกรรมมันสำปะหลังในประเทศไทย มีการแปรรูปเป็นผลิตภัณฑ์หลัก 3 แบบ คือ


1) มันเส้น เป็นการแปรรูปหัวมันสำปะหลังสดขั้นแรก โดยตัดหัวมันเป็นชิ้นเล็กนำไปตากแห้ง ส่งขายเป็นวัตถุดิบอาหารสัตว์ และผลิตเอทานอล

2) มันอัดเม็ด พัฒนาจากการนำมันเส้นไปอัดด้วยความร้อนเป็นเม็ดหนา 2-3 เซนติเมตร เส้นผ่านศูนย์กลาง 1 เซนติเมตร ความชื้น 14% สะดวกต่อการส่งออกไปยังต่างประเทศ และเพื่อเป็นส่วนผสมในอาหารสัตว์

3) แป้งมันสำปะหลัง โดยไทยผลิตแป้งมันคุณภาพสูงได้มากที่สุดเนื้อแป้งมีสีขาวและมันขาวแบ่งออกเป็น แป้งธรรมชาติ (Native starch) และแป้งดัดแปร (Modified starch) ที่มีคุณสมบัติต่างจากแป้งธรรมชาติ โดยใช้กรรมวิธีทางเคมีเพื่อปรับโครงสร้างภายในให้มีขอบเขตการใช้งานที่กว้างขึ้น เฉพาะเจาะจงขึ้น นอกจากนี้ มันสำปะหลังยังถูกนำไปใช้เป็นส่วนประกอบในผลิตภัณฑ์ต่าง ๆ ได้แก่ สารให้ความข้นหนืด สารให้ความคงตัว ผงชูรส สารเคลือบเส้นด้าย กระดาษ กาว ไม้อัดพลาสติกชีวภาพ และเอทานอล



รูปที่ 2.2 ปริมาณการส่งออกผลิตภัณฑ์มันสำปะหลังระหว่างปี ค.ศ. 2000–2021 (พ.ศ. 2543-2564)
(ชัยวัช โสวเจริญกรุง, 2565)



รูปที่ 2.3 ปริมาณการส่งออกและนำเข้าผลผลิตมันสำปะหลังปี พ.ศ. 2564
(ชัยวัช โสวเจริญกรุง, 2565)

2.1.2 การปรับตัวต่อสภาพแวดล้อมของมันสำปะหลัง

มันสำปะหลังเป็นพืชที่ปลูกในเขตร้อนน ตั้งแต่เส้นรุ้งที่ 30 องศาใต้ ถึงเส้นรุ้งที่ 30 องศาเหนือ ในเขตหนาวและเขตอบอุ่นมันสำปะหลังจะไม่สามารถขึ้นได้ ในเขตร้อนการปลูกมันสำปะหลังสามารถทำได้ในสภาพอากาศที่แตกต่างกันอย่างกว้างขวางคือ ขึ้นได้ดีในสภาพที่มีฝนตกชุก ในดินที่มีความอุดมสมบูรณ์ต่ำ และเป็นกรด ในพื้นที่แห้งแล้งแถบแอฟริกา หรือในเทือกเขาแอนดิสที่มีความสูง 2,000 เมตร เหนือระดับน้ำทะเลในทวีปอเมริกาใต้

โดยทั่วไปพื้นที่ปลูกมันสำปะหลังส่วนใหญ่มีปริมาณน้ำฝนเฉลี่ยต่อปีมากกว่า 1,000 มิลลิเมตร และสามารถปรับตัวได้ดีในเขตเขตที่มีฝนตกอยู่ในช่วง 1,000-1,300 มิลลิเมตรต่อปี ในพื้นที่ฝนตกชุกควรมีการระบายน้ำที่ดี เนื่องจากมีโอกาสเกิดความเสียหายได้หากเกิดน้ำท่วม นอกจากนี้มันสำปะหลังยังเป็นพืชที่ทนแล้งได้ดี สามารถทนแล้งได้ยาวนานถึง 6 เดือนต่อปี โดยจะมีการทิ้งใบ และสร้างใบใหม่ที่มีขนาดเล็ก ปากใบบางส่วนจะปิดทำให้ลดการคายน้ำ มันสำปะหลังสามารถเติบโตได้ดีในบางพื้นที่ที่มีปริมาณน้ำฝนน้อยกว่า 1,000 มิลลิเมตร เช่น ประเทศบราซิล และในทวีปแอฟริกา แต่มันสำปะหลังจะไม่สามารถขึ้นได้ในสภาวะอากาศที่มีปริมาณน้ำฝนต่ำกว่า 600 มิลลิเมตร

มันสำปะหลังสามารถปรับตัวในสภาวะที่ดินเป็นกรดจัดได้ถึง pH 4.4 โดยไม่กระทบต่อผลผลิต แต่ไม่สามารถทนต่อความเป็นด่างได้มากกว่า pH 8 และไม่ทนต่อสภาวะดินที่มีน้ำขัง มันสำปะหลังโตได้ดีในสภาวะดินร่วนปนทราย มีความอุดมสมบูรณ์ปานกลาง มี pH 5.5-8 เป็นพืชวันสั้น ผลผลิตจะลดลงถ้าช่วงแสงของวันมากกว่า 10-12 ชั่วโมง

ประเทศไทยปลูกมันสำปะหลังได้ในทุกพื้นที่ แหล่งที่ปลูกมันสำปะหลังมากที่สุด คือ ภาคตะวันออกเฉียงเหนือ และภาคตะวันออก ซึ่งมีปริมาณน้ำฝนเฉลี่ย 1,200-1,500 มิลลิเมตรต่อปี และความสูง 0 - 200 เมตร จากระดับน้ำทะเล จังหวัดที่ปลูกมากที่สุด ได้แก่ นครราชสีมา ชัยภูมิ กำแพงเพชร และกาญจนบุรีตามลำดับ (กระทรวงเกษตรและสหกรณ์, สำนักงานเศรษฐกิจการเกษตร, 2566)

2.1.3 พันธุ์มันสำปะหลัง

มันสำปะหลังที่เผยแพร่เข้าสู่ภาคใต้ของไทยเป็นพันธุ์พื้นเมืองมีผลผลิตที่ต่ำ ได้ผลผลิตโดยเฉลี่ย 2.2 ตัน/ไร่ มีปริมาณแป้งในหัวมันสดเพียงร้อยละ 18 และผลผลิตใช้เวลา 9-10 เดือน ทำให้โรงงานต้องหยุดการผลิตถึง 4 เดือน ต้นทุนในการแปรรูปเป็นแป้งจึงสูง จากยุทธศาสตร์การปฏิรูปการเพาะปลูกทำให้มีการปรับปรุงพันธุ์พืชให้ได้สายพันธุ์ที่มีผลผลิตต่อไร่สูง มีเชื้อแป้งสูง และทนทานต่อโรค โดยสถาบันหลักที่พัฒนาพันธุ์มี 2 รายคือ กรมวิชาการเกษตร พัฒนาพันธุ์ที่ใช้ชื่อสายพันธุ์ (Series Name) ว่า ระยอง (Rayong) หรือ R และมหาวิทยาลัยเกษตรศาสตร์ ภาควิชาพืชไร่นา คณะเกษตร พัฒนาพันธุ์ที่ใช้ชื่อสายพันธุ์ (Series Name) ว่า เกษตรศาสตร์ (Kasetsart) หรือ KU และห้วยบง (Huay Bong) หรือ HB โดยสายพันธุ์ที่นิยมปลูกในประเทศไทย มีดังนี้

2.1.3.1 พันธุ์ระยอง 9 มีลักษณะลำต้นสีน้ำตาลอมเหลือง ไม่ค่อยแตกกิ่ง เหมาะสมกับการปลูกปลายฤดูฝน มีศักยภาพในการให้ผลผลิตสูง แต่สะสมน้ำหนักช้า หากเก็บเกี่ยวเร็วจะให้ผลผลิตต่ำควรเก็บเกี่ยวเมื่ออายุ 12 เดือน

2.1.3.2 พันธุ์ระยอง 11 มีลักษณะยอดอ่อนสีน้ำตาลอมเขียว ไม่ค่อยแตกกิ่ง เปลือกหัวสีน้ำตาล มีปริมาณแป้งสูง มีข้อจำกัดที่ควรเก็บเกี่ยวเมื่ออายุ 12 เดือนเนื่องจากการสะสมน้ำหนักช้า และผลผลิตมีความผันแปรในแต่ละภาค

2.1.3.3 พันธุ์ระยอง 60 เป็นพันธุ์ที่สะสมน้ำหนักเร็ว เหมาะกับเกษตรกรที่ต้องการเก็บเกี่ยวอายุต่ำกว่า 12 เดือน มีข้อจำกัดคือ หากเก็บเกี่ยวในฤดูฝน จะได้เชื้อแป้งต่ำ เนื้อมีสีครีม ให้ผลผลิตไม่สูง การปลูกในภาคตะวันออกให้ผลผลิตสูงกว่าภาคอื่น

2.1.3.4 พันธุ์ระยอง 90 มีลักษณะลำต้นโค้ง สีน้ำตาลอ่อน เชื้อแป้งยังสูงเมื่อเก็บเกี่ยวในฤดูฝน มีข้อจำกัดคือ ไม่เหมาะกับพื้นที่ที่มีแมลงหวี่ขาวระบาด ต้นพันธุ์เสื่อมคุณภาพเร็วให้ผลผลิตไม่สูงนัก การปลูกในภาคตะวันออกให้ผลผลิตสูงกว่าภาคอื่น

2.1.3.5 พันธุ์ระยอง 72 มีลักษณะก้านใบสีแดงเข้ม ลำต้นสีเขียวเงิน แตกกิ่งข้างเล็กน้อย ท่อนพันธุ์มีความอยู่รอดถึงช่วงเก็บเกี่ยวสูง ปรับตัวได้ดีในสภาพแวดล้อมทางภาคตะวันออกเฉียงเหนือ และภาคตะวันออก แต่ไม่ควรเก็บเกี่ยวในฤดูฝน เพราะอาจทำให้มีเชื้อแป้งต่ำ

2.1.3.6 พันธุ์ห้วยบง 60 มีลักษณะแตกกิ่งมาก ลำต้นสีเขียวเงิน ก้านใบสีเขียวอมม่วง ยอดมีสีม่วงอ่อน มีความต้านทานโรคใบจุดปานกลาง ควรเก็บเกี่ยวเมื่ออายุไม่น้อยกว่า 10 เดือน

2.1.3.7 พันธุ์ห้วยบง 80 มีลักษณะยอดอ่อนสีเขียวอ่อน ทรงต้นสูงแตกกิ่งน้อย ควรเก็บเกี่ยวเมื่ออายุไม่น้อยกว่า 10 เดือน

2.1.3.8 พันธุ์เกษตรศาสตร์ 50 ลำต้นโค้งเล็กน้อย สีเขียวเงิน ยอดอ่อนสีม่วงและไม่มีขนอ่อน มีเสถียรภาพและปรับตัวเข้ากับสภาพแวดล้อมได้ดี มีปริมาณเชื้อแป้งสูง ท่อนพันธุ์มีความงอกดี และเก็บรักษาได้นาน

สำหรับข้อมูลความนิยมในการปลูกพบว่าการรวมรวมล่าสุดในปี 2563 กระทรวงเกษตรและสหกรณ์, สำนักงานเศรษฐกิจการเกษตร (2564) ได้รับรวมสถิติจำนวนเนื้อที่เพาะปลูกพื้นที่เก็บเกี่ยว จำแนกตามพันธุ์มันสำปะหลังโรงงาน แสดงได้ในตารางที่ 2.1

ตารางที่ 2.1 เนื้อที่เพาะปลูก เนื้อที่เก็บเกี่ยวจำแนกตามพันธุ์มันสำปะหลังปี พ.ศ.2563⁽¹⁾

พันธุ์	เนื้อที่เพาะปลูก (ตร.กม.)	เนื้อที่เก็บเกี่ยว (ตร.กม.)	ผลผลิต (ตัน)
ระยอง 5	1,905,613	1,853,189	3,583,331
ระยอง 9	283,984	279,883	598,081
ระยอง 11	698,602	676,750	1,329,009
ระยอง 72	208,7162	1,964,190	4,115,312
ระยอง 90	186,998	185,728	367,841
ห้วยบง 60	449,894	428,826	914,663
ห้วยบง 80	676,491	656,205	1,314,723

ตารางที่ 2.1 เนื้อที่เพาะปลูก เนื้อที่เก็บเกี่ยวจำแนกตามพันธุ์มันสำปะหลังปี พ.ศ.2563⁽¹⁾ (ต่อ)

พันธุ์	เนื้อที่เพาะปลูก (ตร.กม.)	เนื้อที่เก็บเกี่ยว (ตร.กม.)	ผลผลิต (ตัน)
เกษตรศาสตร์ 50	4,631,197	4,353,962	8,663,254
อื่นๆ	4,182,474	3,870,467	8,112,908
รวมทั้งประเทศ	15,102,414	14,269,200	28,999,122

หมายเหตุ จาก กระทรวงเกษตรและสหกรณ์, สำนักงานเศรษฐกิจการเกษตร, 2564

2.1.4 การเจริญเติบโตของมันสำปะหลัง

ระยะการเจริญเติบโตของมันสำปะหลังแบ่งเป็น 5 ระยะดังนี้ ในช่วง 2 – 3 สัปดาห์หลังปลูกคือระยะที่ 1 ระยะถอนพันธุ์ออกและตั้งตัว ช่วง 2 เดือนหลังปลูกคือ ระยะที่ 2 ระยะพัฒนาทรงพุ่ม เป็นระยะที่มีการแตกกิ่งและสร้างใบ ช่วง 3 เดือนหลังปลูกเป็นต้นไปคือ ระยะที่ 3 ระยะพัฒนารากและสะสมอาหาร มีการสะสมแป้งที่หัวมันสำปะหลัง ช่วงหลังจากเดือนที่ 14 คือ ระยะที่ 4 ระยะพักตัว มันสำปะหลังจะหยุดการเจริญเติบโตและทิ้งใบ และระยะที่ 5 ระยะฟื้นตัว มันสำปะหลังจะนำอาหารจากหัวมาสร้างใบใหม่ ดังนั้น เกษตรกรควรเก็บเกี่ยวในช่วงอายุ 8 – 14 เดือนหลังปลูกหรือก่อนถึงระยะที่ 4 (ดวงกมล เดชดอน, 2562)

2.1.5 การปลูกและอารักขาพืช

2.1.5.1 ช่วงเวลาที่เหมาะสมในการปลูกมันสำปะหลัง

ช่วงเวลาที่เหมาะสมในการปลูกแบ่งออกเป็น 3 ช่วง คือ ปลูกในช่วงก่อนฤดูฝน (กุมภาพันธ์ – เมษายน) ปลูกในช่วงฤดูฝน (พฤษภาคม – ตุลาคม) และปลูกในช่วงหลังฤดูฝน (พฤศจิกายน – เมษายน) พบว่าการปลูกในช่วงฤดูฝนได้ผลผลิตมากที่สุด รองลงมาคือก่อนฤดูฝน และหลังฤดูฝนตามลำดับ สำหรับการปลูกมันสำปะหลังพันธุ์ระยะยง 1 ระยะยง 3 ระยะยง 60 ระยะยง 72 และระยะยง 90 สามารถปลูกได้ตลอดปี ช่วงเวลาที่เหมาะสมที่สุดคือช่วงเดือนมิถุนายน - พฤศจิกายน

2.1.5.2 การเตรียมดิน

ควรไถพรวนให้ลึก 8-12 นิ้ว โดยไถกลบเศษเหลือของพืช เช่น ลำต้น เหง้าใบ และยอด ของมันสำปะหลังที่เหลือจากการเก็บเกี่ยว ไม่ควรเผาหรือนำออกจากพื้นที่ เพราะจะทำให้ธาตุอาหารสูญหายไปจำนวนมาก กรมวิชาการเกษตร (2547) แนะนำเกษตรกรให้เตรียมดินด้วยวิธีการไถ 2 ครั้ง ด้วยพล 3 (เหล็กสวมเครื่องไถ เพื่อนำดินข้างล่างให้ขึ้นมาอยู่ข้างบน หมายเลขคือจำนวนเหล็กที่อยู่ในชุดพล) และพรวนด้วยพล 7 (รูปที่ 2.4) หากปลูกในพื้นที่ลาดเอียงควรไถขวางทิศทางของความลาดเอียง เพื่อลดการสูญเสียหน้าดิน และถ้าพื้นที่ปลูกเป็นที่มีน้ำขัง ควรทำท่อระบายน้ำ และยกร่องปลูก



รูปที่ 2.4 (a) การไถด้วยพาล 3 และ (b) พรวนด้วยพาล 7

2.1.5.3 วิธีการปลูก และระยะปลูก

วิธีการปลูกมันสำปะหลังปลูกโดยใช้ท่อนพันธุ์ วิธีการปลูกคือปลูกแบบปักท่อนพันธุ์บนสันร่อง ไม่ควรปักลึกกว่า 10 เซนติเมตร เนื่องจากจะทำให้ยากต่อการเก็บเกี่ยว การปลูกบนพื้นราบให้ใช้เชือกทำเครื่องหมายบอกระยะและเป็นแนวในการปลูก จะทำให้ระยะปลูกถูกต้องและสม่ำเสมอ

ระยะปลูกมันสำปะหลัง โดยทั่วไปเกษตรกรใช้ระยะปลูก 70-100 เซนติเมตร ระยะหลุม 50-100 เซนติเมตร ส่วนใหญ่ใช้ระยะปลูก 100 x 100 100 x 80 และ 100 x 66 เซนติเมตร โดยมีจำนวนต้น 1,600 2,000 และ 2,400 ต้นต่อไร่ ตามลำดับ (กรมวิชาการเกษตร, 2547) แต่สำหรับมันสำปะหลังที่มีการให้น้ำในระบบน้ำหยดจะมีระยะระหว่างแถวที่ 120 – 150 เซนติเมตร และระยะระหว่างต้นที่ 80 – 120 เซนติเมตร (สุดชล วุ่นประเสริฐ, ฐิติพร มะชีโกวา, ธีระศักดิ์ ทองอบ และวรุณยุพา เชื้อมตะคุ, ม.ป.ป.)

2.1.5.4 การคัดเลือกท่อนพันธุ์

ขนาดท่อนพันธุ์ที่เหมาะสมในการปลูก (รูปที่ 2.5) ควรมีความยาว 15-20 เซนติเมตร โดยตัดจากส่วนกลาง และโคนของลำต้น ท่อนพันธุ์ที่ใช้ควรมีอายุตั้งแต่ 8 เดือนขึ้นไป ไม่ควรเกิน 18 เดือน ควรเลือกท่อนพันธุ์ที่สะอาดปราศจากการถูกทำลายจากโรคและแมลง



รูปที่ 2.5 ลักษณะของท่อนพันธุ์มันสำปะหลัง

2.1.5.5 ดินที่เหมาะสมในการปลูก

โดยทั่วไปมันสำปะหลังขึ้นได้ในดินที่มีเนื้อดินหยาบจนถึงดินเหนียว มีค่าความเป็นกรดต่างตั้งแต่ pH 4.4-8.0 และในดินที่มีความอุดมสมบูรณ์ต่ำจนถึงสูง โดยดินที่มีความเหมาะสมในการปลูกมันสำปะหลังที่สุด คือ ดินร่วนปนทรายจนถึงดินร่วนเหนียวปนทรายเพราะสามารถระบายน้ำได้ดี มีค่า pH 5.0-7.0 หน้าดินลึกตั้งแต่ 50 เซนติเมตรเป็นต้นไป

ควรใส่ปุ๋ย 2 ครั้ง ครั้งแรกเป็นปุ๋ยสูตร 15-15-15 อัตรา 50 กิโลกรัมต่อไร่ หลังจากปลูกประมาณ 1 เดือน โดยใส่ข้างต้นแล้วพรวนดินกลับ ครั้งที่สองใส่ปุ๋ยยูเรียและโพแทสเซียมคลอไรด์อย่างละ 15 กิโลกรัมต่อไร่ เมื่อมันสำปะหลังอายุ 3-4 เดือน การใส่ปุ๋ยดินจะต้องมีความชื้นพอเพียง

2.1.5.6 การควบคุมวัชพืช

การควบคุมวัชพืชในแปลงมันสำปะหลังในช่วงแรกควรปฏิบัติและดูแลเป็นพิเศษ เพราะวัชพืชจะทำให้มันสำปะหลังชะงักการเจริญเติบโต เจริญเติบโตช้า ในประเทศไทยต้นทุนการกำจัดวัชพืชคิดเป็นร้อยละ 20 ของต้นทุนการผลิต ควรกำจัดวัชพืช 2 ครั้ง คือ ขณะที่ต้นมันสำปะหลังมีอายุ 30 วันและ 60 วัน วิธีการกำจัดวัชพืชมีหลากหลายวิธี อาทิ การใช้แรงงานคน การใช้วิธีเขตกรรมหรือวิธีกล เช่น การไถกลบ และการควบคุมด้วยสารกำจัดวัชพืช เช่น ไดยูรอน, พาราควอต และไกลโฟเสท เป็นต้น (กรมวิชาการเกษตร, 2547)

2.1.5.7 โรค แมลง และศัตรูพืชของมันสำปะหลัง

โรคของมันสำปะหลังเกิดจากเชื้อรา แบคทีเรีย ไวรัส และไมโครพลาสมา ที่มักจะพบในแปลงมันสำปะหลัง ได้แก่ โรคใบไหม้ โรคใบจุดสีน้ำตาล โรคใบจุดไหม้จากเชื้อรา โรคแอนแทรคโนส โรคราสนิม โรครากหัวเน่า และโรคใบด่างที่เกิดจากเชื้อไวรัส เป็นต้น

การป้องกันกำจัดโรคทำได้โดยวิธีดังต่อไปนี้ (1) การกักกันพืช โดยระมัดระวังการนำเข้าส่วนของพืชที่นำเข้าจากต่างประเทศ (2) วิธีเขตกรรม ได้แก่ การปลูกพืช

หมุนเวียน การทำลายส่วนของพืชที่เป็นโรค การใช้ท่อนพันธุ์ที่สะอาดปราศจากโรค (3) การใช้สารเคมีกำจัดเชื้อโรคที่อาจติดมากับท่อนพันธุ์ (4) การเลือกใช้พันธุ์ที่ต้านทานโรค

แมลงและศัตรูพืชของมันสำปะหลัง แบ่งออกเป็น 2 ชนิด คือ (1) ประเภทปากดูด ได้แก่ ไรแดง เพลี้ยแป้ง แมลงหวี่ขาว และเพลี้ยหอยขาว โดยทำความเสียหายจากการดูดกินน้ำเลี้ยงจากส่วนต่าง ๆ ของพืช ส่งผลต่อการงอก การเจริญเติบโต และการสร้างหัวของมันสำปะหลัง (2) ชนิดปากกัด ได้แก่ ปลวก แมลงนูนหลวง และด้วงหนวดยาว ทำความเสียหายโดยการกัดกินทำลายท่อนพันธุ์ ราก ลำต้น และหัวมันสำปะหลัง

การป้องกันและกำจัดแมลงศัตรูพืชทำได้โดยวิธีการต่างๆ ดังนี้ (1) วิธีเขตกรรม ได้แก่ การไถพรวนหลายครั้งเพื่อตากดิน การเก็บศัตรูพืชด้วยมือ การเก็บซากเศษพืชไปเผาทำลาย (2) การใช้ศัตรูตามธรรมชาติเพื่อควบคุมปริมาณศัตรูพืช (3) การใช้สารฆ่าแมลงและไร (4) การกักกันพืชจากการนำเข้าชิ้นส่วนของพืชจากต่างประเทศ



รูปที่ 2.6 แมลงหวี่ขาว

2.1.5.8 ระบบการให้น้ำมันสำปะหลัง

ระบบการให้น้ำมีหลากหลายวิธี ได้แก่ การให้น้ำตามร่อง ระบบให้น้ำแบบฝอย (Sprinkler) และระบบน้ำหยดโดยเป็นระบบที่เหมาะสมที่สุดกับการให้น้ำสำหรับการปลูกมันสำปะหลัง มีข้อดีคือ ประหยัดน้ำมากกว่าวิธีอื่น มีประสิทธิภาพในการให้น้ำสูงที่สุด สามารถละลายปุ๋ยและสารเคมีทางการเกษตรไปกับระบบให้น้ำได้ ประหยัดต้นทุนและได้ผลคุ้มค่าในระยะยาว และช่วยลดการระบาดของศัตรูพืชบางชนิดได้ดี (สุดชล วุ่นประเสริฐ และคณะ, ม.ป.ป.)

การให้น้ำในปริมาณที่ถูกต้องต้องคำนึงถึงช่วงอายุ และความต้องการน้ำในตลอดฤดูกาลปลูก โดยความถี่ในการให้น้ำมันสำปะหลังขึ้นอยู่กับความต้องการน้ำ และความสามารถ

ในการอุ้มน้ำของดิน การให้น้ำควรให้ครั้งแรกหลังปลูกทันที จากนั้นจึงให้ตามความต้องการของมันสำปะหลังโดยพิจารณาจากสภาพอากาศและอายุของต้น และเมื่อมันสำปะหลังมีอายุ 4-5 เดือนหลังปลูกจะมีความต้องการน้ำที่สูง จากนั้นจะหมดความต้องการน้ำในช่วง 10 เดือนหลังปลูกเป็นต้นไป

2.1.6 การเก็บเกี่ยวมันสำปะหลัง

มันสำปะหลังจะเริ่มมีหัวเมื่ออายุตั้งแต่ 3 เดือนขึ้นไป หัวจะเจริญเติบโตโดยการสะสมแป้ง และหลังจาก 6 เดือนแป้งในหัวจะไม่เปลี่ยนแปลงมากนักแต่น้ำหนักหัวมันสดจะเพิ่มขึ้น อายุการเก็บเกี่ยวมันสำปะหลัง ตั้งแต่ 8 - 12 เดือน โดยสามารถยืดอายุเก็บเกี่ยวได้มากกว่า 12 เดือน พบว่าหัวมันสำปะหลังจะมีขนาดใหญ่ยิ่งขึ้น แต่จะมีเส้นใยมากจึงไม่เป็นที่ต้องการของตลาด และทำให้การปลูกรุ่นต่อไปไม่ตรงกับฤดูกาลที่เหมาะสม

ฤดูกาลเก็บเกี่ยวที่เหมาะสมคือช่วงฤดูแล้งไม่มีฝนตก ในช่วงเดือนพฤศจิกายน - เมษายน โดยพบว่ามิผลให้ได้หัวมันสำปะหลังสดที่มีเชื้อแป้งสูงกว่าการเก็บเกี่ยวในช่วงที่มีฝนตกชุก วิธีการเก็บเกี่ยวส่วนใหญ่จะใช้แรงงานคนในการขุด โดยจะตัดต้นมันออกให้เหลือตอยาวประมาณ 30 - 50 เซนติเมตร โดยใช้จอบขุด เครื่องขุดหรือผานขุด (รูปที่ 2.7) จากนั้นจึงตัดหัวมันออกจากเหง้า แล้วขนผลผลิตสู่โรงงาน




รูปที่ 2.7 เครื่องขุดมันสำปะหลัง หรือผานขุดมัน

2.1.7 การวัดปริมาณแป้งในหัวมันสำปะหลังสด

ปริมาณแป้ง หรือเปอร์เซ็นต์แป้งในหัวมันสำปะหลังสด ถูกใช้เป็นเกณฑ์ในการกำหนดราคาซื้อขาย ณ จุดรับซื้อหน้าโรงงานและลานรับซื้อ เครื่องมือที่ใช้วัดในปัจจุบัน คือ เครื่องวัดปริมาณของแป้งในหัวมันสำปะหลังสดแบบ Reimann (Reimann scale balance) ซึ่งใช้การวัดค่าความถ่วงจำเพาะของหัวมันสำปะหลังสดจากการชั่งน้ำหนักในอากาศ และในน้ำ แล้วแปลงเป็นค่าปริมาณแป้งมันสำปะหลังด้วยการใช้หลักการของ Reimann scale การตรวจวัดด้วยเครื่องดังกล่าวใช้

ปริมาณตัวอย่างหัวมันสำปะหลังครั้งละ 5 กิโลกรัมต่อ 1 ตัวอย่าง ความแม่นยำในการประเมินปริมาณแป้งในหัวมันสามารถเพิ่มขึ้นได้จากการสุ่มเก็บตัวอย่างหลายตำแหน่ง และหลายครั้ง เช่น การเก็บตัวอย่าง ณ จุดรับซื้อหน้าโรงงาน 5 ตำแหน่ง และลานรับหัวมัน 3 ตำแหน่ง



รูปที่ 2.8 Reimann scale balance

การวัดปริมาณแป้งในหัวมันสำปะหลังสด จากตัวอย่างที่เก็บจากแปลงทำได้โดยนำตัวอย่างหัวมันสำปะหลังสดจำนวน 5 กิโลกรัม มาชั่งน้ำหนักบนตะกร้าด้านบน (รูปที่ 2.8) จากนั้นปรับน้ำหนักถ่วงบนสเกลด้านล่างของคันเพื่อให้คันสมดุล โดยสังเกตจากแท่งวัดระดับบริเวณด้านตรงข้ามกับตะกร้า เมื่อคันสมดุลแล้วให้นำหัวมันสำปะหลังสดเทลงในตะกร้าใบด้านล่าง ซึ่งอยู่ภายในถังที่บรรจุน้ำไว้จนเต็ม จากนั้นปรับน้ำหนักถ่วงที่สเกลด้านบนของคันเพื่อระบุดัชนีส่วนร้อยละของแป้งในหัวมันสำปะหลังตัวอย่างที่นำมาทำการวัดค่า (กรมส่งเสริมอุตสาหกรรม, สำนักพัฒนาการจัดการอุตสาหกรรม, 2559)


2.2 ทฤษฎีการสุ่มวัดภายในแปลง

การสุ่มตัวอย่างที่ดีจะต้องเป็นตัวแทนของตัวอย่างทั้งหมดในขอบเขตที่ต้องการเก็บข้อมูล โดยอาศัย การสุ่มกระจายตามหลักสถิติ การสุ่มตัวอย่างควรพิจารณาถึงชนิด ลักษณะ ตัวอย่าง และแหล่งที่มาของ ตัวอย่าง เช่น ตัวอย่างจากแปลงปลูก ดิน และน้ำ จากสิ่งแวดล้อมซึ่งจะมีวิธีการที่แตกต่างกัน หลังการสุ่มเก็บตัวอย่างต้องมีการจัดเก็บรักษาตัวอย่างที่ดีก่อนส่งถึงห้องปฏิบัติการ การ

สุ่มเก็บตัวอย่างที่ถูกต้องจะทำให้ได้ข้อมูลที่ถูกต้องชัดเจนเป็นที่ยอมรับ สามารถนำไปใช้ประโยชน์ในการแก้ไขปัญหาในพื้นที่ซึ่งจะทำให้ผลผลิตทางการเกษตรที่มีคุณภาพ (จารุพงศ์ ประสพสุข, 2554)

2.2.1 วิธีการสุ่มตัวอย่างพืช

วิธีการสุ่มตัวอย่างพืชจากแปลงเพาะปลูกสำหรับพื้นที่ขนาดใหญ่ ทำได้โดยเดินสุ่มกระจายเป็นจุด ๆ เว้นช่องว่างให้พอดีและทั่วแปลง โดยเว้นบริเวณขอบแปลง และบริเวณที่พืชมีลักษณะแตกต่างจากบริเวณอื่นภายในแปลงโดยรวมมาก เช่น บริเวณที่เป็นโรค บริเวณที่มีน้ำท่วมขัง เป็นต้น เพื่อให้ได้ข้อมูลที่เป็นตัวแทนของตัวอย่างทั้งหมดในขอบเขตที่กำหนดได้ ดังแสดงในรูปที่ 2.9



รูปที่ 2.9 การสุ่มตัวอย่างพืชแบบกระจายสำหรับพื้นที่ขนาดใหญ่


ตัวอย่างพืชที่ได้จากแปลง เช่น หัวมันสำปะหลังสด ควรนำไปตรวจวัดค่าที่สนใจภายในวันเดียวกันกับที่เก็บตัวอย่าง เพื่อลดโอกาสในการคลาดเคลื่อนของข้อมูลจากการสูญเสียน้ำและปฏิกิริยาทางเคมี

2.2.2 วิธีการเก็บตัวอย่างดิน

การเก็บตัวอย่างดินมีหลักการสำคัญ คือ ตัวอย่างดินที่เก็บจะต้องเป็นตัวแทนที่ถูกต้องของดินในขอบเขตที่ต้องการ โดยมีข้อควรปฏิบัติดังนี้ (1) ไม่เก็บตัวอย่างดินบริเวณจอมปลวก เก็บตัวอย่างดินให้ห่างจากบ้านเรือน อาคารที่อยู่อาศัย คอกสัตว์ และบริเวณที่มีปุ๋ยตกค้าง (2) อุปกรณ์และภาชนะต่าง ๆ ที่ใช้ในการเก็บดิน ต้องสะอาด (3) เวลาที่เหมาะสมในการเก็บตัวอย่างดินคือหลังการเก็บเกี่ยว หรือก่อนปลูกพืชประมาณ 1-2 เดือน โดยเก็บในช่วงที่ดินไม่แฉะ หรือแห้งจนเกินไป

อุปกรณ์ในการเก็บตัวอย่างดิน มีดังนี้ (1) จอบ เสียม หลอดเจาะดิน (Soil tube) (2) ส่วนเจาะดิน (Soil auger) (3) ถังพลาสติก สำหรับรวบรวมดินในแต่ละระดับความลึก (4) แผ่นพลาสติก สำหรับคลุมเคล้าดินและผึ่งดิน (5) ถุงพลาสติก สำหรับบรรจุดินเพื่อนำส่งวิเคราะห์


การสุ่มเก็บตัวอย่างให้ทำการสำรวจพื้นที่ แล้วจึงสุ่มเก็บตัวอย่างตามสภาพพื้นที่ภูมิประเทศ สำหรับพื้นที่ปลูกมันสำปะหลังควรเก็บดินที่ระดับความลึก 0-15 และ 15-30 เซนติเมตร โดยพื้นที่ที่มีภูมิประเทศที่ราบเรียบสม่ำเสมอให้เก็บแบบกระจายเป็นระยะสม่ำเสมอทั่วแปลง สำหรับพื้นที่ที่มีภูมิประเทศที่แตกต่าง เช่น มีความลาดเอียงเนื้อดินต่างกัน หรือมีการปลูกพืชต่างชนิดกันก่อนหน้า ให้เก็บแบบแบ่งโซน ดังรูปที่ 2.10



รูปที่ 2.10 แบบแผนวิธีการเก็บตัวอย่างดิน

(a) เก็บแบบกระจาย (b) เก็บแบบแบ่งโซน

ขั้นตอนการเก็บตัวอย่างดินในแปลง มีขั้นตอนดังนี้ (1) กวาดเศษใบไม้และพืชบนดินให้สะอาด (2) ขุดหลุมเป็นตัววี (V) ลึกถึงระดับที่ต้องการขุดครั้งสุดท้ายให้ดินติดพั่วหรือจอบขึ้นมาตลอดความลึก ใช้มีดหรือพั่วมือตัดดินด้านข้างทิ้งไปทั้งสองข้าง ดังรูปที่ 2.11 (2) รวมตัวอย่างดินที่เก็บได้ในถังพลาสติกคลุมเคล้าดินให้เข้ากัน กระจายดินแบ่งออกเป็น 4 ส่วน แยก 2 ส่วนทิ้งไปและคลุมเคล้าอีก 2 ส่วนที่เหลือจากนั้นทำซ้ำให้เหลือตัวอย่างดิน 0.5 กิโลกรัมแล้วนำไปผึ่งแดดให้แห้งในที่ร่ม (3) นำตัวอย่างดินไปวิเคราะห์ได้ที่สถานีพัฒนาที่ดิน สำนักงานวิจัยและพัฒนาเกษตร หรือส่งที่มหาวิทยาลัยใกล้เคียง



รูปที่ 2.11 การขุดเก็บตัวอย่างดิน

การวิเคราะห์ดินก่อนปลูกมีความสำคัญ เนื่องจากการประเมินความอุดมสมบูรณ์ของดิน และเป็นข้อมูลในการจัดการดินและธาตุอาหารได้อย่างมีประสิทธิภาพ รวมทั้งใช้ในการบริหารจัดการน้ำในปริมาณที่เหมาะสมกับพืชที่ปลูกในดินแต่ละชนิด (ยงยุทธ โอสดสภา, 2552)

2.2.3 การสุ่มอย่างง่าย

การสุ่มอย่างง่าย (Simple random sampling) เป็นการสุ่มกลุ่มตัวอย่างจากประชากรที่มีการใช้งานอย่างแพร่หลายกับข้อมูลเชิงปริมาณด้วยเครื่องมือทางการสำรวจ การสุ่มอย่างง่ายจะใช้กับกลุ่มตัวอย่างในประชากรที่มีลักษณะเป็นเนื้อเดียวกัน (Homogeneous) และมีการสุ่มเลือกตัวอย่างในประชากรอย่างสม่ำเสมอ เช่น การสุ่มตัวอย่างพืชภายในแปลงเดียวกันภายในระยะเวลาต่าง ๆ การสุ่มตัวอย่างอย่างง่ายมีข้อดีที่การสุ่มตัวอย่างนี้ปราศจากความโน้มเอียง (Bias) เพื่อให้มั่นใจว่าตัวอย่างที่ได้จะเป็นตัวแทนของประชากรทั้งหมด อย่างไรก็ตามการสุ่มอย่างง่ายไม่เหมาะสมกับตัวอย่างที่มีความแตกต่างกันมาก หรือมีความหลากหลายของชนิดและประเภทในประชากรทั้งหมดที่ศึกษา (Noor, Tajik and Golzar, 2022)

2.3 เทคโนโลยีภูมิสารสนเทศ

ภูมิสารสนเทศศาสตร์ (Geoinformatics) เป็นศาสตร์ที่บูรณาการความรู้ด้านวิทยาศาสตร์และเทคโนโลยี เพื่อแก้ปัญหาเกี่ยวกับภูมิศาสตร์ การทำแผนที่ ธรณีศาสตร์ และสาขาอื่น ๆ ที่เกี่ยวข้องกับการศึกษาพื้นที่บนโลก

ภูมิสารสนเทศศาสตร์ หมายถึงการสร้างแบบจำลอง และวิเคราะห์ข้อมูลเชิงพื้นที่ ที่การพัฒนาฐานข้อมูลเชิงพื้นที่ การออกแบบระบบสารสนเทศ การปฏิสัมพันธ์ระหว่างคนและเทคโนโลยี เครือข่ายทั้งระบบสายและไร้สาย เพื่อใช้ในการประมวลผลและแสดงผลข้อมูลภูมิศาสตร์

เทคโนโลยีภูมิสารสนเทศ (Geoinformation Technologies) หมายถึง การบูรณาการความรู้และเทคโนโลยีทางการรับรู้จากระยะไกล (Remote Sensing) หรือ RS ระบบสารสนเทศภูมิศาสตร์ (Geographic Information System) หรือ GIS และระบบกำหนดตำแหน่งบนพื้นโลกด้วย

ดาวเทียม (Global Navigation Satellite System) หรือ GNSS เพื่อประยุกต์ใช้งานในด้านต่าง ๆ ให้เป็นไปอย่างมีประสิทธิภาพ (สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน) [GISDA], 2018)



รูปที่ 2.12 องค์ประกอบของเทคโนโลยีภูมิสารสนเทศ (GISDA, 2018)

วิทยาการด้านการรับรู้จากระยะไกลเป็นเทคโนโลยีที่สำคัญในการศึกษาองค์ประกอบต่าง ๆ บนพื้นโลกและในชั้นบรรยากาศ เพื่อศึกษาและติดตามการเปลี่ยนแปลงสภาพแวดล้อมทางธรรมชาติได้โดยการเลือกใช้ข้อมูลที่มีความละเอียดของภาพที่หลากหลาย ขึ้นอยู่กับการประยุกต์ใช้ในแต่ละเรื่อง นอกจากนี้ข้อมูลจากการสำรวจจากระยะไกลเป็นข้อมูลที่ได้มาอย่างรวดเร็ว สามารถตอบสนองความต้องการได้อย่างทัน่วงที่

ระบบสารสนเทศภูมิศาสตร์ สามารถจัดการข้อมูลเชิงพื้นที่ วิเคราะห์ข้อมูลและประยุกต์ใช้ในการวางแผนจัดการทรัพยากรธรรมชาติต่าง ๆ ได้อย่างมีประสิทธิภาพ

ระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม สามารถนำมาใช้กำหนดตำแหน่งเชิงพื้นที่ และติดตามการเคลื่อนที่ของคนและสิ่งของได้อย่างรวดเร็วและแม่นยำ เทคโนโลยีภูมิสารสนเทศจึงเป็นวิทยาการที่สำคัญที่หลายหน่วยงานได้นำมาพัฒนาประเทศในหลากหลายด้าน เช่น ทรัพยากรธรรมชาติและสิ่งแวดล้อม เกษตร พังเมือง การจราจรและการขนส่ง ความมั่นคงทางการทหาร ภัยธรรมชาติ และการค้าเชิงธุรกิจผลการวิเคราะห์ด้วยเทคโนโลยีภูมิสารสนเทศสามารถนำมาประกอบการวางแผนการตัดสินใจในเรื่องต่าง ๆ ได้อย่างถูกต้องและรวดเร็ว (GISDA, 2018)

2.3.1 ระบบสารสนเทศภูมิศาสตร์

ระบบสารสนเทศภูมิศาสตร์ (Geographic Information system) หรือ GIS คือ ชุดเครื่องมือ ระบบคอมพิวเตอร์ และโปรแกรม ที่ช่วยเพิ่มประสิทธิภาพในกระบวนการต่าง ๆ สำหรับ

จัดการข้อมูลเชิงพื้นที่ตั้งแต่การเก็บรวบรวมข้อมูล บันทึก คำนวณ สอบถาม เปรียบเทียบ วิเคราะห์และแสดงผลข้อมูล เพื่ออธิบายสิ่งต่าง ๆ ที่ปรากฏบนแผนที่ ระบบสารสนเทศภูมิศาสตร์มีลักษณะคล้ายกับระบบสารสนเทศทั่วไปแต่ต่างกันที่มุ่งเน้นการอธิบายข้อมูลเชิงตำแหน่งต่าง ๆ ของแผนที่ เช่น ขอบเขตการปกครอง เส้นทางคมนาคม เส้นทางน้ำ ขอบเขตที่ดินและอาคาร เป็นต้น

องค์ประกอบของระบบสารสนเทศภูมิศาสตร์ ได้แก่ บุคลากร (People) ซอฟต์แวร์ (Software) อุปกรณ์ระบบคอมพิวเตอร์ (Hardware) ข้อมูลเชิงพื้นที่ (Data) และกระบวนการวิเคราะห์ข้อมูล (Approaches) ประเภทของข้อมูลในระบบสารสนเทศภูมิศาสตร์ โดยทั่วไปจะแบ่งข้อมูลเป็น 2 ประเภท คือ ข้อมูลเชิงพื้นที่ และข้อมูลเชิงบรรยาย หรือข้อมูลที่ไม่อยู่ในเชิงพื้นที่

2.3.1.1 ข้อมูลเชิงพื้นที่ (Spatial Data) เป็นข้อมูลที่เกี่ยวข้องกับตำแหน่งที่ตั้งของข้อมูลต่าง ๆ บนพื้นโลก โดยอาจแบ่งเป็น 2 ประเภทย่อยคือ ข้อมูลเวกเตอร์ (Vector) และข้อมูลแรสเตอร์ (Raster)


1. ข้อมูลเวกเตอร์ (Vector) เป็นข้อมูลที่จัดเก็บอยู่ในรูปชุดของจุดพิกัดและความสัมพันธ์ระหว่างพิกัดต่าง ๆ แบ่งย่อยได้เป็น (1) จุด (Point) คือชุดพิกัดที่ไม่มีความสัมพันธ์กันเลย แต่ละจุดเป็นข้อมูลแยกของตัวเองไม่เกี่ยวข้องกัน (2) เส้น (Line) คือชุดพิกัดที่มีความเกี่ยวข้องกันในทางเดียว คือมีจุดเริ่มต้นถึงจุดปลายไม่มีลักษณะการวนซ้ำกลับมาจุดเดิม ชุดความสัมพันธ์นี้หนึ่งชุดคือข้อมูลของเส้นหนึ่งเส้นและ (3) รูปหลายเหลี่ยม (Polygon) คือชุดพิกัดที่มีความเกี่ยวข้องกันแบบวนกลับ คือมีจุดเริ่มต้นและจุดปลายเป็นจุดเดียวกัน ทำให้ได้พิกัดเป็นรูปปิดหนึ่งรูป

ข้อมูลแบบเวกเตอร์อาจมีข้อมูลตาราง (Attribute) ประกอบอยู่ด้วยหรือไม่ก็ได้ ซึ่งข้อมูลตารางนี้จะผูกโยงเข้ากับชุดข้อมูลแต่ละชุดไป เช่น ถ้าข้อมูลแบบจุด แต่ละจุดจะมีข้อมูลตารางหนึ่งชุด ถ้าเป็นแบบเส้นก็จะมีข้อมูลตารางอีกหนึ่งชุดเช่นเดียวกัน สำหรับข้อมูลเวกเตอร์อาจได้จากซอฟต์แวร์ที่มีการใช้งานอย่างแพร่หลายเช่น ESRI (.shape), MAPInfo file, Microstation (.DGN) และ AutoCAD (.DXF)

2. ข้อมูลแรสเตอร์ (Raster) คือข้อมูลที่มีการจัดเก็บเป็นช่องตารางสี่เหลี่ยม แต่ละช่องตารางเรียกว่า พิกเซล (Pixel) โดยจะเก็บข้อมูลตัวเลขชุดหนึ่ง พิกเซลแต่ละช่องจะมีขนาดเท่ากัน เรียงตัวเป็นรูปสี่เหลี่ยมมุมฉาก สำหรับพิกัดภูมิศาสตร์จะถูกกำหนดไว้ที่พิกเซลแรกและขนาดพิกเซลจะเป็นตัวกำหนดพิกัดของพิกเซลอื่น หากข้อมูลแรสเตอร์ไม่ได้ระบุพิกเซลแรกมา พิกัดจุดเริ่มต้นจะอยู่ที่จุด (0,0) เรียกว่า Unregistered raster

โดยทั่วไปข้อมูลแรสเตอร์มักจะเป็นข้อมูลภาพถ่ายทางอากาศ ภาพถ่ายดาวเทียม หรือแผนที่ที่สแกนจากกระดาษ แต่ข้อมูลแรสเตอร์ยังสามารถได้จากข้อมูลอื่น ๆ เช่น ระดับความสูงภูมิประเทศได้เช่นกัน ข้อมูลแรสเตอร์อาจอยู่ในรูปของไฟล์นามสกุล .JPG .PNG .GIF .BMP

และ .TIFF อีกทั้งข้อมูลราสเตอร์ที่มีการระบุพิกัด (Georeferencing) อาจอยู่ในรูปของไฟล์นามสกุล .Geo-TIFF .ECW .SID .DEM และ .IMG เป็นต้น



รูปที่ 2.13 ข้อมูลเชิงพื้นที่ (Olexy, 2021)



รูปที่ 2.14 ตัวอย่างข้อมูลราสเตอร์

2.3.1.2 ข้อมูลเชิงบรรยาย หรือข้อมูลที่ไม่อยู่ในเชิงพื้นที่ (Non-Spatial Data) เป็นข้อมูลที่อธิบายถึงลักษณะต่าง ๆ ในพื้นที่นั้น ๆ ณ ช่วงเวลาใดเวลาหนึ่ง หรือหลาย ๆ ช่วงเวลา หรืออาจเรียกว่า ข้อมูลดีลิมิตเตดเท็กซ์ (Delimited text) คือข้อมูลประเภทข้อความ (Text) ที่ถูกคั่น (Delimited) ด้วยเครื่องหมายหรือสัญลักษณ์บางตัว เช่น ลูกน้ำ (“,”) ทับ (“/”) หรือช่องว่าง (“ ”) เพื่อบ่งบอกว่าข้อมูลที่ถูกคั่นนั้นเปรียบเสมือนอยู่คนละช่องตารางกัน ข้อมูลประเภทนี้มักมาจาก

เครื่องรับสัญญาณ GNSS หรือการนำเข้ามาจากซอฟต์แวร์ เพื่อใช้ข้อมูลนี้เป็นข้อมูลตาราง (Attribute) (ศาลาว่าการกรุงเทพมหานคร, สำนักยุทธศาสตร์และประเมินผล, กองสารสนเทศภูมิศาสตร์, ม.ป.ป.)

ซอฟต์แวร์ที่ใช้ในการวิเคราะห์ข้อมูลสำหรับระบบสารสนเทศภูมิศาสตร์มีหลากหลายซอฟต์แวร์ที่เป็นที่นิยมใช้โดยทั่วไป โดยอาจแบ่งออกเป็น ซอฟต์แวร์กรรมสิทธิ์ และซอฟต์แวร์รหัสเปิด

ซอฟต์แวร์กรรมสิทธิ์ (Proprietary software) เป็นซอฟต์แวร์ที่ต้องเสียค่าใช้จ่ายในการซื้อลิขสิทธิ์เพื่อที่จะสามารถใช้งานซอฟต์แวร์ โดยที่ผู้ใช้งานต้องใช้งานภายใต้ข้อจำกัดและขอบเขตการใช้งานที่กำหนด อีกทั้งยังไม่สามารถเห็น source code ต้นฉบับได้ จึงทำให้ไม่สามารถปรับปรุงหรือพัฒนาได้ความต้องการของผู้ใช้ แต่ซอฟต์แวร์กรรมสิทธิ์อาจมีข้อดีในเรื่องความสะดวกในการใช้งาน และความเสถียรของซอฟต์แวร์ ตัวอย่างซอฟต์แวร์กรรมสิทธิ์สำหรับระบบสารสนเทศภูมิศาสตร์ เช่น Geomedia, ERDAS, ArcGIS, MapInfo, GRASS GIS และ AutoCAD Map 3D เป็นต้น

ซอฟต์แวร์รหัสเปิด (Open-source software) เป็นซอฟต์แวร์ที่เจ้าของซอฟต์แวร์อนุญาตให้ผู้ใช้งาน ใช้งานได้อย่างไม่มีข้อจำกัดทั้งจำนวนและรูปแบบการใช้งาน ทั้งการใช้งานส่วนบุคคล การใช้งานเชิงพาณิชย์ และการใช้งานภายในองค์กร อีกทั้งยังสามารถปรับปรุงและพัฒนาต่อจากรหัสต้นฉบับ (Source code) ได้ตามต้องการ ภายใต้ข้อตกลงทางกฎหมาย โดยซอฟต์แวร์รหัสเปิดที่นิยมใช้สำหรับระบบสารสนเทศภูมิศาสตร์มีชื่อว่า Quantum GIS หรือ QGIS

ซอฟต์แวร์ Quantum GIS (QGIS) เป็นซอฟต์แวร์รหัสเปิด (Open source) ที่ถูกพัฒนาขึ้นเพื่อวัตถุประสงค์ในการจัดการข้อมูลภูมิสารสนเทศโดยมีความสามารถที่หลากหลาย ทั้งการใช้งานทั่วไปอย่างการเรียกใช้งานข้อมูลภาพ ตารางสืบค้นข้อมูล วิเคราะห์ข้อมูลแบบอ้างอิงข้อมูลเชิงตำแหน่ง ตลอดจนนำเสนอแผนที่ในรูปแบบที่สวยงามได้ โดยลักษณะของซอฟต์แวร์รหัสเปิดที่มีผู้ใช้งานร่วมกันพัฒนาขึ้น ทำให้ซอฟต์แวร์มีความสามารถหลากหลายแทบจะครอบคลุมทุกฟังก์ชันที่ซอฟต์แวร์ตามท้องตลาดมี แต่อาจมีข้อจำกัดในเรื่องของฟังก์ชันที่มีความซับซ้อนสูง ซึ่งบางครั้ง QGIS อาจจะตอบสนองได้ไม่ดีเท่าที่ควรนัก ทั้งนี้สามารถใช้งานซอฟต์แวร์นี้ได้ทั้งในเกือบทุกระบบปฏิบัติการคอมพิวเตอร์ อีกทั้งผู้ใช้งานยังสามารถดาวน์โหลดโปรแกรมเสริม (Plugin) เข้ามาใช้งานด้วยก็ได้ (ศาลาว่าการกรุงเทพมหานคร, สำนักยุทธศาสตร์และประเมินผล, กองสารสนเทศภูมิศาสตร์, ม.ป.ป.)



รูปที่ 2.15 ซอฟต์แวร์ QGIS

นอกจากซอฟต์แวร์ที่ติดตั้งบนคอมพิวเตอร์แล้ว (GIS Desktop software) ในปัจจุบันยังมีแพลตฟอร์มออนไลน์ (Web Mapping Platforms) ที่สามารถทำงานด้านการจัดการวิเคราะห์ ประมวลผล และแสดงข้อมูลเชิงพื้นที่ได้เช่นเดียวกัน อาทิ ArcGIS ESRI, CARTO และ GIS Cloud

สำหรับกระบวนการวิเคราะห์ข้อมูลเชิงตำแหน่ง (Spatial Analysis) เป็นการประเมิน ตรวจสอบ วิเคราะห์ และสร้างแบบจำลองจากข้อมูลเชิงพื้นที่ซึ่งต้องอาศัยแบบจำลองเทคนิคการวิเคราะห์ข้อมูล และอัลกอริทึมที่หลากหลาย เพื่อนำมาแก้ปัญหาเชิงพื้นที่ อาทิ การแปลงข้อความเป็นพิกัดตำแหน่ง (Geocoding) การวิเคราะห์ความลาดชัน (Slope Analysis) การประมาณค่าเชิงพื้นที่ (Spatial Interpolation) การวิเคราะห์ระยะใกล้เคียง (Proximity) การซ้อนทับข้อมูลแผนที่ (Map Overlay) และการวิเคราะห์ทางสถิติ (Geo-statistics) เป็นต้น

2.3.2 ระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม

ระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม (GNSS) เป็นเทคโนโลยีที่ใช้ระบุพิกัดบนพื้นโลกและนำทางโดยอาศัยข้อมูลจากดาวเทียมหลายดวงที่โคจรรอบโลกส่งสัญญาณมายังพื้นโลกด้วยคลื่นความถี่สูง และมีความเที่ยงตรงสูง

ปัจจุบันนี้ได้มีการพัฒนาระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียมขึ้นมาหลายระบบ เช่น GPS (USA), GLONASS (Russia), Galileo (Europe), BeiDou (China), QZSS (Japan) และ SBAS เป็นต้น



(a)



(b)



(c)




(d)

รูปที่ 2.16 GNSS ระบบต่าง ๆ

(a) GPS (b) GLONASS (c) Galileo (d) BeiDou

หลักการของระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม คือเครื่องรับสัญญาณภาคพื้นดินจะทำหน้าที่รับสัญญาณมาคำนวณหาระยะเสมือนจริง จากเครื่องรับสัญญาณถึงดาวเทียมแต่ละดวง โดยการคำนวณตำแหน่งจะต้องอาศัยข้อมูลจากดาวเทียมอย่างน้อย 3 ดวงสำหรับพิกัดสองมิติ และดาวเทียมอย่างน้อย 4 ดวงสำหรับพิกัดใน 3 มิติ



รูปที่ 2.17 GNSS principles (Dawoud, 2012)

หลักการของ GNSS ขึ้นอยู่กับการใช้สัญญาณวิทยุที่ส่งจากเครือข่ายดาวเทียมไปยังเครื่องรับบนภาคพื้นดิน เครื่องรับใช้สัญญาณเหล่านี้เพื่อระบุตำแหน่ง ความเร็ว และเวลาโดยการวัดระยะทางไปยังดาวเทียมตามเวลาที่สัญญาณใช้ในการเดินทางจากดาวเทียมไปยังเครื่องรับ

2.3.3 การรับรู้ระยะไกล

การรับรู้ระยะไกล (Remote Sensing) เป็นศาสตร์ในการสำรวจข้อมูลพื้นที่ผิวโลกและปรากฏการณ์ต่าง ๆ ในโลก โดยใช้อุปกรณ์ในการบันทึกข้อมูล หรือเซนเซอร์ (Sensor) ในการตรวจวัดการสะท้อนของคลื่นแม่เหล็กไฟฟ้าของวัตถุขึ้นไปกระทบอุปกรณ์ในการบันทึกภาพโดยไม่ต้องสัมผัสวัตถุโดยตรง

คำว่า Remote Sensing เป็นประโยคที่ประกอบขึ้นมาจากการรวมคำ 2 คำ คือ Remote หมายถึง ระยะไกล และ Sensing หมายถึง การรับรู้ จากการรวมคำ 2 คำเข้าด้วยกัน คำว่า “Remote Sensing” จึงหมายถึง “การรับรู้ระยะไกล” โดยมีนิยามความหมายว่า “เป็นการสำรวจตรวจสอบคุณสมบัติสิ่งใด ๆ ก็ตาม โดยที่ไม่ได้สัมผัสกับสิ่งเหล่านั้น”

การรับรู้จากระยะไกลเป็นกระบวนการรับข้อมูลเกี่ยวกับวัตถุหรือพื้นที่จากระยะไกล โดยทั่วไปจะใช้เซ็นเซอร์บนเครื่องบินหรือดาวเทียม ข้อมูลที่รวบรวมโดยการสำรวจระยะไกลสามารถนำมาใช้เพื่อวัตถุประสงค์ที่หลากหลาย รวมถึงการทำแผนที่ การตรวจสอบ และการศึกษาพื้นผิวโลก


และชั้นบรรยากาศ การรับรู้จากระยะไกลสามารถแบ่งออกเป็น 2 ประเภท คือแบบ Passive และแบบ Active

การรับรู้ระยะไกลแบบ Passive ใช้เครื่องมือที่ตรวจจับพลังงานที่เกิดขึ้นตามธรรมชาติ เช่น แสงที่มองเห็นหรือรังสีอินฟราเรด สำหรับการรับรู้ระยะไกลแบบ Active ใช้เครื่องมือที่ปล่อยพลังงาน เช่น เรดาร์ (Radar) และไลดาร์ (LiDAR) เพื่อวัดการสะท้อนหรือการกระจายกลับของพลังงานที่ปล่อยออกมา เทคโนโลยีการสำรวจระยะไกลถูกนำมาใช้อย่างแพร่หลายในสาขาต่าง ๆ เช่น การเกษตร ป่าไม้ การสำรวจแร่ การจัดการภัยพิบัติ และการตรวจสอบด้านสิ่งแวดล้อม

ในอดีตที่ผ่านมาเทคโนโลยีภาพถ่ายทางอากาศ (Aerial Photograph) และภาพถ่ายดาวเทียม (Satellite Imagery) เป็นคำที่ใช้แยกจากกัน ต่อมาได้มีการกำหนดให้ใช้ 2 คำรวมกัน และรวมถึงเทคโนโลยีต่าง ๆ ที่เกี่ยวข้องกับข้อมูลที่ได้จากตัวรับสัญญาณระยะไกล โดยจะเรียกเทคโนโลยีดังกล่าวว่า การรับรู้ระยะไกล (Remote Sensing)

ดังนั้น คำว่า Remote Sensing จึงมีความหมายที่นิยมเรียกอีกอย่างหนึ่งว่า การสำรวจจากระยะไกล โดย Remote Sensing จัดเป็นวิทยาศาสตร์ และศิลปะของการได้มาซึ่งข้อมูลเกี่ยวกับวัตถุ พื้นที หรือ ปรากฏการณ์จากเครื่องมือบันทึกข้อมูล โดยปราศจากการเข้าไปสัมผัสวัตถุเป้าหมาย ทั้งนี้ อาศัยคุณสมบัติของ คลื่นแม่เหล็กไฟฟ้าเป็นสื่อในการได้มาของข้อมูลใน 3 ลักษณะ คือ

1. คลื่นรังสี (Spectral) คือ คลื่นแม่เหล็กไฟฟ้าที่มีความยาวคลื่นต่าง ๆ เช่น คลื่นรังสีย่านแสงที่ตามองเห็น ซึ่งมีความยาวคลื่นอยู่ระหว่าง 0.4–0.7 ไมโครเมตร เป็นต้น
2. รูปทรงสัญญาณ (Spatial) คือ พื้นผิวของโลกที่มีลักษณะขรุขระ สูง ต่ำ ราบเรียบ ไม่ราบเรียบ ปรากฏเป็นรูปทรงต่าง ๆ เช่น ทรงกลม ทรงรี เป็นต้น
3. การเปลี่ยนแปลงตามช่วงเวลา (Temporal) คือ วัตถุต่าง ๆ จะมีการเปลี่ยนแปลงในลักษณะการ เปลี่ยนแปลงตามช่วงฤดูกาล การเปลี่ยนแปลงรายปี เป็นต้น ลักษณะการเปลี่ยนแปลงดังกล่าวทำให้มีความแตกต่างของระดับสีในภาพขาวดำ และภาพสีผสม จึงสามารถใช้ข้อมูลดาวเทียมที่ถ่ายซ้ำบริเวณเดิมในช่วงเวลาต่าง ๆ มาใช้ติดตามการเปลี่ยนแปลงได้



รูปที่ 2.18 การรับรู้ระยะไกล

ดาวเทียม (Satellites) เป็นหนึ่งในเครื่องมือสำหรับงานด้านการสำรวจระยะไกลที่มีความสำคัญในการเก็บรวบรวมข้อมูลจากอวกาศ และส่งข้อมูลกลับมายังพื้นโลก โดยดาวเทียมที่โคจรรอบโลกอาจแบ่งออกตามลักษณะการใช้งานได้ดังนี้

1. ดาวเทียมสื่อสาร สำหรับใช้ในการสื่อสารโทรคมนาคมภายในประเทศ และระหว่างประเทศ โดยการส่งสัญญาณคลื่นวิทยุในความถี่ไมโครเวฟ เช่น ดาวเทียมไทยคม ดาวเทียม IRIDIUM และดาวเทียม INTELSAT เป็นต้น

2. ดาวเทียมสำรวจทรัพยากรโลก เป็นดาวเทียมที่เก็บรวบรวมข้อมูลที่มีความละเอียดเชิงพื้นที่ และความละเอียดเชิงคลื่น เพื่อการสำรวจ ติดตามทรัพยากรและสิ่งแวดล้อม รวมไปถึงการทำแผนที่ เช่น ดาวเทียม LANDSAT ดาวเทียม THEOS และดาวเทียม SMMS เป็นต้น

3. ดาวเทียมอุตุนิยมวิทยา เป็นดาวเทียมที่ใช้ในการสังเกตพื้นผิวบนโลกได้อย่างต่อเนื่อง โดยให้ข้อมูลสำคัญในการติดตามและวิเคราะห์ลักษณะอากาศที่เกิดขึ้นในแต่ละบริเวณ ร่วมกับเครื่องมืออื่น โดยอาจให้ข้อมูลภาพถ่ายเรดาร์ ภาพถ่ายอินฟราเรด หรือสัญญาณวิทยุมายังสถานีภาคพื้น เช่น ดาวเทียม NOAA และดาวเทียม GMS

4. ดาวเทียมนำร่อง เป็นดาวเทียมที่ใช้คลื่นวิทยุและรหัสจากดาวเทียมไปยังเครื่องรับสัญญาณบนพื้นผิวโลก โดยสามารถใช้บอกตำแหน่งบนโลกที่ถูกต้อง เช่น ดาวเทียมในระบบ GPS



รูปที่ 2.19 ดาวเทียม THEOS-2 (GISDA, 2566)

การถ่ายภาพทางอากาศ (Aerial Imagery) คือ กระบวนการถ่ายภาพภาคพื้นดินจากเครื่องบินหรือระบบอากาศยานไร้คนขับซึ่งแตกต่างจากภาพถ่ายดาวเทียมซึ่งถ่ายจากดาวเทียมที่โคจรรอบโลก ทั้งภาพถ่ายทางอากาศและภาพถ่ายดาวเทียมต่างมีข้อดีและข้อเสียต่างกันไป และถูกนำไปใช้งานที่แตกต่างกัน ต่อไปนี้เป็นเหตุผลบางประการที่ภาพถ่ายทางอากาศอาจเป็นที่นิยมมากกว่าภาพถ่ายดาวเทียมในบางสถานการณ์ ดังนี้

1. มีความละเอียดสูงกว่า การถ่ายภาพทางอากาศสามารถให้ภาพที่มีความละเอียดสูงกว่าภาพถ่ายดาวเทียม ซึ่งจะเป็นประโยชน์สำหรับการทำแผนที่โดยละเอียดและการสำรวจพื้นที่ขนาดเล็ก
2. ควบคุมการได้มาของภาพได้สะดวกมากขึ้น การถ่ายภาพทางอากาศช่วยให้สามารถควบคุมเวลาและมุมของการรับภาพได้มากขึ้น ซึ่งจะเป็นประโยชน์ในการเก็บรายละเอียดเฉพาะหรือหลีกเลี่ยงเงาและแสงสะท้อน
3. เหมาะสมการรวบรวมข้อมูลตามเวลาจริง (Real-time) การถ่ายภาพทางอากาศสามารถให้การรวบรวมข้อมูลตามเวลาจริง ซึ่งจะเป็นประโยชน์สำหรับการตรวจสอบและสำรวจเหตุการณ์แบบตามเวลาจริงหรือพื้นที่ที่ยากต่อการเข้าถึง
4. ต้นทุนที่ต่ำกว่าสำหรับการครอบคลุมพื้นที่ขนาดเล็ก สำหรับการครอบคลุมพื้นที่ขนาดเล็ก การถ่ายภาพทางอากาศอาจมีราคาถูกกว่าภาพถ่ายจากดาวเทียม
5. สนับสนุนเทคนิคการรับรู้ระยะไกลอื่น ๆ การถ่ายภาพทางอากาศสามารถใช้เป็นส่วนเสริมของเทคนิคการสำรวจระยะไกลอื่น ๆ เช่น การถ่ายภาพด้วยแสงหรือภาพความร้อน เพื่อให้ข้อมูลที่มีรายละเอียดมากขึ้นเกี่ยวกับพื้นที่

2.3.4 ระบบอากาศยานไร้คนขับ

ระบบอากาศยานไร้คนขับ (Unmanned Aerial Systems) หรือ UAS หมายถึง ระบบอากาศยานที่ควบคุมจากระยะไกล ซึ่งบินโดยไม่มีนักบินควบคุมอยู่ภายในอากาศยาน

The International Civil Aviation Organization (2018) หรือ ICAO หรือในชื่อ องค์การการบินพลเรือนระหว่างประเทศ นิยามระบบอากาศยานไร้คนขับ (UAS) ว่า "เครื่องบินและ องค์ประกอบที่เกี่ยวข้องซึ่งดำเนินการโดยไม่มีนักบินอยู่บนเครื่องบิน" ซึ่งรวมถึงอากาศยานไร้คนขับ (Unmanned Aerial Vehicle) หรือ UAV หรือที่เรียกกันทั่วไปว่าโดรน ตลอดจนอุปกรณ์และระบบ ควบคุมที่เกี่ยวข้อง ICAO เป็นหน่วยงานหนึ่งของสหประชาชาติ และมีหน้าที่รับผิดชอบในการพัฒนา และส่งเสริมมาตรฐานและกฎระเบียบระหว่างประเทศสำหรับการบินพลเรือน องค์การทำงานร่วมกับ ประเทศสมาชิก รวมถึง Federal Aviation Administration (FAA) เพื่อพัฒนาแนวทางและมาตรฐาน สำหรับการรวม UAS เข้ากับน่านฟ้าสากลอย่างปลอดภัยและมีประสิทธิภาพ

Federal Aviation Administration (FAA) (n.d) นิยามว่าระบบอากาศยานไร้ คนขับ (UAS) เป็น "อากาศยานที่ดำเนินการโดยปราศจากการแทรกแซงของมนุษย์โดยตรงจากภายใน หรือบนเครื่องบิน" ซึ่งรวมถึงอากาศยานไร้คนขับ ตลอดจนอุปกรณ์และระบบควบคุมที่เกี่ยวข้อง โดย FAA มีหน้าที่ควบคุมและดูแลการใช้ UAS ในระบบน่านฟ้าแห่งชาติ (The National Airspace System) หรือ NAS เพื่อความปลอดภัยและมีประสิทธิภาพ ทั้งการออกคำรับรอง ระเบียบ และแนว ปฏิบัติในการปฏิบัติงาน ตลอดจนกำหนดบทลงโทษหากมีการฝ่าฝืน

สถาบันเทคโนโลยีป้องกันประเทศ ได้ให้ความหมายของอากาศยานไร้คนขับว่าเป็น อากาศยานที่ไม่มีนักบินประจำอยู่บนเครื่อง แต่สามารถควบคุมได้ในระยะไกล โดยมีรูปร่าง รูปแบบ ขนาด และเอกลักษณ์ที่แตกต่างกันออกไป มีการควบคุม 2 แบบ ได้แก่ แบบอัตโนมัติ และแบบ กึ่งอัตโนมัติ โดยใช้ระบบการบินด้วยตนเองโดยต้องใช้ระบบโปรแกรมคอมพิวเตอร์ที่มีความซับซ้อน ติดตั้งภายในอากาศยาน (อาภรณ์ พลเสน, 2562)

ดังนั้น ระบบอากาศยานไร้คนขับหรือที่เรียกว่าอากาศยานไร้คนขับ หรือโดรน คือ อากาศยานที่ทำงานโดยไม่มีนักบินบนเครื่องบิน สามารถควบคุมจากระยะไกลหรือทำงานแบบอิสระ โดยทำตามคำแนะนำที่ตั้งโปรแกรมไว้ล่วงหน้า UAS ถูกนำมาใช้เพื่อวัตถุประสงค์ที่หลากหลาย รวมถึง การลาดตระเวน การเฝ้าระวัง และการขนส่ง อากาศยานไร้คนขับโดยทั่วไปประกอบด้วยองค์ประกอบ สำคัญ ดังนี้

1. โครงเครื่องบิน (Airframe) คือ โครงสร้างทางกายภาพของอากาศยานไร้คนขับ ซึ่งรวมถึงลำตัว ปีก และหาง

2. ระบบขับเคลื่อน (Propulsion system) คือ แหล่งพลังงานและระบบขับเคลื่อนที่ช่วยให้อากาศยานไร้คนขับบินได้ ซึ่งอาจรวมถึงเครื่องยนต์สันดาปภายใน มอเตอร์ไฟฟ้า หรือเครื่องยนต์ไอพ่น

3. ระบบควบคุม (Control systems) คือ ระบบอิเล็กทรอนิกส์ที่ควบคุมการบิน การนำทาง และการสื่อสารของอากาศยานไร้คนขับ ซึ่งโดยทั่วไปประกอบด้วยคอมพิวเตอร์ควบคุมการบิน เครื่องรับสัญญาณ GNSS และเครื่องรับส่งสัญญาณวิทยุ

4. เครื่องมือวัด หรือเซ็นเซอร์ (Sensors) คือ เครื่องมือที่ใช้ในการรวบรวมข้อมูลเกี่ยวกับสภาพแวดล้อม เช่น กล้อง, ไลดาร์, เรดาร์ และเซ็นเซอร์ถ่ายภาพความร้อน (Thermal sensor)

5. น้ำหนักบรรทุก (Payload) คือ อุปกรณ์หรือเครื่องมือที่บรรทุกโดยอากาศยานไร้คนขับ เพื่อวัตถุประสงค์ในการปฏิบัติงานเฉพาะ

6. สถานีควบคุมภาคพื้นดิน (Ground control station) คือ อุปกรณ์และซอฟต์แวร์ที่ใช้ในการควบคุมและควบคุมอากาศยานไร้คนขับจากภาคพื้นดิน

7. แบตเตอรี่หรือเชื้อเพลิง (Battery or Fuel) คือ แหล่งพลังงานที่ช่วยให้อากาศยานไร้คนขับบินได้

8. ช่องทางการสื่อสาร (Communication link) คือ วิธีการสื่อสารที่เชื่อมต่ออากาศยานไร้คนขับกับสถานีควบคุมภาคพื้นดิน ทำให้ผู้ปฏิบัติงานสามารถควบคุมอากาศยานไร้คนขับ และรับข้อมูลจากเซ็นเซอร์ได้ โดยส่วนประกอบเหล่านี้ทำงานร่วมกันเพื่อให้อากาศยานไร้คนขับบินได้เองโดยอัตโนมัติ หรือควบคุมจากระยะไกล และรวบรวมและส่งข้อมูลเกี่ยวกับสภาพแวดล้อม (กรมที่ดิน, ศูนย์ข้อมูลแผนที่รูปแปลงที่ดิน, ม.ป.ป.; มหาวิทยาลัยนเรศวร, อุทยานวิทยาศาสตร์มหาวิทยาลัยนเรศวร, 2566)

2.3.5 การสำรวจด้วยอากาศยานไร้คนขับ

อากาศยานไร้คนขับสามารถใช้สำหรับการสำรวจระยะไกลได้โดยการพกพาเซ็นเซอร์ที่รวบรวมข้อมูลเกี่ยวกับสภาพแวดล้อม เช่น กล้อง ไลดาร์ เรดาร์ และเซ็นเซอร์ถ่ายภาพความร้อน เพื่อเก็บรวบรวมข้อมูลสำหรับนำไปใช้ในการการทำแผนที่ การตรวจสอบ และการศึกษาพื้นผิวโลก และชั้นบรรยากาศ สำหรับเทคนิคการใช้งานอากาศยานไร้คนขับเพื่อการสำรวจและทำแผนที่ เรียกว่า โฟโตแกรมเมตรี (Photogrammetry) โดยเป็นกระบวนการใช้ภาพถ่ายเพื่อการรังวัดและทำแผนที่พื้นผิวโลก โดยสามารถใช้เพื่อสร้างแบบจำลองระดับความสูงเชิงเลขที่มีความละเอียดสูง แผนที่ภาพถ่ายความละเอียดสูง หรือภาพถ่ายออร์โธ และแบบจำลองพื้นผิวภูมิประเทศเชิงเลขโดยสามารถใช้อากาศยานไร้คนขับ เพื่อถ่ายภาพทางอากาศของภาคพื้นดินโดยใช้กล้อง ซึ่งสามารถประมวลผลได้

โดยใช้ซอฟต์แวร์ในการวิเคราะห์ข้อมูลสำหรับระบบสารสนเทศภูมิศาสตร์ เพื่อสร้างแผนที่และแบบจำลองดังกล่าว

2.3.5.1 กระบวนการใช้อากาศยานไร้คนขับสำหรับการสำรวจระยะไกล โดยทั่วไปมีขั้นตอนโดยสรุป ดังต่อไปนี้

1) การวางแผนการบิน (Flight Planning) คือ การกำหนดแผนการบิน ประเภทของกล้องและเลนส์ที่จะใช้ ความละเอียดที่ต้องการ (Resolution) เช่น ค่าระยะระหว่างจุดศูนย์กลางจุดภาพบนพื้นดิน

2) การทำภารกิจ (Flight Mission) เป็นใช้งาน UAV เพื่อถ่ายภาพทางอากาศภาคพื้นดิน

3) การประมวลผล (Processing) คือ การใช้ซอฟต์แวร์เพื่อประมวลผลภาพถ่ายทางอากาศ รวมถึงการจัดตำแหน่งภาพ การสร้างแบบจำลอง 3 มิติ และการสร้างแบบจำลองภูมิประเทศ

4) การวิเคราะห์ (Analysis) คือ การตีความและวิเคราะห์ข้อมูลเพื่อตั้งข้อมูล เช่น พืชพรรณ ภูมิประเทศ และการใช้ประโยชน์ที่ดิน

2.3.5.2 ระยะระหว่างจุดศูนย์กลางจุดภาพบนพื้นดิน (Ground sampling distance) หรือ GSD คือการวัดความละเอียดของภาพที่ถ่ายโดยเซ็นเซอร์ทางอากาศหรือดาวเทียม แสดงถึงระยะห่างระหว่างสองพิกเซลติดต่อกันบนพื้นซึ่งตรงกับตำแหน่งเดียวกันในรูปภาพ โดยทั่วไป GSD จะวัดเป็นหน่วยความยาว เช่น เมตร หรือ เซนติเมตร และสามารถหาคำนวณขนาดของวัตถุที่สามารถแยกแยะได้ในภาพ ยิ่ง GSD มีขนาดเล็กลงเท่าใด ความละเอียดของภาพก็จะยิ่งสูงขึ้นเท่านั้น และข้อมูลที่สามารถดึงออกมาได้มีรายละเอียดมากขึ้น (กรมโยธาธิการและผังเมือง, สำนักวิศวกรรม การผังเมือง, 2564; มหาวิทยาลัยนเรศวร, อุทยานวิทยาศาสตร์มหาวิทยาลัยนเรศวร, 2566)

GSD ถูกกำหนดโดยปัจจัยหลายประการ รวมถึงความสูงของเซ็นเซอร์ ทางยาวโฟกัสของเลนส์ และขนาดของเซ็นเซอร์ภาพ GSD สามารถคำนวณได้โดยการหาความสูงของเซ็นเซอร์ด้วยทางยาวโฟกัสของเลนส์ และคูณผลลัพธ์ด้วยจำนวนพิกเซลต่อหน่วยความยาวของเซ็นเซอร์สามารถคำนวณได้ดังสมการที่ 2.1


$$H = (GSD \times f \times IW) / (SW \times 100) \quad (2.1)$$

โดยที่	H	คือ	ความสูงการบินเหนือจุดที่บิน (เมตร)
	GSD	คือ	ระยะระหว่างจุดศูนย์กลางจุดภาพบนพื้นดิน (เซนติเมตร/พิกเซล)
	SW	คือ	ระยะด้านกว้างของเซ็นเซอร์ (Sensor width) (มิลลิเมตร)

f คือ ทางยาวโฟกัสของเลนส์ (มิลลิเมตร)
 IW คือ จำนวนพิกเซลด้านกว้าง (พิกเซล)

โดยสามารถหาระยะพื้นจริงต่อหนึ่งภาพในหน่วย เมตร (Distance width) หรือ DW จากภาพถ่าย ได้จากสมการที่ 2.2

$$DW = (GSD \times IW)/100 \quad (2.2)$$




รูปที่ 2.20 การหาความสูงการบินเหนือจุดที่บิน

GSD เป็นตัวแปรที่สำคัญในการวางแผนการบินของอากาศยานไร้คนขับ เนื่องจากมีผลโดยตรงต่อการกำหนดระดับความสูงขั้นต่ำที่จำเป็น เพื่อให้ได้ความละเอียดตรงตามความต้องการ นอกจากนี้ยังช่วยในการกำหนดจำนวนการทับซ้อนระหว่างภาพหรือส่วนซ้อนและส่วนเกย ซึ่งจำเป็นสำหรับการต่อภาพ และการสร้างแบบจำลองสามมิติโดยใช้เทคนิคโฟโตแกรมเมตรี

2.3.5.3 ส่วนซ้อนและส่วนเกย เป็นคำศัพท์ที่ใช้ในกระบวนการโฟโตแกรมเมตรีเพื่ออธิบายระดับการเหลื่อมกันระหว่างภาพที่ต่อเนื่องซึ่งถ่ายโดยเซ็นเซอร์ทางอากาศ หรือดาวเทียม สิ่งเหล่านี้เป็นข้อพิจารณาที่สำคัญในการวางแผนการบินของอากาศยานไร้คนขับ เนื่องจากส่งผลต่อคุณภาพของแบบจำลอง เช่น ความละเอียดและความแม่นยำของแบบจำลองพื้นผิวภูมิประเทศเชิงเลข และแผนที่ภาพถ่ายความละเอียดสูง

1) ส่วนซ้อน (Frontal Overlap) หมายถึงระดับการเหลื่อมกันระหว่างภาพที่ถ่ายในทิศทางเดียวกัน โดยปกติจะเป็นทิศทางไปข้างหน้าหรือถอยหลังของเส้นทางการบิน โดยปกติจะแสดงเป็นเปอร์เซ็นต์และระบุว่าพื้นที่เดียวกันครอบคลุมพื้นที่สองภาพติดต่อกันมากน้อยเพียงใด ระดับการทับซ้อนที่สูงขึ้นทำให้มั่นใจได้ว่าข้อมูลมีความซ้ำซ้อนในระดับที่สูงขึ้น ซึ่งสามารถปรับปรุงการประมวลผลของซอฟต์แวร์และคุณภาพของแบบจำลองส่วนซ้อนขึ้นต่ำทั่วไปที่แนะนำคือ 75% (กรมโยธาธิการและผังเมือง, สำนักวิศวกรรมการผังเมือง, 2564)

2) ส่วนเกย (Side Overlap) หมายถึงระดับการเหลื่อมระหว่างภาพที่ถ่ายในแนวตั้งฉาก โดยปกติจะอยู่ที่ด้านข้างของเส้นทางการบิน โดยทั่วไปจะแสดงเป็นเปอร์เซ็นต์และระบุว่าพื้นที่เดียวกันครอบคลุมพื้นที่สองภาพติดต่อกันมากน้อยเพียงใด ระดับความเหลื่อมข้างที่สูงขึ้นช่วยให้มั่นใจได้ว่าข้อมูลมีความซ้ำซ้อนในระดับที่สูงขึ้น ซึ่งสามารถปรับปรุงการประมวลผลของซอฟต์แวร์และคุณภาพของแบบจำลองได้ส่วนเกยขึ้นต่ำทั่วไปที่แนะนำคือ 60% (กรมโยธาธิการและผังเมือง, สำนักวิศวกรรมการผังเมือง, 2564)




รูปที่ 2.21 ส่วนซ้อน และส่วนเกย

ทั้งส่วนซ้อนและส่วนเกย มีความสำคัญในการสร้างแบบจำลองสามมิติที่แม่นยำ โดยเฉพาะอย่างยิ่งเมื่อถ่ายภาพในมุมต่าง ๆ นอกจากนี้ ยังช่วยให้แน่ใจว่ามีข้อมูลเพียงพอในการสร้างแผนที่และแบบจำลองที่มีรายละเอียดถูกต้อง และสามารถใช้เพื่อปรับปรุงความแม่นยำของแบบจำลอง โดยการลดข้อผิดพลาดและปรับปรุงคุณภาพของการจับคู่รูปภาพ

2.3.5.4 รูปแบบการบิน เป็นการวางแผนรูปร่างของเส้นทางการบินสำรวจ โดยทั่วไปจะกำหนดเส้นทางการบินในลักษณะของสี่เหลี่ยมมุมฉาก เพื่อให้โครงข่ายมีความแข็งแรง

และครอบคลุมพื้นที่ได้อย่างทั่วถึง มีรูปแบบการบิน 2 รูปแบบ ดังนี้ รูปแบบการบินทั่วไปหรือ Grid และรูปแบบการบินแบบ Double grid (กรมโยธาธิการและผังเมือง, สำนักวิศวกรรมการผังเมือง, 2564)



รูปที่ 2.22 (a) รูปแบบการบินทั่วไป และ (b) รูปแบบการบินแบบ Double grid

2.3.5.5 การถ่ายภาพ ที่ได้จากการสำรวจด้วยอากาศยานไร้คนขับเป็นส่วนสำคัญต่อการประมวลผลภาพในหัวข้อถัดไป เพื่อให้ได้ภาพที่มีคุณภาพดีและคมชัดที่สุด อาจต้องพิจารณาปัจจัยต่าง ๆ ที่อาจมีผลดังต่อไปนี้

1) มุมรังสีดวงอาทิตย์ เป็นสาเหตุหนึ่งที่ทำให้เกิดเงาของวัตถุและสิ่งแวดล้อมภายในภาพ ดังนั้นช่วงเวลาที่เหมาะสมในการถ่ายภาพควรต้องถ่ายเมื่อดวงอาทิตย์อยู่สูงกว่า 45 องศา จากพื้น หรือถ่ายในช่วงเวลา 9.00 น. – 15.00 น. ภายใต้สภาวะแสงที่ไม่ทำให้เกิดเงาหรือความต่างของสีอย่างชัดเจน

2) การปกคลุมของเมฆ การที่มีเมฆปกคลุมอย่างหนาแน่นเหนือพื้นที่เป้าหมายอาจทำให้เกิดเงาได้ จึงควรหลีกเลี่ยงการบินในสถานที่หรือช่วงเวลาดังกล่าว

3) สภาพอากาศเหนือพื้นดิน เช่น การเกิดหมอกควัน สภาพพื้นหลังฝน หรือสภาพอากาศที่มีลมแรง โดยปัจจัยเหล่านี้ส่งผลเสียต่อคุณภาพของภาพถ่าย และเสี่ยงต่อการเกิดอุบัติเหตุ (กรมโยธาธิการและผังเมือง, สำนักวิศวกรรมการผังเมือง, 2564)

อากาศยานไร้คนขับสามารถนำไปใช้ในวัตถุประสงค์ต่าง ๆ ในภาคการเกษตร อีกทั้งสามารถติดตั้งเซ็นเซอร์ต่าง ๆ เพื่อรวบรวมข้อมูล และข้อมูลที่รวบรวมได้สามารถนำมาใช้ในการตัดสินใจอย่างชาญฉลาดเกี่ยวกับการทำเกษตรแม่นยำ โดยถูกนำไปใช้งานในวัตถุประสงค์ที่หลากหลาย อาทิ

1) การตรวจสอบความสมบูรณ์ของพืช (Crop monitoring) โดยใช้อากาศยานไร้คนขับ เพื่อตรวจสอบการเจริญเติบโต และความสมบูรณ์ของพืชได้ สามารถใช้เพื่อทำแผนที่การเติบโตของพืช ตรวจสอบความเครียดของพืช และระบุพื้นที่ที่พืชเติบโตได้ไม่ดี ข้อมูลนี้สามารถใช้เพื่อเพิ่มประสิทธิภาพการชลประทาน และการให้ปุ๋ย

2) การทำนายผลผลิต (Crop yield prediction) โดยใช้อากาศยานไร้คนขับ เพื่อประเมินผลผลิต ด้วยการวิเคราะห์ข้อมูลดัชนีพืชพรรณ เช่น NDVI ทำให้สามารถทำนายผลผลิตพืชผลได้ด้วยความสะดวก

3) การจัดการชลประทาน (Irrigation management) โดยใช้อากาศยานไร้คนขับ เพื่อระบุพื้นที่ที่ต้องการการชลประทาน และเพื่อปรับตารางเวลาการชลประทานให้เหมาะสม นอกจากนี้ยังสามารถใช้เพื่อตรวจสอบปริมาณการได้น้ำของพืช และตรวจสอบพื้นที่ที่ขาดน้ำ

4) การนับจำนวนพืชในแปลง และการทำแผนที่ (Plant counting and mapping) โดยใช้อากาศยานไร้คนขับ เพื่อนับจำนวนพืชในแปลง และเพื่อทำแผนที่การกระจายของพืช ข้อมูลนี้สามารถใช้เพื่อระบุพื้นที่ของแปลงที่สนใจ และตัดสินใจเกี่ยวกับการจัดการแปลง

5) การวิเคราะห์ดิน (Soil analysis) โดยใช้อากาศยานไร้คนขับ เพื่อรวบรวมข้อมูลเกี่ยวกับลักษณะของดิน เช่น ความชื้นในดิน ชนิดของดิน และค่า pH ของดิน ข้อมูลนี้สามารถใช้เพื่อเพิ่มประสิทธิภาพการให้ปุ๋ย และวางแผนการใช้ที่ดินอย่างยั่งยืน

6) การจัดการปศุสัตว์ (Livestock monitoring) โดยใช้อากาศยานไร้คนขับ เพื่อตรวจสอบสภาพของปศุสัตว์ ตรวจสอบหาปัญหาด้านสุขภาพ และติดตามการเคลื่อนไหวของสัตว์เป็นต้น (สิริวัฒน์ สาครวาสี, 2562)

สิ่งที่ควรคำนึงถึงอย่างยิ่ง คือ กฎระเบียบสำหรับการใช้อากาศยานไร้คนขับ ในภาคการเกษตรนั้นแตกต่างกันไปตามแต่ละประเทศ และการใช้งานเฉพาะ ตัวอย่างเช่น ในสหรัฐอเมริกา เกษตรกรจำเป็นต้องได้รับการยกเว้นพิเศษจาก Federal Aviation Administration (FAA) เพื่อใช้อากาศยานไร้คนขับ เพื่อวัตถุประสงค์ทางการเกษตร ในขณะที่ประเทศอื่น ๆ เกษตรกรอาจต้องได้รับใบอนุญาตพิเศษหรือใบรับรอง สิ่งสำคัญคือต้องปฏิบัติตามข้อบังคับและได้รับอนุญาตที่จำเป็นก่อนใช้อากาศยานไร้คนขับในภาคการเกษตร สำหรับประเทศไทยตามพระราชบัญญัติการเดินอากาศ พ.ศ.2497 อากาศยานไร้คนขับที่มีการติดตั้งกล้องบันทึกภาพ หรือมีน้ำหนักเกิน 2 กิโลกรัม แต่ไม่เกิน 25 กิโลกรัมต้องขึ้นทะเบียนกับสำนักงานการบินพลเรือนแห่งประเทศไทยทุกกรณี สำหรับอากาศยานไร้คนขับที่มีน้ำหนักเกิน 25 กิโลกรัมขึ้นไป ต้องขึ้นทะเบียนโดรนทุกกรณีและต้องได้รับอนุญาตเป็นหนังสือจากรัฐมนตรีว่าการกระทรวงคมนาคมอีกด้วย (มหาวิทยาลัยนเรศวร, อุทยานวิทยาศาสตร์มหาวิทยาลัยนเรศวร, 2566)

นอกจากนี้ สิ่งสำคัญในการเก็บรวบรวมข้อมูลคือ ต้องเลือกใช้ผู้ที่มีความรู้และมีประสบการณ์ เพื่อให้มั่นใจถึงความปลอดภัย และความถูกต้องของข้อมูลที่ได้รับ เช่นเดียวกับเทคโนโลยีใหม่ๆ เกษตรกร และผู้เชี่ยวชาญด้านการเกษตรควรประเมินต้นทุนและประโยชน์ของการใช้อากาศยานไร้คนขับ และพิจารณาว่าเหมาะสมกับการปฏิบัติงานเฉพาะของตนหรือไม่

2.3.6 การประมวลผลภาพ

ขั้นตอนการประมวลผล (Processing) นั้นมีความเกี่ยวข้องกับหลายขั้นตอน รวมถึงการรับภาพ การวางแผนภาพ และการวิเคราะห์ภาพ ขั้นตอนเฉพาะที่เกี่ยวข้องอาจแตกต่างกันไป ขึ้นอยู่กับประเภทของภารกิจ และแบบจำลองที่ต้องการ โดยสามารถทำได้โดยใช้ซอฟต์แวร์ เช่น Agisoft Photoscan, Pix4D หรือ ERDAS Imagine อย่างไรก็ตามกระบวนการทั่วไปสำหรับการประมวลผลข้อมูลด้วยเทคนิคโฟโตแกรมเมตรี มีขั้นตอนต่อไปนี้

1) การได้มาซึ่งภาพ คือถ่ายภาพซ้อนทับกันของพื้นที่ที่สนใจโดยใช้เซ็นเซอร์ทางอากาศหรือดาวเทียม ซึ่งสามารถทำได้โดยใช้แพลตฟอร์มที่มีคนควบคุมหรือไม่มีคนควบคุม เช่น เครื่องบิน เฮลิคอปเตอร์ หรืออากาศยานไร้คนขับ

2) การวางแผนภาพ เป็นการกำหนดตำแหน่งและแนวของกล้องสำหรับแต่ละภาพ โดยทั่วไปจะทำได้โดยการระบุและแยกจุดหรือคุณลักษณะเฉพาะในภาพ เช่น มุมหรือขอบ และจับคู่กับจุดที่สอดคล้องกันในภาพอื่น ๆ กระบวนการนี้เรียกอีกอย่างว่า Image Tie-pointing

3) การวางแผนภายในและภายนอก เป็นการกำหนดตำแหน่งและการวางแผนที่แม่นยำของกล้องสำหรับแต่ละภาพโดยใช้จุดควบคุมหรือ Ground control point (GCP) ขั้นตอนนี้เรียกอีกอย่างว่า การปรับแบบบันเดิล

4) การวิเคราะห์รูปภาพ คือการแยกข้อมูลจากรูปภาพ


5) การควบคุมคุณภาพและการตรวจสอบความถูกต้อง เป็นการตรวจสอบความถูกต้องและความเที่ยงตรงของผลิตภัณฑ์ขั้นสุดท้ายโดยเปรียบเทียบกับจุดควบคุมภาคพื้นดินหรือข้อมูลอ้างอิงอื่น ๆ

6) การสร้างผลิตภัณฑ์ขั้นสุดท้าย คือการสร้างผลิตภัณฑ์ เช่น แผนที่ แบบจำลองสามมิติ หรือแบบจำลองพื้นผิวภูมิประเทศเชิงเลข ซึ่งสามารถนำไปใช้ในงานต่าง ๆ เช่น การสำรวจที่ดิน การวางแผนเมือง และการจัดการทรัพยากร

โครงสร้างจากการเคลื่อนไหว (Structure from Motion) หรือ SfM เป็นวิธีการสร้างแบบจำลองสามมิติของวัตถุ หรือฉากจากชุดภาพสองมิติ เป็นเทคนิคที่ใช้ในโฟโตแกรมเมตรีทำงานโดยวิเคราะห์ความสัมพันธ์และความสอดคล้องกันระหว่างภาพหลายภาพของวัตถุหรือฉากเดียวกันที่ถ่ายจากมุมมองที่แตกต่างกัน ด้วยการใช้ Parallax effect ซึ่งเป็นปรากฏการณ์ทางแสงที่เกิดขึ้นเมื่อวัตถุถูกมองจากสองมุมมองที่แตกต่างกัน เป็นการเปลี่ยนแปลงตำแหน่งของวัตถุอย่าง

ชัดเจนซึ่งเกิดจากการเปลี่ยนแปลงในมุมมองของผู้สังเกต อัลกอริทึม SfM จึงสามารถระบุตำแหน่งของกล้องและพิกัดสามมิติของวัตถุในฉาก

การสร้างพอยท์คลาวด์ (Point Cloud) คือ การสร้างชุดของจุดสามมิติที่แสดงถึงพื้นผิวของวัตถุหรือภูมิประเทศ แต่ละจุดในพอยท์คลาวด์มีชุดพิกัด XYZ ซึ่งแสดงถึงตำแหน่งในพื้นที่สามมิติ พอยท์คลาวด์ถูกสร้างขึ้นโดยใช้เทคนิคโฟโตแกรมเมตรี เช่น การมองเห็นแบบสเตอริโอหรือโครงสร้างจากการเคลื่อนไหว เพื่อดึงข้อมูลสามมิติจากชุดภาพสองมิติที่ซ้อนทับกัน




รูปที่ 2.23 Image Tie-pointing และ Point Cloud

แผนที่ภาพถ่ายความละเอียดสูง หรือภาพถ่ายออร์โธ (Ortho photo) หรือภาพถ่ายออร์โธเรกติไฟด์ (Orthorectified image) คือ ภาพถ่ายทางอากาศหรือภาพถ่ายดาวเทียมที่ได้รับการแก้ไขทางเรขาคณิตซึ่งได้รับการเปลี่ยนรูปเพื่อลบผลกระทบของการเลือนนูนและการเอียงของกล้อง เป็นภาพที่ได้รับการแก้ไขการบิดเบี้ยว เพื่อให้มาตราส่วนมีความสม่ำเสมอทั่วทั้งภาพ และองค์ประกอบในภาพอยู่ในตำแหน่งที่ถูกต้องโดยสัมพันธ์กันและกับพื้น


แผนที่ภาพถ่ายความละเอียดสูงถูกสร้างขึ้นด้วยเทคนิคโฟโตแกรมเมตรีจากการสร้างพอยท์คลาวด์ (Point Cloud) เพื่อดึงข้อมูลสามมิติจากชุดภาพสองมิติที่ทับซ้อนกัน เมื่อดึงข้อมูลสามมิติออกมาแล้ว สามารถใช้ฉายภาพบนระบบพิกัด 3D ทั่วไป และลบผลกระทบของการเคลื่อนที่และการเอียงของกล้อง แผนที่ภาพถ่ายความละเอียดสูงถูกนำมาใช้อย่างแพร่หลาย เช่น การทำแผนที่

การวางแผนการใช้ที่ดิน และการจัดการทรัพยากร นอกจากนี้ ยังสามารถใช้เพื่อสร้างแผนที่สำหรับ
ตรวจจับการเปลี่ยนแปลง และติดตามกิจกรรมต่าง ๆ




รูปที่ 2.24 ตัวอย่างแผนที่ภาพถ่ายความละเอียดสูง

แบบจำลองพื้นผิวภูมิประเทศเชิงเลข (Digital Surface Model) หรือ DSM เป็นการนำเสนอข้อมูลในรูปแบบเชิงเลขของพื้นผิวโลก ซึ่งได้แก่ข้อมูลภูมิประเทศ ตลอดจนอาคาร ต้นไม้ และลักษณะเหนือพื้นดินอื่น ๆ แบบจำลองพื้นผิวภูมิประเทศเชิงเลขเป็นตารางกริด 3 มิติ (3D grid) ของจุดความสูงที่ครอบคลุมพื้นที่ที่สนใจ โดยแสดงด้วยรูปแบบไฟล์ราสเตอร์ ในแต่ละเซลล์ของตารางประกอบด้วยระดับความสูงของภูมิประเทศ ณ ตำแหน่งนั้น ๆ โดยเซลล์สามารถมีความละเอียดต่างกัน ขึ้นอยู่กับข้อกำหนดของข้อมูลที่มีอยู่ แบบจำลองพื้นผิวภูมิประเทศเชิงเลขถูกนำมาใช้อย่างแพร่หลายในการทำงานต่าง ๆ เช่น การวางแผนการใช้ที่ดิน การจัดการทรัพยากรธรรมชาติ การตรวจสอบด้านสิ่งแวดล้อม และสามารถใช้ในการสร้างแบบจำลองระดับความสูงเชิงเลข (Digital Elevation Model) หรือ DEM หรือ Digital Terrain Model (DTM) โดย DEM เป็นแบบจำลองของพื้นผิวภูมิประเทศโดยไม่มีลักษณะเหนือพื้นดิน เช่น อาคาร ต้นไม้ เป็นต้น (มหาวิทยาลัยนเรศวร, อุทยานวิทยาศาสตร์มหาวิทยาลัยนเรศวร, 2566) ความแตกต่างระหว่าง DSM และ DTM แสดงได้ดังรูปที่ 2.26



รูปที่ 2.25 แบบจำลองพื้นผิวภูมิประเทศเชิงเลข (DSM)



รูปที่ 2.26 DSM และ DEM

2.3.7 ดัชนีพืชพรรณ

พืชพรรณ ดิน และน้ำ เป็นวัตถุกลุ่มผิวโลกเป็นส่วนใหญ่ การสะท้อนพลังงานที่ความยาวช่วงคลื่นต่างกันของพืชพรรณ ดิน และน้ำ ทำให้สามารถแยกประเภทของวัตถุชนิดต่าง ๆ ได้ โดยวัตถุทั้งสามชนิดหลักนี้มีรูปแบบการตอบสนองต่อช่วงคลื่นต่างกัน เรียกว่า ค่าลายเส้นเชิงคลื่น (Spectral signature) โดยที่ช่วงคลื่นเดียวกัน วัตถุต่างชนิดจะให้ค่าการสะท้อนพลังงานต่างกัน ขณะที่ความยาวช่วงคลื่นต่างกัน วัตถุชนิดเดียวกัน จะมีความสะท้อนเชิงสเปกตรัมต่างกัน ความยาว

ช่วงคลื่นต่างกัน วัตถุต่างกันจะมีความสะท้อนเชิงสเปกตรัม ต่างกัน ทำให้สามารถแยกชนิดของวัตถุได้ (Jiang et al., 2020)

สำหรับพืชพรรณ คลอโรฟิลล์ของใบพืชดูดกลืนพลังงานสีน้ำเงิน (Blue) ที่ 0.4-0.5 ไมโครเมตร และสีแดง (Red) ที่ 0.6-0.7 ไมโครเมตร แต่สะท้อนพลังงานสีเขียว (Green) ที่ 0.5-0.6 ไมโครเมตร ดังนั้นดวงตามนุษย์จึงมองเห็นใบพืชเป็นสีเขียว ถ้าใบพืชมีอาการผิดปกติ เช่น แห้ง หรือเหี่ยวเป็นต้น ทำให้คลอโรฟิลล์ลดลงก็จะทำให้การสะท้อนคลื่นสีแดงสูงขึ้นในช่วงคลื่นอินฟราเรดสะท้อนที่ 0.7-1.3 ไมโครเมตร การสะท้อนพลังงานของใบพืชสูงมากคือสะท้อนพลังงานประมาณร้อยละ 50 ของพลังงานที่ตกกระทบลักษณะของการสะท้อนพลังงานนี้เป็นผลเนื่องมาจากโครงสร้างภายในใบของพืช เนื่องจากพืชก็สามารถแยกชนิดจะมีลักษณะโครงสร้างภายในที่แตกต่างกัน ดังนั้นการสะท้อนพลังงานในช่วงนี้ก็จะสามารถแยกชนิดของพืชได้ แม้ว่าการสะท้อนพลังงานของพืชในช่วงคลื่นสายตามองเห็นได้จะใกล้เคียงกัน ในทำนองเดียวกันการสะท้อนพลังงานที่มีความยาวคลื่นอินฟราเรดสะท้อนของพืชที่มีอาการผิดปกติทางใบจะมีความแตกต่างไปจากการสะท้อนที่มีความยาวคลื่นเดียวกันของพืชที่สมบูรณ์กว่า (สถานีรับสัญญาณดาวเทียมจุฬารณ, ม.ป.ป.)

ดังนั้น การรับรู้จากระยะไกลสามารถบันทึกค่าสะท้อนของช่วงคลื่นนี้ได้สามารถใช้สำรวจอาการผิดปกติของพืชได้ในช่วงคลื่นที่มีความยาวสูงกว่า 1.3 ไมโครเมตร พลังงานส่วนใหญ่จะถูกดูดกลืนหรือสะท้อน มีการส่งผ่านพลังงานน้อยมาก มักพบค่าต่ำลงในช่วงคลื่น 1.4 1.9 และ 2.7 ไมโครเมตร เพราะว่าในช่วงเหล่านี้ น้ำในใบพืชจะดูดกลืนพลังงาน จึงเรียกว่า ช่วงคลื่นดูดกลืนน้ำ (Water absorption bands) ดังนั้นค่าการสะท้อนพลังงานของใบพืชจึงแปรผกผันกับปริมาณน้ำในใบพืชด้วย

ดัชนีพืชพรรณ (Vegetation Index) เป็นค่าตัวเลขที่ได้มาจากข้อมูลการสำรวจระยะไกลซึ่งใช้ในการประเมินสุขภาพและผลผลิตของพืชพรรณ ดัชนีพืชพรรณอาศัยหลักการที่ว่า พืชที่มีสุขภาพดีจะสะท้อนแสงในย่านอินฟราเรดย่านใกล้ (Near-infrared) หรือ NIR ของสเปกตรัมแม่เหล็กไฟฟ้าได้มากกว่าในบริเวณที่มองเห็นได้ดัชนีพืชพรรณที่ใช้บ่อยที่สุดในการเกษตรคือดัชนีพืชพรรณชนิด Normalized Difference Vegetation Index (Jiang et al., 2020)

2.3.7.1 Normalized Difference Vegetation Index (NDVI) เป็นดัชนีพืชพรรณที่คำนวณจากการสะท้อนแสงในช่วงคลื่นแสงสีแดงจากการดูดกลืนแสงของใบพืช และช่วงคลื่น NIR ที่ได้จากกล้องถ่ายภาพหลายช่วงคลื่น โดยพืชไม่ดูดกลืนแสงในช่วงคลื่น NIR แต่จะกระเจิงแสงจากโครงสร้างของใบ มีค่าอยู่ในช่วงตั้งแต่ -1 ถึง 1 ค่าที่ใกล้เคียงกับ -1 หมายถึงดินหรือน้ำ ค่าที่ใกล้ 0 หมายถึงมีความหนาแน่นพืชพรรณต่ำ และค่าที่ใกล้ 1 หมายถึงมีพืชพรรณที่หนาแน่น NDVI มีความไวต่อการเปลี่ยนแปลงของปริมาณคลอโรฟิลล์ในพืช และสามารถใช้ตรวจจับการเปลี่ยนแปลงของสุขภาพพืช และผลผลิตได้ NDVI สามารถใช้ในการเกษตรเพื่อระบุความหนาแน่นของพืชผล ทำนาย

ผลผลิตของพืชผล และเพิ่มประสิทธิภาพการจัดการพืชผล ตัวอย่างเช่น สามารถใช้ข้อมูล NDVI เพื่อระบุพื้นที่ของแปลงที่พืชผลเติบโตได้ไม่ดี ซึ่งอาจบ่งชี้ถึงการขาดน้ำหรือสารอาหาร ข้อมูลนี้สามารถใช้เพื่อเพิ่มประสิทธิภาพการชลประทานและการให้ปุ๋ย นอกจากนี้ ยังสามารถใช้ข้อมูล NDVI เพื่อทำนายผลผลิตของพืช โดยระบุพื้นที่ของไร่ที่พืชเจริญเติบโตได้ดี และติดตามการเจริญเติบโตของพืชตลอดฤดูปลูก นอกจากนี้ ยังสามารถใช้ข้อมูล NDVI เพื่อระบุตำแหน่งที่ศัตรูพืช วัชพืช และโรคพืชที่อาจส่งผลกระทบต่อพืชในแปลง ตัวอย่างเช่น สามารถใช้ข้อมูล NDVI เพื่อตรวจจับการเปลี่ยนแปลงของสุขภาพพืชที่เกิดจากศัตรูพืชและโรค และเพื่อระบุบริเวณภายในแปลงที่มีศัตรูพืช และโรคระบาดมากที่สุด (Tucker, 1979) สมการคำนวณดัชนี NDVI แสดงดังสมการที่ 2.3

$$NDVI = (NIR - Red)/(NIR + Red) \quad (2.3)$$

2.3.7.2 Excess Green index (ExG) คำนวณโดยการลบการสะท้อนแสงสีแดงและสีน้ำเงินออกจากการสะท้อนแสงสีเขียวสองเท่า ExG มีความไวต่อการเปลี่ยนแปลงของปริมาณคลอโรฟิลล์ของพืช และสามารถประเมินสุขภาพและผลผลิตของพืชได้ โดยค่า ExG สูงบ่งชี้ว่าพืชมีสุขภาพแข็งแรง มีความเป็นพืชพรรณใบเขียวหนาแน่นอย่างอุดมสมบูรณ์ ในขณะที่ค่า ExG ต่ำบ่งชี้ว่าพืชเครียดหรือไม่แข็งแรง (Woebbecke, Meyer, Von Bargen and Mortensen, 1995) สมการคำนวณดัชนี ExG แสดงดังสมการที่ 2.4

$$ExG = 2g - r - b \quad (2.4)$$

โดยที่	r	เป็นค่า normalized ของความยาวคลื่นแสงสีแดง คำนวณได้จาก $r = Red/(Red + Green + Blue)$
	g	เป็นค่า normalized ของความยาวคลื่นแสงสีเขียว คำนวณได้จาก $g = Green/(Red + Green + Blue)$
	b	เป็นค่า normalized ของความยาวคลื่นแสงสีน้ำเงิน คำนวณได้จาก $b = Blue/(Red + Green + Blue)$

2.3.7.3 Green Red Vegetation Index (GRVI) ดัชนี GRVI เป็นดัชนีที่คำนวณจากภาพถ่าย RGB โดยมีลักษณะคล้ายกับดัชนี NDVI แต่จะใช้แสงในช่วงคลื่นสีเขียวมาทดแทนการใช้ช่วงคลื่น NIR โดยเป็นดัชนีพืชพรรณที่อิงตามความแตกต่างระหว่างการสะท้อนแสงของพืชในแถบสีเขียวและการสะท้อนแสงของพืชในแถบสีแดง GRVI มีความไวต่อการเปลี่ยนแปลงของปริมาณคลอโรฟิลล์ของพืช และสามารถประเมินสุขภาพและผลผลิตของพืชได้ ค่า GRVI ที่สูงบ่งชี้ถึงพืชพรรณที่แข็งแรงเช่นเดียวกับ ExG อย่างไรก็ตาม GRVI อาจได้รับผลกระทบจากการมีอยู่ของเมฆที่บดบังแสงในพืช เช่น แครอทินอยด์ และแอนโทไซยานิน ทำให้ค่าดัชนีมีการเปลี่ยนแปลงค่อนข้างสูง (Starý, Jelínek, Kumhálová and Chyba, 2020) สมการคำนวณดัชนี GRVI แสดงดังสมการที่ 2.5

$$GRVI = (Green - Red)/(Green + Red) \quad (2.5)$$

การเลือกดัชนีพืชที่เหมาะสมจึงขึ้นอยู่กับชนิดของพืช สภาพพื้นที่ และข้อมูลที่เป็นจำเป็น โดย NDVI ถือเป็นดัชนีพืชพรรณที่ใช้บ่อยที่สุดในภาคการเกษตร แต่ดัชนีอื่น ๆ อาจเหมาะสมกว่าสำหรับการใช้งานตามวัตถุประสงค์เฉพาะที่ต้องการ นอกจากนี้ยังมีดัชนีพืชพรรณอื่น ๆ เช่น Soil Adjusted Vegetation Index (SAVI), Enhanced Vegetation Index (EVI), Transformed Vegetation Index (TVI), Simple Ratio (SR), Photochemical Reflectance Index (PRI) เป็นต้น


2.4 ปัญญาประดิษฐ์

2.4.1 นิยามของปัญญาประดิษฐ์

คำว่า ปัญญาประดิษฐ์ หรือ Artificial Intelligence (AI) ถูกคิดขึ้นโดย จอห์น แมคคาธิ (John McCarthy) และทีมวิจัยเรื่องทฤษฎีอัตโนมัติในงานประชุมที่ Dart-mouth Collage เมื่อปี ค.ศ. 1956 (พ.ศ. 2499) โดยนิยามของปัญญาประดิษฐ์ คือ เครื่องจักรที่มนุษย์ไม่สามารถแยกแยะได้ว่าสิ่งนั้นคืออะไรระหว่างเครื่องจักรหรือมนุษย์ด้วยตนเอง ผ่านการตอบโต้กันเป็นอย่างดี นิยามนี้ถูกคิดขึ้นก่อนที่จะมีคำว่าปัญญาประดิษฐ์ โดยนักประดิษฐ์ที่มีชื่อเสียงชาวอังกฤษที่ชื่อว่า อัลัน ทัวริง (Alan Turing) ผู้ซึ่งมีผลงานร่วมกับทีมในการประดิษฐ์เครื่องถอดรหัสที่ชื่อว่า Bombe ให้แก่กองทัพฝ่ายสัมพันธมิตรไว้ใช้สำหรับถอดรหัสลับของฝ่ายอักษะที่ใช้เครื่องส่งรหัสลับชื่อว่า Enigma machine ที่กองทัพนาซีใช้ในการส่งข้อความปฏิบัติการทางการทหาร เครื่อง Bombe นี้เองที่เป็นแรงบันดาลใจให้ทัวริงมีแนวคิดเรื่องการเรียนรู้ของเครื่องจักรหรือปัญญาประดิษฐ์ในบทความที่ชื่อว่า Computing Machinery and Intelligence ในปี ค.ศ. 1950 (พ.ศ. 2493) โดยได้นิยามผ่าน

แบบทดสอบที่ถูกคิดค้นขึ้นเรียกว่า Turing Test อย่างไรก็ตามหากจะแบ่งที่มาของความฉลาดที่เครื่องจักรมีได้นั้น สามารถแบ่งออกได้ 2 วิธีคือ

1. ความฉลาดที่เกิดจากการที่มนุษย์กำหนดขึ้นให้แก่เครื่องจักร เช่น วิธีการคำนวณ
2. ความฉลาดที่เกิดจากการที่เครื่องจักรเรียนรู้ได้ด้วยตนเองผ่านข้อมูล หรือการลองผิดต่าง ๆ เพื่อนำมาใช้ในการตัดสินใจ (สมถ์ ชินประสาทศักดิ์, ปรีชาพล อินทร์สุข, นันทนัช พุฒาม ปือก และณัฐพล สนพะเนาว์, 2566)



รูปที่ 2.27 การพัฒนาเครื่องถอดรหัส Bombe

นักคณิตศาสตร์ได้นำเสนอวิธีการคำนวณทางคณิตศาสตร์ผ่านทางอัลกอริทึม (Algorithm) ต่าง ๆ ที่ทำให้คอมพิวเตอร์สามารถเรียนรู้ได้ด้วยตนเอง เช่น Perceptron, Nearest neighbor, Q-learning, Random forest และ Support vector machine เป็นต้น อัลกอริทึมเหล่านี้ได้รับการพัฒนาและต่อยอดต่อมา และเกิดศาสตร์ใหม่ที่ศึกษาการทำให้คอมพิวเตอร์สามารถเรียนรู้ได้ด้วยตนเองขึ้น


ซอฟต์แวร์ตัวแรกที่แสดงให้เห็นถึงความสามารถของคอมพิวเตอร์ที่สามารถเรียนรู้ได้ด้วยตนเองนั้นถูกพัฒนาขึ้นโดย อาเธอร์ ซามูเอล (Arthur Samuel) ในปี ค.ศ. 1956 (พ.ศ. 2499) ในชื่อ Checker ซึ่งทำงานบนเครื่องคอมพิวเตอร์ IBM 701 สำหรับเล่นเกมหมากรุกฮอส ที่มีการเรียนรู้และทำการกำหนดกลยุทธ์ในการเดินด้วยตนเอง โดยใช้วิธีกำจัดเส้นทางที่ไม่ต้องการเดินออกไป ความสำเร็จแรกเริ่มของ Checker นี้เองทำให้ซามูเอลได้ให้นิยามของ การเรียนรู้ของเครื่อง (Machine learning) ไว้ว่า “เป็นสาขาการศึกษาที่ช่วยให้คอมพิวเตอร์สามารถเรียนรู้ได้ด้วยตนเองโดยไม่ต้องตั้งโปรแกรมไว้ให้อย่างชัดเจน” (เจรอน, 2566; วรากรณ์ พรหมวิอินทร์, 2566)



รูปที่ 2.28 การพัฒนาซอฟต์แวร์ Checker บนคอมพิวเตอร์ IBM 701

2.4.2 การเรียนรู้ของเครื่อง

ในการพัฒนาความสามารถของคอมพิวเตอร์ให้สามารถทำงานได้ตามประสงค์นั้น ผู้พัฒนาจะต้องทำการเขียนโปรแกรมขึ้นผ่านการใช้ภาษาคอมพิวเตอร์ในการกำหนดกฎ (Rule) ต่าง ๆ โดยอาจเป็นวิธีการคำนวณหรือกำหนดเงื่อนไขการทำงาน (Logic) เพื่อให้คอมพิวเตอร์สามารถทำงานได้อย่างถูกต้องตามเงื่อนไข หรือกฎที่ถูกตั้งเอาไว้ สิ่ง que การเรียนรู้ของเครื่องมีความโดดเด่นกว่า การเขียนโปรแกรมคอมพิวเตอร์แบบดั้งเดิม คือ มีการนำข้อมูล (Data) มาใช้ให้คอมพิวเตอร์เรียนรู้ จากข้อมูลที่ให้นั้นผ่านอัลกอริทึมต่าง ๆ แล้วสร้างแบบจำลอง (Model) ขึ้นมาไว้สำหรับนำไปใช้งาน ต่อไปได้ (กอบเกียรติ สระอุบล, 2563; โมโรนีย์, 2564)




รูปที่ 2.29 การเขียนโปรแกรมแบบดั้งเดิม และการเรียนรู้ของเครื่อง

ความโดดเด่นของการเรียนรู้ของเครื่องอยู่ที่สามารถแก้โจทย์ที่ซับซ้อนและยากในการวางกฎให้ครอบคลุมได้โดยมนุษย์ และประโยชน์อีกอย่างหนึ่งคือ การเรียนรู้ของเครื่องสามารถกลับมาสอนมนุษย์เองได้ โดยช่วยให้มนุษย์เข้าใจปัญหาหรือโจทย์ได้ดียิ่งขึ้น เพราะการเรียนรู้ของเครื่องมีการสังเกตรูปแบบของข้อมูล (Pattern) ได้อย่างละเอียดถี่ถ้วนในเวลาอันรวดเร็วกว่าการสังเกตโดยมนุษย์ อีกทั้งการเรียนรู้ของเครื่องอาจชี้ให้เห็นถึงรูปแบบที่ไม่เคยเห็นมาก่อน หรือยากต่อ

การสังเกตได้ (เจอร์อน, 2566) อาจกล่าวได้ว่าการเรียนรู้ของเครื่องมีความเหมาะสมกับปัญหาดังต่อไปนี้

- 1) ปัญหาที่จำเป็นต้องกำหนดกฎและเงื่อนไขจำนวนมาก
- 2) ปัญหาที่ซับซ้อนมากไม่อาจใช้วิธีการคิดโดยมนุษย์ได้
- 3) ปัญหาที่สภาพแวดล้อม หรือสถานการณ์มีการเปลี่ยนแปลงผันผวนอยู่ตลอดเวลา
- 4) ปัญหาที่มีข้อมูลมีจำนวนมาก

ความสามารถเหล่านี้เองทำให้การเรียนรู้ของเครื่องถูกนำมาใช้ในการแก้ปัญหาในสถานการณ์ที่หลากหลายโดยเฉพาะอย่างยิ่งในปัญหาการทำนาย (Prediction) และการจำแนก (Classification) การศึกษาการใช้คอมพิวเตอร์เพื่อแก้ปัญหาด้วยการเรียนรู้ของเครื่อง และการพัฒนาปัญญาประดิษฐ์นั้นจัดอยู่ในศาสตร์ที่เรียกว่า วิทยาการคอมพิวเตอร์ (Computer Science) ที่เป็นการศึกษาในเรื่องการเขียนโปรแกรมคอมพิวเตอร์ การเรียนรู้ของเครื่อง ปัญญาประดิษฐ์ การทำเหมืองข้อมูล (Data mining) อีกทั้งยังครอบคลุมไปถึงวิทยาศาสตร์ข้อมูล (Data science) ที่เป็นการสกัดเอาความรู้ และข้อมูลเชิงลึก (Insight) ออกมาจากข้อมูลดิบด้วยวิธีการใช้คอมพิวเตอร์เป็นเครื่องมือ (วารกรณ์ พรหมวิอินทร์, 2566)



รูปที่ 2.30 ขอบข่ายการศึกษาใน Computer science

แม้ว่าปัญญาประดิษฐ์จะอยู่ในขอบข่ายของวิทยาการคอมพิวเตอร์ แต่มีเพียงปัญญาประดิษฐ์เท่านั้นที่มี Intelligence Agent หรือตัวแทนอัจฉริยะ มีหน้าที่ในการแก้ไขปัญหาไป

ตามการเปลี่ยนแปลงของสิ่งแวดล้อมผ่านทางเซ็นเซอร์ และตอบสนองการทำงานผ่านทาง Actuator โดยตัวแทน (Agent) จะทำงานผ่าน Actuator แตกต่างกันไปตามสิ่งที่เซ็นเซอร์สามารถจับค่าได้ โดยหากต้องการให้เครื่องจักรมีความสามารถที่หลากหลายอาจต้องมีการใช้งานแบบหลายตัวแทน ที่สามารถสื่อสารกันไปมาได้ด้วยภาษาสื่อสารระหว่างกัน (Protocol) การที่ตัวแทนจำนวนมากสามารถทำงานสอดคล้องกันได้อย่างลงตัวและบรรลุวัตถุประสงค์ได้อย่างชาญฉลาดนั้นเป็นตัวชี้วัดความฉลาดของตัวแทนอัจฉริยะ ความสามารถและความฉลาดของตัวแทนนี้เองทำให้ทัวริง ได้สร้างเกณฑ์ในการกำหนดความฉลาดของปัญญาประดิษฐ์ออกเป็น 7 ข้อ ดังนี้

- 1) ต้องสามารถสื่อสารด้วยภาษาสื่อสารของมนุษย์ หรือสามารถประมวลผลภาษาธรรมชาติ (Neural language procession) ภาษาใดภาษาหนึ่งได้อย่างสมบูรณ์
- 2) ต้องสามารถเข้าใจเสียงและคำพูด (Speech recognition) เพื่อให้สามารถโต้ตอบสื่อสารได้
- 3) ต้องสามารถเข้าใจวัตถุและภาพ (Computer Vision) หรือคอมพิวเตอร์วิทัศน์ เพื่อให้สามารถวิเคราะห์และตัดสินใจในข้อมูลภาพได้
- 4) ต้องสามารถวางแผน กำหนดการทำงาน และปรับปรุงประสิทธิภาพเพื่อให้ได้ผลลัพธ์เป็นค่าเหมาะสมที่สุด (Optimization) ได้ด้วยตนเอง
- 5) หากเป็นวิทยาการหุ่นยนต์ (Robotics) อุปกรณ์ของหุ่นยนต์ ต้องสามารถรับรู้และโต้ตอบกับสิ่งแวดล้อมได้ทุกสถานการณ์
- 6) หากเป็นระบบผู้เชี่ยวชาญ (Expert System) ต้องสามารถตัดสินใจและวางแผนได้ทุกเมื่อโดยใช้ข้อมูลที่เตรียมเอาไว้
- 7) หากเป็นการเรียนรู้ของเครื่อง ต้องสามารถทำนายหรือจำแนกจากข้อมูลได้ด้วยตนเอง

การกำหนดความฉลาดของปัญญาประดิษฐ์เหล่านี้เองที่ได้กลายมาเป็นแขนงย่อยของปัญญาประดิษฐ์ โดยการเรียนรู้ของเครื่องก็เป็นหนึ่งในแขนงย่อยของปัญญาประดิษฐ์อีกทีหนึ่งด้วยเช่นกัน สำหรับแนวทางในการพัฒนาการเรียนรู้ของเครื่องมีขั้นตอนหลัก 7 ขั้นตอน (ปิยะนากสงศ์, 2566) ดังนี้

- 1) ระบุปัญหาที่สนใจ และรวบรวมข้อมูลที่เกี่ยวข้อง
- 2) กระบวนการเตรียมข้อมูลทำความสะอาดข้อมูล (Data cleaning) การเลือกค่าตัวแปรหรือคุณลักษณะเด่น (Feature selection) และตัวแปรเป้าหมาย (Target) เพื่อจัดทำชุดข้อมูล (Dataset)
- 3) ออกแบบแบบจำลองโดยเลือกใช้อัลกอริทึมที่เหมาะสม
- 4) ฝึกฝนแบบจำลอง (Train model) โดยใช้ชุดข้อมูลที่มีอยู่

- 5) ประเมินประสิทธิภาพของแบบจำลอง (Evaluation model)
- 6) ปรับปรุงประสิทธิภาพของแบบจำลองโดยการปรับค่าตัวแปรเกิน (Hyperparameter tuning)
- 7) การนำแบบจำลองมาใช้งาน เช่น การทำนาย, การจับกลุ่ม หรือการจำแนกประเภท

2.4.3 เครื่องมือสำหรับการเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่องเป็นวิทยาการที่ต้องอาศัยการเขียนโปรแกรมคอมพิวเตอร์ในการจัดเตรียมข้อมูล การฝึกฝนแบบจำลอง การประเมินประสิทธิภาพ การปรับปรุงแบบจำลอง และการนำแบบจำลองไปใช้งานต่อ โดยภาษาคอมพิวเตอร์ที่นิยมใช้อย่างมากในการพัฒนาการเรียนรู้ของเครื่อง คือ ภาษาไพธอน (Python) และภาษา R โดยภาษาไพธอนได้รับความนิยมอย่างสูงในปัจจุบันเนื่องจากมีจุดเด่นในเรื่องความง่ายต่อการทำความเข้าใจ มีชุดคำสั่ง หรือไลบรารี (Library) และเฟรมเวิร์ก (Framework) ให้เลือกใช้งานจำนวนมาก และสามารถใช้งานข้ามแพลตฟอร์ม (Platform) ได้อย่างอิสระ (ปิยะ นากสงค์, 2566) สำหรับแพลตฟอร์มและไลบรารีที่สนับสนุนการทำงานของเครื่องเรียนรู้ของเครื่องมีหลายชนิด และใช้ในวัตถุประสงค์ที่แตกต่างกัน ดังนี้

- 1) Pandas เป็นชุดคำสั่งแบบรหัสเปิดที่ช่วยในการจัดการและวิเคราะห์ข้อมูลได้อย่างรวดเร็ว โดยเฉพาะข้อมูลในรูปแบบของตาราง หรือ Data Frame
- 2) Numpy เป็นชุดคำสั่งแบบรหัสที่ใช้ในการคำนวณทางวิทยาศาสตร์ และการดำเนินการกับอาร์เรย์ (Array) หรือข้อมูลชนิดเดียวกันที่ถูกจัดเก็บไว้ด้วยกันแบบเรียงต่อกัน
- 3) Matplotlib เป็นชุดคำสั่งที่ใช้ในการแสดงภาพข้อมูล (Data visualization) เช่น แผนภาพ กราฟ และกราฟการกระจายต่าง ๆ
- 4) Seaborn เป็นชุดคำสั่งที่ใช้สำหรับการนำเสนอข้อมูลทางสถิติ อีกทั้งยังสนับสนุนการทำงานของ Matplotlib ในการแสดงภาพข้อมูล
- 5) Scikit-Learn เป็นชุดคำสั่งที่ใช้ในการสร้างแบบจำลองการเรียนรู้ของเครื่องในภาษาไพธอน และแบบจำลองทางสถิติอื่น ๆ เช่น การถดถอย (Regression), การจับกลุ่ม (Clustering) และการลดมิติข้อมูล (Dimensional reduction)
- 6) TensorFlow เป็นแพลตฟอร์มแบบรหัสเปิดที่ประกอบด้วยชุดคำสั่งในการพัฒนาและใช้งานแบบจำลองการเรียนรู้ของเครื่องเช่นเดียวกับ Scikit-Learn อีกทั้งยังสามารถเรียกใช้ไลบรารีใน API สำหรับสร้างแบบจำลองสำเร็จรูป เช่น Keras สามารถถ่ายโอนแบบจำลองข้ามแพลตฟอร์มเพื่อใช้งานบนเว็บไซต์, ระบบคลาวด์ (Cloud system) และอุปกรณ์มือถือ (Smart phone) ได้อย่างอิสระ

7) Keras เป็นชุดคำสั่งที่สนับสนุนการทำงานของ TensorFlow ในการสร้างแบบจำลองการเรียนรู้ของเครื่องแบบสำเร็จรูป

ในการใช้งานชุดคำสั่งหรือแพลตฟอร์มต่าง ๆ สำหรับการเรียนรู้ของเครื่อง มีเครื่องมือที่หลากหลายในการเขียนโปรแกรมเพื่อเรียกใช้งาน โดยเครื่องมือที่เรียกว่า IDE หรือ Integrated Development Environment เป็นที่นิยมอย่างมากในการเขียนโปรแกรมมากกว่าการเขียนผ่าน Text Editor ปกติเนื่องจากมีความสามารถในการเขียนโปรแกรมบน Source code editor มีตัวช่วยในการตรวจจับความผิดพลาด (Debugger) และมีตัวแปลภาษาภายในตัว IDE บางตัวยังสามารถเรียกใช้งานชุดคำสั่งที่จำเป็นสำหรับการเขียนโปรแกรมภาษาต่าง ๆ ได้ อีกด้วย (อรพิน ประวัติดิษฐ์, 2564)


1) Jupyter Notebook เป็น IDE สำหรับเขียนโปรแกรมที่สามารถประมวลผลโต้ตอบกับผู้ใช้งานได้ทันที รองรับการทำงานกับโปรแกรมภาษาต่าง ๆ เช่น R, Julia, Haskell และไพธอน การทำงานจะทำงานอยู่บนเว็บเบราว์เซอร์ (Web browser) โดยโค้ด (code) ของโปรแกรมจะเก็บอยู่ในรูปแบบของสมุดบันทึก (Notebook) ที่สามารถบรรจุโค้ด ตัวอักษร สูตรคำนวณ กราฟ และรูปภาพได้ อีกทั้งยังสามารถเรียกใช้ชุดคำสั่งและประมวลผลได้อย่างสะดวก การทำงานของ Jupyter Notebook สามารถปรับให้อยู่บนระบบคลาวด์ได้ เช่น Google Colaboratory ของบริษัท Google และ Azure Notebook ของบริษัท Microsoft

2) Anaconda เป็นเครื่องมือรหัสเปิดสำหรับวิทยาศาสตร์ข้อมูล และการเรียนรู้ของเครื่อง มีความสามารถในการรองรับการเขียนโปรแกรมในภาษา R และ Python มีแพ็คเกจ (Package) และไลบรารีที่จำเป็นมากมายสำหรับใช้งานบน Jupyter Notebook มีอินเทอร์เฟซสำหรับเรียกใช้แอปพลิเคชันต่าง ๆ โยไม่ต้องพิมพ์คำสั่งผ่าน Command line อีกทั้งยังสามารถเรียกใช้ GPU เช่น NVIDIA GeForce และ Tesla เพื่อเพิ่มประสิทธิภาพในการประมวลผลได้ (ปิยะ นากสงค์, 2566)



รูปที่ 2.31 Anaconda Navigator และแอปพลิเคชันภายใน

3) Google Colaboratory เป็นเครื่องมือของบริษัท Google สำหรับการเขียนโปรแกรมและประมวลผลในภาษาไพธอน สามารถแสดงผลโต้ตอบได้เช่นเดียวกับ Jupyter Notebook ทำงานอยู่บนระบบคลาวด์โดยสามารถใช้งานผ่านบัญชี Gmail สามารถนำเข้าและบันทึกสมุดบันทึกได้บน Google Drive, อัปโหลดและแชร์ไฟล์ได้, นำเข้าและส่งไฟล์ไปยัง Github, นำเข้าชุดข้อมูลจากแหล่งอื่น, มีการรวบรวมชุดคำสั่งไว้จำนวนมาก และประมวลผลบน GPU ที่อยู่ในระบบคลาวด์ นอกจากนี้ยังมีเครื่องมืออื่น ๆ อีกที่ไม่ได้กล่าวถึง เช่น PyCharm และ PythonIDE เป็นต้น



รูปที่ 2.32 สมุดบันทึกของ Google Colaboratory

2.4.4 ข้อมูลและการเตรียมชุดข้อมูล

แบบจำลองการเรียนรู้ของเครื่องจะถูกสร้างขึ้นโดยได้รับการฝึกฝนจากชุดข้อมูล กระบวนการฝึกฝนนี้เกี่ยวข้องกับการปรับค่าตัวแปรของแบบจำลอง เพื่อให้สามารถทำนายหรือตัดสินใจเกี่ยวกับข้อมูลฝึกฝนได้อย่างแม่นยำ โดยเมื่อแบบจำลองได้รับการฝึกฝนแล้วจะสามารถใช้ทำนายหรือตัดสินใจเกี่ยวกับข้อมูลใหม่ที่ไม่เคยถูกใช้ในการฝึกฝนมาก่อน

สำหรับชุดข้อมูล คือ กลุ่มของข้อมูลที่ใช้ในการฝึกฝน ตรวจสอบ และทดสอบแบบจำลอง ชุดข้อมูลจะถูกใช้เพื่อสอนแบบจำลองถึงวิธีการทำนายหรือตัดสินใจเกี่ยวกับข้อมูลใหม่ที่ไม่เคยได้รับมาก่อน ชุดข้อมูลโดยทั่วไปประกอบด้วยชุดของค่ารับเข้า (Input) เรียกอีกอย่างว่าคุณลักษณะ (feature) หรือตัวทำนาย (Predictor) และค่าส่งออก (Output) ที่สอดคล้องกันเรียกอีกอย่างว่าป้ายกำกับ (Label) หรือเป้าหมาย (Target) กล่าวได้ว่า ค่ารับเข้า คือตัวแปรที่ใช้ในการทำนาย และค่าส่งออก คือตัวแปรที่แบบจำลองพยายามทำนาย (กิตติสุชาติ พสุภา, 2564) ชุดข้อมูลแบ่งออกเป็น 3 ประเภท คือ ข้อมูลชุดฝึกฝน ข้อมูลชุดตรวจสอบ และข้อมูลชุดตรวจสอบ

1) ข้อมูลชุดฝึกฝน (Training set) ใช้เพื่อฝึกฝนแบบจำลองโดยการปรับค่าตัวแปรของแบบจำลองเพื่อให้สามารถทำนายข้อมูลสำหรับฝึกฝนได้อย่างแม่นยำ

2) ข้อมูลชุดตรวจสอบ (Validation set) ใช้เพื่อตรวจสอบความถูกต้องของแบบจำลอง โดยทดสอบประสิทธิภาพกับข้อมูลใหม่ที่ไม่เคยเห็นมาก่อน ชุดข้อมูลนี้ใช้เพื่อปรับแต่งแบบจำลองอย่างละเอียด และตรวจสอบให้แน่ใจว่าไม่เกิดการเรียนรู้ที่เหมาะสมกับข้อมูลมากเกินไป

3) ข้อมูลชุดตรวจสอบ (Test set) เพื่อทดสอบประสิทธิภาพขั้นสุดท้ายของแบบจำลอง โดยการประเมินความถูกต้องของแบบจำลอง

ชุดข้อมูลมีความสำคัญต่อการเรียนรู้ของเครื่อง เนื่องจากหากไม่มีชุดข้อมูลก็ไม่สามารถฝึกฝนหรือทดสอบแบบจำลองได้ คุณภาพและขนาดของชุดข้อมูลส่งผลกระทบต่อประสิทธิภาพและความแม่นยำของแบบจำลอง โดยสิ่งสำคัญ คือ ชุดข้อมูลต้องเป็นตัวแทนของปัญหาในโลกแห่งความเป็นจริง และมีความหลากหลาย รวมไปถึงมีปริมาณที่มากพอจะใช้ในการฝึกฝนแบบจำลองได้

ในการเตรียมชุดข้อมูลมีขั้นตอนที่สำคัญขั้นตอนหนึ่งคือ การทำความสะอาดข้อมูล โดยเป็นกระบวนการตรวจสอบ แก้ไข ปรับแต่งโครงสร้างของข้อมูลบางส่วน เพื่อให้ข้อมูลมีคุณภาพเหมาะสมเพียงพอต่อการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง วิธีการสำคัญในการทำความสะอาดข้อมูลมีดังนี้

1) ตรวจสอบข้อมูลสูญหาย (Missing data หรือ Missing value) เกิดจากการที่ข้อมูลในบางช่องของตารางข้อมูลสูญหายไปเนื่องจากกระบวนการเก็บข้อมูลที่ผิดพลาด มีวิธีการจัดการคือลบแถว (row) ที่มีข้อมูลบางคอลัมน์ (column) ไม่สมบูรณ์ออกไปทั้งแถว หรือหากคอลัมน์นั้นไม่มีความสำคัญอาจพิจารณาลบคอลัมน์นั้นออกไปแทนการลบแถว อีกวิธีหนึ่งคือการแทนที่ข้อมูลด้วยค่าต่าง ๆ เช่น แทนที่ช่องที่สูญหายด้วยค่าเดียวกันทั้งหมด, แทนที่ด้วยค่าเฉลี่ย, แทนที่ด้วยค่าข้างเคียง และแทนที่ด้วยค่าจากสมการทางสถิติ (กอบเกียรติ สระอุบล, 2563)

2) ข้อมูลซ้ำ กรณีนี้ทำได้โดยการลบข้อมูลที่ซ้ำซ้อนออกไปจากชุดข้อมูล

3) ค่าผิดปกติ (Outlier) คือข้อมูลที่มีความผิดปกติไปจากชุดข้อมูล เช่น มีค่าแตกต่างกันมากกับข้อมูลในคอลัมน์เดียวกัน โดยอาจส่งให้ประสิทธิภาพของแบบจำลองลดลง การจัดการค่าผิดปกติทำได้โดยการลบค่าผิดปกตินั้นออกไปจากชุดข้อมูล

4) ข้อมูลที่ไม่ได้เป็นข้อมูลตัวเลข (Numerical data) จะต้องทำการแปลงให้เป็นตัวเลขก่อน ด้วยวิธีที่เรียกว่า Data Encoding หรือการเข้ารหัสข้อมูล โดยข้อมูลที่มีการเรียงลำดับอย่างชัดเจน (Ordinal) จะใช้เทคนิคที่เรียกว่า Ordinal Encoding ส่วนข้อมูลที่ไม่มีการลำดับข้อมูลชัดเจน (Nominal) จะใช้วิธี One Hot Encoding

ภายหลังจากการทำความสะอาดข้อมูลแล้วสิ่งที่จะต้องพิจารณาอีกอย่างหนึ่ง คือ การปรับค่าของตัวแปรให้มีค่าอยู่ในช่วงเดียวกัน เรียกว่า Feature Scaling โดยขั้นตอนนี้จะช่วยลดทรัพยากรในการประมวลผลให้น้อยลง อีกทั้งยังส่งผลโดยตรงต่อความแม่นยำของแบบจำลองประเภท distance-based เช่น K-Nearest Neighbor และ Support Vector Machine และแบบจำลองประเภท Gradient-based เช่น Regression และ Deep Learning อีกด้วย (มฤณ ชินประสาทศักดิ์ และคณะ, 2566) การทำ Feature Scaling ที่นิยมได้แก่ Min-Max Scaling และ Standardization

Min-Max Scaling เป็นเทคนิคการทำข้อมูลให้เป็นค่ามาตรฐาน (Normalization) โดยการปรับค่าของข้อมูลให้อยู่ในช่วง 0 ถึง 1 โดยค่าที่มากที่สุดจะถูกแปลงค่าเป็น 1 และค่าที่น้อยที่สุดจะถูกแปลงค่าเป็น 0 การเลือกใช้งาน Min-Max Scaling จะถูกนำมาใช้งานเมื่อไม่รู้ลักษณะการกระจายตัวของข้อมูล โดยหากข้อมูลมีค่าผิดปกติมากจะส่งผลต่อการทำ Min-Max Scaling มากด้วยเช่นกัน วิธีการคำนวณแสดงดังสมการที่ 2.6

$$\acute{x} = \frac{X - X_{min}}{X_{min} - X_{max}} \quad (2.6)$$

โดยที่	X	คือ	ตัวแปรต้นที่พิจารณา
	X_{min}	คือ	ค่าน้อยที่สุดของตัวแปรต้นที่พิจารณา
	X_{max}	คือ	ค่ามากที่สุดของตัวแปรต้นที่พิจารณา
	$\acute{x}$	คือ	ค่าตัวแปรต้นใหม่ที่ได้

Standardization เป็นการปรับค่าของข้อมูลให้ค่าเฉลี่ย (mean) มีค่าเท่ากับ 0 และมีส่วนเบี่ยงเบนมาตรฐาน (Standard deviation) มีค่าเท่ากับ 1 การทำ Standardization จะตอบสนองต่อค่าผิดปกติที่น้อยกว่า Min-Max Scaling และจะถูกนำมาใช้เมื่อกระจายตัวของข้อมูลมีการกระจายแบบปกติ วิธีการคำนวณแสดงดังสมการที่ 2.7

$$\acute{x} = \frac{X - \bar{X}}{SD} \quad (2.7)$$

โดยที่	$\bar{X}$	คือ	ค่าเฉลี่ยของตัวแปรต้นที่พิจารณา
	SD	คือ	ส่วนเบี่ยงเบนมาตรฐานของตัวแปรต้นที่พิจารณา

2.4.5 การแบ่งประเภทการเรียนรู้ของเครื่อง

ภายหลังจากที่มีการกำหนดปัญหาและจัดเตรียมข้อมูลแล้ว จะต้องมีการเลือกใช้งานแบบจำลองที่เหมาะสมกับปัญหาผ่านการทำความเข้าใจลักษณะการเรียนรู้ของแบบจำลองชนิดต่างกัน สำหรับการเรียนรู้ของเครื่องสามารถแบ่งชนิดของแบบจำลองออกได้เป็น 4 ประเภทจากลักษณะการเรียนรู้ ดังนี้

2.4.5.1. การเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นประเภทการเรียนรู้ของเครื่องที่พบได้มากที่สุด เป็นการป้อนข้อมูลชุดฝึกฝนที่มีการติดป้ายกำกับให้กับอัลกอริทึม โดยข้อมูลที่ถูกติดป้ายกำกับ (Labeled data) คือ ข้อมูลที่มีการระบุค่าเป้าหมายไว้อย่างชัดเจน เพื่อให้คอมพิวเตอร์สามารถเรียนรู้และใช้ในการทำนายค่าเป้าหมายของชุดข้อมูลอื่นได้ การติดป้ายกำกับนั้นต้องผ่านกระบวนการเตรียมชุดข้อมูลที่มีขนาดใหญ่เพียงพอโดยอาศัยผู้เชี่ยวชาญในสาขาที่เกี่ยวข้อง ก่อนที่จะนำค่านี้มาใช้ในการฝึกฝนแบบจำลอง เพื่อให้มั่นใจได้ว่าแบบจำลองได้รับการฝึกฝนด้วยการใช้ข้อมูลที่ต้องเพียงพอ (วรารักษ์ พรหมวิวัฒน์, 2566)

คำว่าเป้าหมาย และป้ายกำกับ มีความหมายนัยเดียวกันและอาจใช้เหมือนกันได้ แต่คำว่า เป้าหมาย จะพบในการอธิบายแบบจำลองการถดถอย ส่วนคำว่า ป้ายกำกับ จะพบในแบบจำลองการจำแนกประเภท (เจรอน, 2566) นอกจากนี้ คำว่าคุณสมบัติ ยังมีความหมายเดียวกันกับคำว่า ตัวทำนาย หรือแอตทริบิวต์ (Attribute)

การเรียนรู้ของเครื่องสามารถแบ่งออกได้เป็น 2 ประเภทย่อยตามลักษณะของวัตถุประสงค์การใช้งานคือ การถดถอย (Regression) และการจำแนก (Classification)

1) การถดถอย เป็นแบบจำลองที่ใช้ในการทำนายค่าเป้าหมายที่เป็นค่าตัวเลขต่อเนื่อง อัลกอริทึมที่สำคัญของการถดถอย ได้แก่ Linear Regression

2) การจำแนก เป็นแบบจำลองที่ใช้ในการแบ่งชนิดของข้อมูลออกเป็นประเภท (Class) ตามที่ได้กำหนดไว้ โดยป้ายกำกับของข้อมูลจะเป็นค่าที่ไม่ต่อเนื่อง (Discrete value) อัลกอริทึมที่สำคัญของการจำแนกประเภท ได้แก่ Logistic Regression, K-Nearest Neighbor และ Support Vector Machine นอกจากนี้แบบอัลกอริทึมบางชนิดมีความสามารถทั้งในการทำนายและการจำแนก ได้แก่ Decision Trees, Random Forest, Naïve Bayes และโครงข่ายประสาทเทียม

2.4.5.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) หรือบางครั้งเรียกว่า Zero-shot learning เป็นการเรียนรู้ที่ข้อมูลไม่ได้รับการใส่ป้ายกำกับเอาไว้ หรือไม่ได้มีการระบุค่าเป้าหมายเอาไว้ แบบจำลองจะต้องค้นหารูปแบบ และความสัมพันธ์ในข้อมูลด้วยตัวของมันเอง เป้าหมายของการเรียนรู้แบบไม่มีผู้สอนคือการเปิดเผยโครงสร้างพื้นฐานของข้อมูล โดยไม่ต้องมีการเตรียมค่าจากผลลัพธ์ที่มีป้ายกำกับเอาไว้ วิธีการเรียนรู้แบบไม่มีผู้สอนมีหลายประเภทได้แก่ การจับ

กลุ่ม (Clustering), การลดขนาด (Dimensionality reduction), การเรียนรู้กฎความสัมพันธ์ (Association rule) และการตรวจจับความผิดปกติ (Anomaly detection) อัลกอริทึมการเรียนรู้แบบไม่มีผู้สอนที่เป็นที่รู้จักอย่างกว้างขวางคือ K-means clustering โดยเป็นอัลกอริทึมที่ใช้ในการจับกลุ่ม

2.4.5.3 การเรียนรู้แบบกึ่งสอน (Semi-supervised learning) เป็นการผสมผสานระหว่างการเรียนรู้แบบมีผู้สอนและแบบไม่มีผู้สอน ในการเรียนรู้ของเครื่องประเภทนี้แบบจำลองจะให้ข้อมูลที่มีป้ายกำกับบางส่วน และข้อมูลที่ไม่มีป้ายกำกับบางส่วน แนวคิดเบื้องหลังการเรียนรู้แบบกึ่งสอนคือการใช้ข้อมูลที่ติดป้ายกำกับเพื่อฝึกฝนแบบจำลอง จากนั้นใช้แบบจำลองเพื่อจัดประเภทหรือทำนายข้อมูลที่ไม่ได้ติดป้ายกำกับ การเรียนรู้แบบกึ่งสอนจะมีประโยชน์เมื่อข้อมูลที่มีป้ายกำกับหายากหรือมีต้นทุนในการหาข้อมูลที่สูง ช่วยให้สามารถปรับปรุงประสิทธิภาพของแบบจำลองได้โดยใช้ข้อมูลที่มีป้ายกำกับจำนวนน้อยลงและข้อมูลที่ไม่มีป้ายกำกับจำนวนมากขึ้น เทคนิคนี้ใช้กันอย่างแพร่หลายในการประมวลผลภาษาธรรมชาติ และงานด้านคอมพิวเตอร์วิทัศน์

2.4.5.4 การเรียนรู้แบบเสริมกำลัง (Reinforcement learning) แบบจำลองสำหรับการตัดสินใจในสถานการณ์ (Condition) ต่าง ๆ โดยแบบจำลองจะได้รับการฝึกฝนผ่านการลองผิด-ลองถูก เพื่อให้ได้รับสัญญาณรางวัล (Reward) เพิ่มขึ้นและเรียนรู้ที่จะตัดสินใจเพื่อนำไปสู่รางวัลสูงสุดหรือบรรลุเป้าหมาย (Goal) เมื่อเวลาผ่านไป การเรียนรู้แบบเสริมกำลังเป็นการเรียนรู้จากกระบวนการที่เกิดขึ้น โดยแบบจำลองจะเรียนรู้จากการสังเกตสถานการณ์ใหม่ที่เกิดขึ้นเพื่อเลือกการตัดสินใจที่ทำให้ได้รางวัลสูงสุด โดยมีเป้าหมายคือการเรียนรู้เชิงกลยุทธ์ ซึ่งนำไปใช้เป็นแผนการปฏิบัติเพื่อบรรลุเป้าหมาย จะสังเกตได้ว่าการเรียนรู้แบบเสริมกำลังเป็นแนวทางสำคัญในการพัฒนาตัวแทนอัจฉริยะ ตัวอย่างที่เป็นที่รู้จักกันทั่วโลกคือ อัลฟาโก (Alpha Go) ของบริษัท DeepMind ที่สามารถชนะเกมหมากล้อมในการแข่งขันกับแชมป์หมากล้อมได้ในปี ค.ศ. 2017 (เจอรอน, 2566)

2.4.6 การถดถอยเชิงเส้น

2.4.6.1 การถดถอยแบบเชิงเส้นอย่างง่าย (Simple linear regression) เป็นประเภทของการถดถอยเชิงเส้นที่มีตัวแปรอิสระและตัวแปรตามอย่างละหนึ่งตัวแปร โดยถูกใช้เพื่อสร้างแบบจำลองทางคณิตศาสตร์ที่มีความสัมพันธ์ในเชิงเส้นตรงระหว่างค่ารับเข้าและค่าส่งออก (ฆฤณ ชินประสาทศักดิ์ และคณะ, 2566; ปิยะ นากสงค์, 2566) แสดงได้ดังสมการที่ 2.8

$$Y = b_0 + b_1X \quad (2.8)$$

โดยที่	Y	คือ	ตัวแปรตาม
	X	คือ	ตัวแปรอิสระ
	b_0	คือ	สัมประสิทธิ์การถดถอยซึ่งเป็นจุดตัดบนแกน Y

b_1 คือ สัมประสิทธิ์การถดถอยซึ่งเป็นความชันของเส้นตรง

สมการที่ 2.8 แสดงถึงการเปลี่ยนแปลงในตัวแปรตามต่อการเปลี่ยนแปลงหนึ่งหน่วยในตัวแปรอิสระ เมื่อแบบจำลองได้รับการฝึกฝนแล้ว จะสามารถใช้ทำนายข้อมูลใหม่ที่ยังมองไม่เห็นได้

2.4.6.2 การถดถอยเชิงเส้นหลายตัวแปร (Multiple Linear Regression) คือ การถดถอยเชิงเส้นประเภทหนึ่งที่มีตัวแปรอิสระตั้งแต่สองตัวขึ้นไป กับตัวแปรตามหนึ่งตัวในการสร้างแบบจำลองความสัมพันธ์ระหว่างตัวแปรรับเข้าหลายตัว และตัวแปรส่งออกเพียงตัวเดียว แบบจำลองหรือสมการการถดถอยเชิงเส้นแบบหลายตัวแปร สามารถแสดงด้วยสมการที่ 2.9

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_NX_N \quad (2.9)$$

โดยที่	X_N	คือ	ตัวแปรอิสระ
	b_N	คือ	ค่าสัมประสิทธิ์ (Coefficient) หรือน้ำหนัก (Weight)
	N	คือ	จำนวนตัวแปรอิสระ N ตัว

เป้าหมายของการถดถอยเชิงเส้น คือ การหาค่าที่ดีที่สุดสำหรับที่ลดผลรวมของเศษเหลือกำลังสอง ค่าสัมประสิทธิ์เหล่านี้แสดงถึงความชันของเส้นสำหรับตัวแปรอิสระแต่ละตัว และค่าจุดตัดบนแกน y ซึ่งสามารถทำได้โดยใช้อัลกอริทึมการปรับให้เหมาะสม เช่น การเคลื่อนลงตามความชัน หรือการลดลงขั้นสุด การถดถอยเชิงเส้นถือว่าความสัมพันธ์เชิงเส้นระหว่างตัวแปรรับเข้าและส่งออก และพยายามค้นหาสมการความสัมพันธ์ที่ดีที่สุดที่เหมาะสมกับชุดข้อมูล (กิตติสุขชาติ พสุภา, 2564)

ในกระบวนการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง การเคลื่อนลงตามความชัน Gradient descent) จะถูกนำมาใช้ในการฝึกฝนแบบจำลอง โดยเป็นการหาค่าน้ำหนักที่เหมาะสมที่สุดที่ทำให้ค่าฟังก์ชันต้นทุนหรือค่าฟังก์ชันความสูญเสียของแบบจำลองมีค่าน้อยที่สุด

2.4.6.3 การเคลื่อนลงตามความชัน หรือการลดลงขั้นสุด เป็นอัลกอริทึมสำหรับการปรับค่าให้เหมาะสมที่ใช้ในการค้นหาค่าต่ำสุดของฟังก์ชันเป็นอัลกอริทึมสำหรับการหาค่าเหมาะสมที่สุดในเบื้องต้น ซึ่งหมายความว่าใช้หาค่าต่ำสุดของฟังก์ชันเพื่อปรับปรุงตัวแปรในทิศทางที่ลดค่าความชันของฟังก์ชัน การเคลื่อนลงตามความชันเป็นเวกเตอร์ของอนุพันธ์ย่อยของฟังก์ชันที่เกี่ยวข้องค่ารับเข้า แนวคิดเบื้องต้นของการเคลื่อนลงตามความชัน คือ การกำหนดค่าเริ่มต้นด้วยชุดพารามิเตอร์เริ่มต้น จากนั้นปรับปรุงพารามิเตอร์ซ้ำ ๆ ในทิศทางของการลดลงความชันเชิงลบจนกว่าจะพบค่าต่ำสุด สมการของการเคลื่อนลงตามความชันแสดงได้ดังสมการที่ 2.10

$$\theta = \theta - \alpha \nabla J(\theta) \quad (2.10)$$

โดยที่ θ	คือ	ชุดของพารามิเตอร์
α	คือ	อัตราการเรียนรู้
$\nabla J(\theta)$	คือ	เกรเดียนต์ของฟังก์ชันความสูญเสีย $J(\theta)$ ที่เกี่ยวกับพารามิเตอร์ θ

การเคลื่อนลงตามความชันใช้กันอย่างแพร่หลายในการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึกเพื่อฝึกฝนแบบจำลอง สามารถใช้เพื่อปรับพารามิเตอร์ของการถดถอยเชิงเส้น และโครงข่ายประสาทเทียมให้เหมาะสมที่สุดกับการเรียนรู้ เป็นอัลกอริทึมที่ใช้กันอย่างแพร่หลายและง่ายต่อการใช้งาน (กอบเกียรติ สระอุบล, 2565)


2.4.7 โครงข่ายประสาทเทียม และการเรียนรู้เชิงลึก

อวัยวะสำคัญในร่างกายที่ทำให้มนุษย์มีความคิด ฉลาดในการเรียนรู้ สื่อสาร วางแผน จัดจำ และควบคุมการทำงานของร่างกายได้นั้นคือสมองและระบบประสาท โดยหากต้องการที่จะทำให้คอมพิวเตอร์มีความสามารถในการเรียนรู้และตัดสินใจได้ไม่ต่างจากมนุษย์นั้น การเลียนแบบการทำงานของสมองมนุษย์จึงเป็นสิ่งที่ผู้นำมาพิจารณาในการสร้างอัลกอริทึมการเรียนรู้ของคอมพิวเตอร์

ในปี ค.ศ. 1940 (พ.ศ. 2483) วอร์เรน แมคคัลลอค (Warren McCulloch) และ วอเตอร์ พิตส์ (Walter Pitts) ได้พัฒนาทฤษฎีประสาทวิทยาขึ้นโดยกล่าวถึงการจำลองการทำงานของโครงข่ายประสาทชีวภาพ (Neural networks) ภายในสมองมนุษย์ด้วยการใช้ฮาร์ดแวร์และซอฟต์แวร์ เรียกว่า โครงข่ายประสาทเทียม (Artificial neural network) หรือ ANN (เจรอน, 2566)

โครงข่ายประสาทมีองค์ประกอบที่เรียกว่า นิวรอน (Neuron) หรือเซลล์ประสาท เป็นหน่วยประมวลผลจำนวนมหาศาล มีแกนประสาทนำออก (Axon) สำหรับทำหน้าที่ส่งสัญญาณไฟฟ้าจากนิวรอนไปยังจุดเชื่อมต่อกับนิวรอนอื่นหรือ ซินแนปส์ (Synapse terminal) สำหรับส่งสารสื่อประสาทไปยังใยประสาทนำเข้า (Dendrites) ของนิวรอนตัวถัดไป การทำงานของเซลล์ประสาทยังจะทำงานเป็นโครงข่ายที่โยงใยไปถึงเซลล์อื่นทั่วร่างกายนับพันล้านเซลล์เพื่อส่งคำสั่งในควบคุมการทำงานของร่างกาย

หากหน่วยย่อยของระบบประสาทและสมองของมนุษย์คือเซลล์ประสาท หน่วยย่อยของโครงข่ายประสาทเทียมคือ เพอร์เซ็ปตรอน (Perceptron) ถูกคิดค้นขึ้นโดยแฟรงก์ โรเซนแบลตต์ (Frank Rosenblatt) ในปี ค.ศ. 1957 (พ.ศ. 2490) โดยเป็นหน่วยย่อยที่สุดของโครงข่ายประสาทเทียมแสดงดังรูปที่ 2.33



รูปที่ 2.33 โครงสร้างของ Single layer perceptron

ในรูปที่ 2.33 ค่ารับเข้าที่เป็นตัวเลขจะถูกสุ่มค่าน้ำหนักก่อนที่จะป้อนค่านั้นเข้าไปเพื่อรวมผล (Sum) จากนั้นส่งต่อไปยังฟังก์ชันกระตุ้น (Activation function) เพื่อตัดสินใจหรือเลือกค่าในการส่งค่าส่งออกพร้อมกับค่าน้ำหนักไปยัง Perceptron ตัวถัดไปหน่วยประมวลผลสำคัญของ Perceptron เรียกว่า โหนด (Node) คือการรวมกันของการรวมผลและฟังก์ชันกระตุ้น (เพื่อหลีกเลี่ยงความสับสนกับโครงข่ายประสาทเทียมทางชีวภาพ) หากโครงสร้างของ Single layer Perceptron ที่มีอยู่เดิมได้มีการเพิ่มขึ้น (Layer) ของหน่วยประมวลผลเข้าไปอีกชั้นหนึ่งระหว่างค่ารับเข้ากับค่าส่งออกเรียกว่า ชั้นซ่อน และการที่มีการเพิ่มขึ้นซ่อนลงในโครงสร้างของหน่วยประมวลผลจะได้โครงสร้างใหม่ที่เรียกว่า Multilayer Perceptron (MLP) อันเป็นพื้นฐานที่สำคัญของการเรียนรู้เชิงลึกต่อไป

โครงข่ายประสาทเทียมแบบหลายชั้น หรือโครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network) หรือ DNN เป็นแบบจำลองการเรียนรู้เชิงลึกที่มีความสามารถในการทำนายและจำแนกโดยมีพื้นฐานมาจาก โครงสร้างของ Multilayer Perceptron หรือ MLP โดยส่วนประกอบที่สำคัญของ MLP คือ ชั้น (Layer) แบ่งออกเป็น 3 ชั้นดังนี้

1) ชั้นนำเข้า (Input layer) คือ ชั้นแรกของโครงข่าย โดยเป็นจุดเริ่มต้นของขั้นตอนการทำงานของโครงข่ายประสาทเทียม ทำหน้าที่ส่งข้อมูลไปยังแต่ละโหนดของชั้นต่อไป โดยจำนวนโหนดของ ชั้นรับเข้าขึ้นกับขนาดของข้อมูล

2) ชั้นซ่อน (Hidden layers) ชั้นเหล่านี้เป็นชั้นระหว่างชั้นรับเข้า และชั้นส่งออก โดยชั้นเหล่านี้ใช้เพื่อแยกคุณสมบัติเด่นจากข้อมูลรับเข้า และเป็นส่วนที่ทำหน้าที่ส่งต่อข้อมูลไปยังชั้นส่งออก โดยแต่ละครั้งที่มีการฝึกฝนข้อมูล (Training Data) ผ่านชั้นนี้ แต่ละโหนดจะปรับค่าน้ำหนัก (Weight) ให้เข้ากับข้อมูลมากขึ้น

3) ชั้นส่งออก (Output layer) คือ ชั้นสุดท้ายของโครงข่าย ทำหน้าที่ส่งออกข้อมูลส่งออกจากการคาดคะเนของโครงข่าย โดยจำนวนโหนดของชั้นนี้ขึ้นกับจำนวนชนิดข้อมูลที่ต้องการจำแนก (Classification Data หรือ Classes) ในชุดข้อมูล

2.4.7.1 โครงข่ายประสาทแบบป้อนข้อมูลไปข้างหน้า (Feedforward neural networks) หรือ FFNN ดังที่ได้กล่าวมาวิธีการเรียนรู้ของ MLP โดยทั่วไปจะด้วยโครงสร้าง 3 ชั้นคือ ชั้นนำเข้า ชั้นซ่อน และชั้นส่งออก โดยมีจำนวนอย่างละ 1 ชั้น ข้อมูลที่ถูกนำมาใช้ในการฝึกฝนจะถูกส่งต่อไปประมวลผลแบบไหลในทิศทางเดียว เรียกว่า โครงข่ายประสาทแบบป้อนข้อมูลไปข้างหน้า โดยโครงข่ายประสาทนี้จะเริ่มจากข้อมูลไหลเข้าสู่ชั้นนำเข้าตามจำนวนขนาดของกลุ่มข้อมูลที่แบ่งไว้ (Batch size) ขณะที่ทำการฝึกฝนแบบจำลองข้อมูลจากชั้นนำเข้าจะมีการป้อนข้อมูลไปยังชั้นของเซลล์ประสาทเทียมในชั้นซ่อนหรือโหนด และนำข้อมูลมาคูณกับค่าพหุนามค่าหนึ่ง เรียกว่า ค่าน้ำหนักที่เกิดจากการสุ่ม โดยก่อนที่จะส่งข้อมูลออกมาถึงชั้นส่งออก ผลรวมของการคูณของข้อมูลและค่าน้ำหนักบวกด้วยค่าพหุนามค่าหนึ่ง หรือ Bias ที่เกิดจากการสุ่มในตอนแรกเพื่อปรับแก้ความถูกต้องของผลลัพธ์ และค่าผลรวมจะถูกนำมาคำนวณด้วยฟังก์ชันกระตุ้นก่อนส่งค่าออกมาในชั้นส่งออก (ณัฐโชติ พรหมฤทธิ์ และสัจจาภรณ์ ไวจรรยา, 2564; ปริญญา สงวนสัตย์, 2562)

ฟังก์ชันกระตุ้น หรือ Transfer function เป็นหน่วยประมวลผลที่ต่อมาจากการรวมผล เพื่อตัดสินใจเลือกค่าข้อมูลส่งออก ฟังก์ชันกระตุ้นที่ใช้สำหรับการเรียนรู้ของ MLP ได้แก่

1. Linear function มีลักษณะการทำงานเป็นแบบเชิงเส้นตามสมการเส้นตรง โดยค่าส่งออก (y) จะมีค่าเท่ากับค่าความชัน (m) คูณด้วยค่ารับเข้า (x)

$$y = mx \quad (2.11)$$

2. Rectified Linear Unit หรือ ReLU เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ของข้อมูลส่งออก $f(x)$ เท่ากับค่าข้อมูลนำเข้าเมื่อมีค่ามากกว่า 0 และมีค่าผลลัพธ์เป็น 0 เมื่อข้อมูลนำเข้าติดลบ

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2.12)$$

3. Sigmoid function หรือ Logistic function เป็นฟังก์ชันกระตุ้นที่ใช้ในการแปลงค่าข้อมูลรับเข้าให้ได้ค่าข้อมูลส่งออกอยู่ระหว่าง 0 ถึง 1 นิยมใช้ในการจำแนกข้อมูลออกเป็น 2 ประเภท

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.13)$$

4. Hyperbolic tangent activation function หรือTanh มีค่าส่งออกอยู่ระหว่าง -1 ถึง 1 โดยช่วงที่กว้างกว่า Sigmoid function

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.14)$$


3. SoftMax function เป็นฟังก์ชันสัดส่วนความน่าจะเป็น มักใช้กับชั้นส่งออกของโครงข่ายประสาทเทียมที่ต้องการทำนายผลมากกว่า 2 ชนิด โดยพิจารณาค่าส่งออกจากความน่าจะเป็นสูงสุด

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2.14)$$

โดยที่	σ	คือ SoftMax function
	$\vec{z}_i$	คือ ค่าเวกเตอร์รับเข้า (Vector input)
	e^{z_i}	คือ ค่า Standard exponential ค่าเวกเตอร์รับเข้า
	e^{z_j}	คือ ค่า Standard exponential ค่าเวกเตอร์ส่งออก
	K	คือ จำนวนประเภทที่ต้องการจำแนก

นอกจากนี้ยังมีฟังก์ชันกระตุ้นอื่นอีก เช่น Binary step และ Leaky ReLU เป็นต้น (กอบเกียรติ สระอุบล, 2565) หลังจากที่โครงข่ายประสาทเทียมส่งค่าส่งออกออกมาจะมีบางค่าที่ผิดจากคำตอบจะมีการใช้ฟังก์ชันต้นทุน หรือฟังก์ชันความสูญเสีย ในการหาค่าความสูญเสีย (Loss) หรือต้นทุน (Cost) หากค่าส่งออกที่ส่งออกมาามีค่าที่ผิดมากค่าการสูญเสียก็จะมากขึ้น

การลู่ค่าน้ำหนักในการประมวลผลครั้งแรกค่าจากโหนดในชั้นส่งออกจะยังไม่สามารถแก้ปัญหาได้อย่างถูกต้อง จึงต้องมีการปรับค่าน้ำหนักที่นำมาคูณกับข้อมูลในชั้นนำเข้า เพื่อให้ได้ผลลัพธ์ใกล้เคียงกับผลลัพธ์ที่ต้องการซึ่งถูกเตรียมไว้ก่อนหน้าโดยการติดป้ายกำกับ การที่แบบจำลองจะปรับค่าน้ำหนักให้ได้ผลลัพธ์ที่ต้องการจะต้องมีการประเมินจากค่าฟังก์ชันการสูญเสีย และเพื่อให้ได้รับผลลัพธ์ที่ต้องการจะต้องมีการปรับค่าน้ำหนักหลายครั้งหรือมีรอบการประมวลผล (Epoch) หลายรอบ โดยมีการกำหนดค่าอัตราการเรียนรู้ เพื่อควบคุมการปรับปรุงค่าน้ำหนักและ Bias ของแบบจำลอง กระบวนการนี้เรียกว่า การแพร่ย้อนกลับ (Backpropagation) นอกจากนี้ยังต้องมีวิธีการปรับค่าน้ำหนักโดยการกำหนดวิธีการปรับค่าด้วย Optimizer




รูปที่ 2.34 FFNN ที่มีชั้นซ่อน 3 ชั้น

Optimizer คือ อัลกอริทึมสำหรับการปรับเปลี่ยนค่าตัวทำนาย หรือแอตทริบิวต์ของแบบจำลอง ได้แก่ อัตราการเรียนรู้ และค่าน้ำหนัก โดยการปรับค่านี้อาจส่งผลต่อความแม่นยำและความสูญเสียของแบบจำลอง Optimizer ที่เป็นที่นิยมในการใช้งาน เช่น Momentum, SGD, RMSProp และ Adam เป็นต้น

อัตราการเรียนรู้ (Learning rate) เป็นตัวแปรเกินที่เกี่ยวข้องกับการปรับค่าความผิดพลาด ที่เกิดจากการปรับปรุงค่าน้ำหนัก และ bias ด้วยวิธีการเรียนรู้แบบการแพร่ย้อนกลับ ในกรณีที่มีการใช้ Optimizer พื้นฐาน เช่น SGD การปรับค่าอัตราการเรียนรู้มีผลอย่างมากต่อความแม่นยำและความผิดพลาดของแบบจำลอง

Adam (Adaptive moment estimation) เป็น Optimizer ที่รวบรวมความสามารถของ Optimizer ตัวอื่นเข้าไว้ด้วยกัน จึงทำให้ไม่จำเป็นต้องมีการปรับค่าอัตราการเรียนรู้ของแบบจำลอง โดยกำหนดค่าอัตราการเรียนรู้ไว้ที่ 0.001 (เจรอน, 2566)

2.4.7.2 โครงข่ายประสาทแบบวนกลับ (Recurrent neural networks) หรือ RNN เป็นโครงข่ายประสาทเทียมประเภทหนึ่งที่ได้รับการออกแบบมาเป็นพิเศษเพื่อประมวลผลข้อมูลตามลำดับ เช่น อนุกรมเวลา ภาษาธรรมชาติ และเสียงพูด ซึ่งแตกต่างจากโครงข่ายประสาทแบบป้อนข้อมูลไปข้างหน้าซึ่งออกแบบมาเพื่อประมวลผลข้อมูลที่ไม่ขึ้นกับเวลา โครงข่ายประสาทแบบวนกลับมีการเชื่อมต่อที่ช่วยให้ข้อมูลไหลเวียนในลักษณะเป็นวงจร โครงสร้างของโครงข่ายประสาทแบบวนกลับแสดงดังรูปที่ 2.34



รูปที่ 2.34 แผนภาพอัลกอริทึมของโครงข่ายประสาทเทียมแบบวนกลับ

โดย h_t คือ ชั้นซ่อน (Hidden Layer), y_t คือ ข้อมูลส่งออก (Output data) ณ เวลา t , x_t คือ ข้อมูลนำเข้า (Input data) ณ เวลา t และ h_t คือ สถานะซ่อน (Hidden state) ณ เวลา t จากรูปที่ 2.34 แสดงให้เห็นว่าจะมีการเข้าสู่วน (Loop) กลับมาที่ชั้นซ่อนซึ่งมีประโยชน์ในการนำสถานะซ่อนก่อนหน้ากลับมาใช้งาน

2.4.8 การประเมินประสิทธิภาพของแบบจำลอง

การประเมินประสิทธิภาพของแบบจำลอง (Evaluation model performance) เป็นเครื่องมือที่มีความสำคัญอย่างมาก ทำให้ทราบถึงประสิทธิภาพของแบบจำลองที่ใช้ในการพิจารณาปัญหาที่สนใจ ซึ่งช่วยในการตัดสินใจในการนำแบบจำลองมาใช้งาน การประเมินประสิทธิภาพของแบบจำลองจะวัดจากค่าฟังก์ชันต้นทุน (Cost function) หรือฟังก์ชันความสูญเสีย (Loss function) และความแม่นยำ (Accuracy) โดยแบบจำลองที่มีการเรียนรู้ที่ดีมีประสิทธิภาพจะมีค่าฟังก์ชันความสูญเสียต่ำ และมีค่าความแม่นยำสูง (ณัฐโชติ พรหมฤทธิ์ และสัจจาภรณ์ ไวจรรยา, 2564)

การประเมินประสิทธิภาพแบบจำลองมีความจำเป็นอย่างยิ่งในขั้นตอนการสร้างแบบจำลอง เนื่องจากในขั้นตอนการสร้างแบบจำลองต้องมีการเลือกใช้ตัวแปรเกินหรือตัวแปรแทรกซ้อน ที่ใช้ในการควบคุมการเรียนรู้ของอัลกอริทึมต่าง ๆ อาทิ การถดถอยเชิงเส้นต้องมีการปรับค่าอัตราการเรียนรู้ การเลือกค่าตัวแปรเกินที่เหมาะสมจึงมีผลอย่างมากต่อประสิทธิภาพของแบบจำลอง


เป้าหมายของการสร้างแบบจำลองคือการทำให้ฟังก์ชันที่พิจารณามีค่าเหมาะสมที่สุดอย่างไรก็ตามการพิจารณาเพียงแค่ฟังก์ชันความสูญเสีย ของแต่ละอัลกอริทึมอาจจะไม่ได้ทำให้ได้แบบจำลองที่เหมาะสมที่สุด และหากแบบจำลองได้รับข้อมูลทดสอบที่ไม่เคยได้รับการฝึกฝนมาก่อน อาจทำให้ผลลัพธ์ที่ได้อาจไม่มีประสิทธิภาพ เนื่องจาก 2 เหตุปัจจัย คือ

1) แบบจำลองที่พิจารณาเรียนรู้มาจากข้อมูลที่มีสัญญาณรบกวนเป็นองค์ประกอบด้วย

2) ในกรณีข้อมูลที่ไม่มีสัญญาณรบกวนเป็นองค์ประกอบ ก็ยังไม่สามารถมั่นใจได้ว่าฟังก์ชันที่ใช้ในแบบจำลองนั้นถูกต้องหรือไม่ เพราะหาไม่ทราบว่าฟังก์ชันที่แท้จริงของปัญหาคือฟังก์ชันใด อีกทั้งการสร้างแบบจำลองที่ดีไม่ควรมีความยืดหยุ่นมากเกินไป เพราะจะส่งผลให้มีแนวโน้มเข้าใกล้กับข้อมูลในทุกจุด และผันผวนมากเกินไป ทำให้การทำนายกับข้อมูลที่ไม่เคยเห็น (Unseen data) มีความผิดพลาดสูง นอกจากนี้การสร้างแบบจำลองที่ดีไม่ควรมีความกระด้างมากเกินไป เนื่องจากจะทำให้แบบจำลองไม่สามารถทำนายได้อย่างมีประสิทธิภาพเช่นกัน (กิตติสุชาติ พสุภา, 2564)


การประเมินประสิทธิภาพของแบบจำลองจะต้องทดสอบจากข้อมูลที่ไม่เคยนำไปใช้ในการฝึกฝน และสามารถทำได้โดยการวัดความผิดพลาดสองชนิด ได้แก่ ความผิดพลาดเชิงประจักษ์ (Empirical Error) คือการวัดความผิดพลาดของแบบจำลอง จากการนำเข้าข้อมูลฝึกฝน โดยวัดค่าเฉลี่ยความผิดพลาดกำลังสองในปัญหาการถดถอย และอัตราการจำแนกประเภทผิด (Misclassification Rate) ในปัญหาการจำแนก และความผิดพลาดจริง (True Error) คือการวัดความผิดพลาดของแบบจำลองจากการนำเข้าข้อมูลทดสอบ โดยวัดค่าเฉลี่ยความผิดพลาดกำลังสอง หรือความน่าจะเป็นของการจับกลุ่มผิด เป็นต้น สำหรับประสิทธิภาพของแบบจำลองสามารถประเมินได้จากลักษณะของแบบจำลองที่ถูกฝึกฝนมาแบ่งออกได้ 3 ลักษณะ ดังนี้

1) ความเหมาะสมกับข้อมูลมากเกินไป (Over-fitting) เป็นปัญหาที่เกิดขึ้นจากการฝึกฝนแบบจำลองเป็นลักษณะของแบบจำลองที่ไม่ดี เนื่องจากแบบจำลองนั้นถูกฝึกฝนจนเข้ากับข้อมูลมากเกินไป โดยเป็นผลจากการที่พยายามฝึกฝนแบบจำลองจนกระทั่งฟังก์ชันต้นทุนค่าความผิดพลาดกำลังสองเข้าใกล้ศูนย์ ทำให้ความผิดพลาดเชิงประจักษ์มีค่าน้อยมาก จึงส่งผลให้ประสิทธิภาพในการทำนายโดยใช้ข้อมูลทดสอบมีความผิดพลาดต่ำมาก แบบจำลองนี้จะเกิดความผันผวน และเปลี่ยนแปลงได้ง่ายเมื่อมีการเปลี่ยนแปลงตัวอย่างในการฝึกฝน เนื่องจากแบบจำลองจะพยายามฝึกฝนข้อมูลที่มีสัญญาณรบกวนเข้าไปด้วย (กิตติสุชาติ พสุภา, 2564; ณัฐโชติ พรหมฤทธิ์ และ สัจจาภรณ์ ไวจรรยา, 2564) พิจารณาความเหมาะสมกับข้อมูลมากเกินไปได้จาก Loss curve ดังรูปที่ 2.35




รูปที่ 2.35 Loss curve ของแบบจำลองที่มีความเหมาะสมกับข้อมูลมากเกินไป

2) ความเหมาะสมกับข้อมูลต่ำเกินไป (Under-fitting) เป็นปัญหาที่เกิดขึ้นจากการฝึกฝนแบบจำลองเป็นลักษณะของแบบจำลองที่ไม่ดี เนื่องจากแบบจำลองนั้นถูกฝึกฝนจากข้อมูลที่ไม่เพียงพอ ทำให้แบบจำลองไม่มีความซับซ้อน และความผิดพลาดเชิงประจักษ์มีค่าสูง ส่งผลให้ความผิดพลาดจริงมีค่าสูง พิจารณาความเหมาะสมกับข้อมูลต่ำเกินไปได้จาก Loss curve ดังรูปที่ 2.35



รูปที่ 2.36 Loss curve ของแบบจำลองที่มีความเหมาะสมกับข้อมูลต่ำเกินไป

3) ความเหมาะสมกับข้อมูลพอดี (Good-fitting) เป็นลักษณะของแบบจำลองที่ดี (Good model) โดยมีความผิดพลาดในเชิงประจักษ์อยู่ในระดับที่ยอมรับได้ และเมื่อนำไปทดสอบด้วยข้อมูลทดสอบ แบบจำลองยังคงมีความผิดพลาดจริงอยู่ในระดับเดียวกับความผิดพลาดเชิงประจักษ์ แบบจำลองลักษณะนี้มีความซับซ้อนที่พอเหมาะสามารถใช้ในการปัญหาการถดถอย และการจำแนกประเภทได้ดี พิจารณาความเหมาะสมกับข้อมูลพอดีได้จาก Loss curve ดังรูปที่ 2.37



รูปที่ 2.37 Loss curve ของแบบจำลองที่มีความเหมาะสมกับข้อมูลพอดี

กล่าวได้ว่า การประเมินประสิทธิภาพของแบบจำลองใช้ในการเปรียบเทียบประสิทธิภาพของแบบจำลองที่สร้างจากอัลกอริทึมต่างชนิดกันที่พัฒนาจากชุดข้อมูลเดียวกัน เพื่อที่จะได้เลือกใช้อัลกอริทึมที่เหมาะสมที่สุดกับข้อมูล สำหรับปัญหาการถดถอยจะนิยมพิจารณาประสิทธิภาพของแบบจำลองด้วยค่าสัมประสิทธิ์แสดงการตัดสินใจ, ค่าความผิดพลาดสัมบูรณ์เฉลี่ย และความผิดพลาดกำลังสองเฉลี่ย

2.4.8.1 ค่าสัมประสิทธิ์แสดงการตัดสินใจ (Coefficient of Determination) หรือ R^2 เป็นการศึกษาความสัมพันธ์ระหว่างตัวแปรตามหรือข้อมูลเป้าหมาย กับตัวแปรตามจากการทำนาย โดยมีค่าระหว่าง 0 ถึง 1 หาก R^2 มีค่าเท่ากับ 1 หมายถึงแบบจำลองทำนายได้ตรงตามเป้าหมายทั้งหมด หากมีค่าเท่ากับ 0 หมายถึงแบบจำลองมีประสิทธิภาพเท่ากับการทำนายโดยใช้ค่าเฉลี่ยของข้อมูลทั้งหมด และหากมีค่าน้อยกว่า 0 หมายความว่าแบบจำลองทำนายผลได้แย่กว่าการใช้ค่าเฉลี่ยเป็นคำตอบ (กิตติสุชาติ พสุภา, 2564) โดยค่า R^2 สามารถคำนวณได้จากสมการที่ 2.15

$$R^2 = 1 - \frac{\sum (y_i - y_j)^2}{\sum (y_i - \bar{y}_j)^2} \quad (2.15)$$

โดยที่	y_i	คือ	ค่าตัวแปรตาม
	y_j	คือ	ค่าตัวแปรตามจากการทำนาย
	$\bar{y}_j$	คือ	ค่าเฉลี่ยจากค่าตัวแปรตามทั้งหมด

อย่างไรก็ตามค่า R^2 ที่มากไม่ได้หมายความว่าแบบจำลองจะมีประสิทธิภาพที่ดีเสมอไป โดยหากพิจารณาจากความซับซ้อน แบบจำลองที่มีความซับซ้อนต่ำหากมีจำนวนข้อมูลที่มากพอค่าความผิดพลาดของแบบจำลองที่ประเมินจากชุดทดสอบจะมีแนวโน้มลดลงได้ง่ายกว่า

แบบจำลองที่มีความซับซ้อนสูงแม้ว่าจะมีค่า R^2 ที่ใกล้เคียงกัน (Abu-Mostafa, 2012) การพิจารณา ค่าฟังก์ชันความสูญเสียจึงถูกนำมาใช้พิจารณาร่วมด้วย

2.4.8.2 ค่าความผิดพลาดกำลังสองเฉลี่ย (Mean Square Error) หรือ MSE เป็น ฟังก์ชันวัดความผิดพลาดที่นิยมมากที่สุด (กิตติสุชาติ พสุภา, 2564) โดยคำนวณจากค่าเฉลี่ยของผลรวม ของผลต่างระหว่างค่าเป้าหมายกับค่าทำนายกำลังสอง โดยคำนวณได้จากสมการที่ 2.16 ค่าของ ฟังก์ชันนี้จะอยู่ในช่วง $[0, \infty)$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2 \quad (2.16)$$

โดยที่	y_i	คือ	ค่าข้อมูลเป้าหมายตัวที่ i ,
	$\hat{y}$	คือ	ค่าเฉลี่ยของ y_i และ
	N	คือ	จำนวนข้อมูลทั้งหมด

นอกจากนี้ สามารถปรับค่าความผิดพลาดกำลังสองเฉลี่ยให้อยู่ในมาตราส่วน เดียวกันโดยการใส่รากที่สองให้กับค่าความผิดพลาดกำลังสองเฉลี่ย เรียกว่า ค่ารากที่สองของความ ผิดพลาดกำลังสองเฉลี่ย (Root Mean Square Error) หรือ RMSE ดังสมการที่ 2.17

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (2.17)$$

2.4.8.3 ค่าความผิดพลาดสัมบูรณ์เฉลี่ย (Mean Absolute Error) หรือ MAE เป็น ฟังก์ชันความสูญเสียที่ถูกใช้เพื่อลดข้อผิดพลาดซึ่งเป็นผลรวมของความแตกต่างทั้งหมดระหว่างค่าจริง และค่าทำนาย การสูญเสีย L1 เรียกอีกอย่างว่า ความผิดพลาดสัมบูรณ์ (Absolute error) ดังนั้นค่า ความข้อผิดพลาดสัมบูรณ์เฉลี่ย (MAE) จึงเป็นการวัดความผิดพลาดโดยคำนวณจากค่าเฉลี่ยของ ผลรวมของค่าสัมบูรณ์ของผลต่างระหว่างค่าเป้าหมายกับค่าทำนาย โดยที่ไม่พิจารณาทิศทางของ ความผิดพลาด คำนวณได้ดังสมการที่ 2.18 ค่าของฟังก์ชันนี้จะอยู่ในช่วง $[0, \infty)$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}| \quad (2.18)$$

พบว่า ค่าความผิดพลาดกำลังสองเฉลี่ยเป็นการวัดความผิดพลาดที่นิยมมากที่สุด เนื่องจากการใช้ฟังก์ชันความผิดพลาดกำลังสองเฉลี่ยเป็นฟังก์ชันความสูญเสียง่ายกว่าการใช้ความ ผิดพลาดสัมบูรณ์เฉลี่ย โดยที่เมื่อค่าตอบของฟังก์ชันเข้าใกล้จุดต่ำสุด ค่าเกรเดียนต์จะมีความมากเกินไป

ในกรณีที่อัตราการเรียนรู้คงที่ ทำให้ไม่สามารถถึงจุดต่ำสุดได้ในขณะที่ความผิดพลาดกำลังสองเฉลี่ยจะไม่พบปัญหา เนื่องจากฟังก์ชันมีความเหมาะสมในการหาค่าจุดต่ำสุดโดยในแต่ละรอบการฝึกค่าเกรเดียนต์จะมีค่าลดลงในแต่ละรอบ

ค่าความผิดพลาดกำลังสองเฉลี่ยจะเป็นที่นิยมมากกว่าความผิดพลาดสัมบูรณ์เฉลี่ย นอกจากนี้รากที่สองของค่าความผิดพลาดกำลังสองเฉลี่ยนั้นได้เปรียบต่อการหาค่าเฉลี่ยของข้อมูลเนื่องจากผลต่างของข้อมูลถูกยกกำลังสองทำให้ข้อมูลทิศทางนั้นหายไป จากนั้น นำมาหาค่าเฉลี่ยและถอดรากที่สอง ซึ่งเป็นการหาค่าเฉลี่ยของผลต่างกำลังสองและถอดราก ในขณะที่การหาความผิดพลาดสัมบูรณ์เฉลี่ยเป็นการหาค่ามัธยฐาน โดยไม่ขึ้นกับข้อมูลทิศทางผลต่างเช่นเดียวกันแต่ใช้ค่าสัมบูรณ์ โดยมีข้อได้เปรียบประการหนึ่งคือมีความคงทนต่อข้อมูลที่มีค่าผิดปกติมากกว่า เนื่องจากค่าผลต่างไม่ได้ถูกยกกำลังสองเหมือนกับการหารากที่สองของความผิดพลาดกำลังสองเฉลี่ย ทำให้ค่าไม่เปลี่ยนแปลงเท่ากับการยกกำลังสอง เนื่องจากการหาค่ามัธยฐานมีความคงทนต่อค่าผิดปกติมากกว่าค่าเฉลี่ย (กิติ์สุชาติ พสุภา, 2564)

2.4.9 การปรับปรุงประสิทธิภาพของแบบจำลอง

ภายหลังจากการประเมินประสิทธิภาพของแบบจำลองจะได้ค่าความแม่นยำ และความผิดพลาดที่เกิดขึ้นจากการเรียนรู้ของแบบจำลอง หากแบบจำลองนั้นยังไม่มีประสิทธิภาพกับการนำไปใช้งานเพื่อปรับปรุงประสิทธิภาพของแบบจำลองให้ดียิ่งขึ้น โครงข่ายประสาทเทียมเป็นแบบจำลองหนึ่งที่มีความยืดหยุ่นอย่างมากในการปรับปรุงโครงสร้างโดยนอกเหนือจากชุดข้อมูลที่ป้อนให้กับแบบจำลองเป็นตัวแปรในการเรียนรู้แล้ว ยังมีตัวแปรอื่นที่สามารถปรับแต่งได้และมีผลต่อการเรียนรู้ของแบบจำลอง เรียกว่า ตัวแปรเกิน (Hyperparameter) ได้แก่ จำนวนชั้น, จำนวนโหนด, ฟังก์ชันกระตุ้น, Optimizer และ Batch size เป็นต้น การปรับปรุงตัวแปรเกินเหล่านี้เป็นส่วนหนึ่งในกระบวนการพัฒนาแบบจำลองการเรียนรู้เชิงลึก


2.4.9.1 การเลือกตัวแปรเกิน อาจเริ่มจากการปรับจำนวน Epoch โดยเป็นค่าที่กำหนดความซับซ้อนของแบบจำลองเป็นจำนวนรอบของการปรับค่าน้ำหนักด้วยวิธีการแพร่ย้อนกลับ โดยจะพิจารณาใช้เมื่อแบบจำลองนั้นมีความเหมาะสมกับข้อมูลต่ำเกินไป

หากการเพิ่มจำนวน Epoch นั้นไม่ได้ส่งผลต่อประสิทธิภาพของแบบจำลอง มากนั้นการปรับจำนวนชั้นของแบบจำลอง การเพิ่มจำนวนชั้นซ้อนอาจพิจารณาเลือกใช้จากลักษณะของชุดข้อมูล ชั้นซ้อนที่มากจะยิ่งเพิ่มประสิทธิภาพของแบบจำลองที่ข้อมูลที่มีความซับซ้อนมาก การพิจารณาการเพิ่มจำนวนชั้นซ้อนอาจพิจารณาอย่างไรก็ตามหากจำนวนชั้นซ้อนมีมากเกินไป อาจทำให้เกิดการเรียนรู้เกิดความเหมาะสมกับข้อมูลมากเกินไปเช่นกัน (ณัฐโชติ พรหมฤทธิ์ และ สัจจาภรณ์ ไวจรรยา, 2564)

จำนวนโหนดในชั้นนำเข้าและชั้นส่งออกกำหนดจากจำนวนตัวแปรของชุดข้อมูล แต่จำนวนโหนดในชั้นซ่อนนั้นสามารถกำหนดได้อย่างอิสระโดยทั่วไปอาจกำหนดให้มีจำนวนโหนดลดลงในแต่ละชั้นซ่อน เช่น 64-32-16-8 เป็นต้น เพื่อให้คุณลักษณะที่ไม่สำคัญของข้อมูลถูกตัดทอนลงไป อย่างไรก็ตามวิธีที่มีประสิทธิภาพดีกว่าคือการกำหนดจำนวนโหนดให้เท่ากันในแต่ละชั้นซ่อน เพื่อให้มีตัวแปรเกินเพียงตัวแปรเดียวในการปรับแต่ง (เจรอน, 2566) สำหรับการปรับแต่งจำนวนโหนดมีหลักการเดียวกับจำนวน Epoch และจำนวนชั้นซ่อน คือต้องพิจารณาจากความเหมาะสมกับข้อมูลมากเกินไปและต่ำเกินไป

สำหรับฟังก์ชันกระตุ้น, อัตราการเรียนรู้ และ Optimizer นั้นโดยทั่วไปจะเริ่มพิจารณาจากการเลือกค่าฟังก์ชันกระตุ้น และค่า Optimizer เพื่อเลือกค่าอัตราการเรียนรู้ที่เหมาะสมกับค่านั้น ๆ สำหรับ Batch size หรือจำนวนข้อมูลที่ถูกแบ่งนำไปใช้ในแต่ละรอบการประมวลผล (Epoch) โดยหาก Batch size มีขนาดใหญ่จะทำให้ประมวลผลได้รวดเร็วขึ้นหรือมีจำนวนรอบการวนซ้ำ (Iteration) ที่น้อย แต่ใช้ทรัพยากรในการประมวลผลที่สูง และหาก Batch size มีขนาดเล็กจะทำให้จำนวนรอบการประมวลผลช้าลงและใช้ทรัพยากรในการประมวลผลน้อยลงด้วย (เจรอน, 2566) อย่างไรก็ตามเพื่อหลีกเลี่ยงการเกิดความเหมาะสมกับข้อมูลมากเกินไปการเรียกใช้วิธีเช่นจึงถูกนำมาใช้ในการฝึกฝนแบบจำลองที่มีความซับซ้อนสูง

2.4.9.2 การเรียกใช้วิธีเช่น (Regularization) หรือการทำให้เป็นระเบียบ เป็นเทคนิคในการปรับปรุงแบบจำลองให้มีความราบเรียบมากที่สุด กล่าวคือทำให้แบบจำลองนั้นมีการแปรผันที่น้อยตามข้อมูลที่ใช้ในการฝึกฝน เพื่อให้เกิดประสิทธิภาพในการทำนายที่ดี คือมีความผิดพลาดจริงน้อยลง ซึ่งช่วยแก้ปัญหาการเกิดความเหมาะสมกับข้อมูลมากเกินไป การวิเคราะห์สัญญาณตกหาย (Dropout) เป็นหนึ่งในเทคนิคการทำเรียกใช้วิธีเช่นที่เรียบง่าย โดยเป็นการสุ่มเพื่อปิดการทำงานชั่วคราวของโหนด ภายในแต่ละชั้นตามอัตราร้อยละที่กำหนดขณะที่ทำการฝึกฝนแบบจำลองแต่ละรอบ การใช้เทคนิคนี้จะทำให้ไม่มีการปรับปรุงค่าน้ำหนักใหม่ในโหนดที่ถูกปิด อัตราการกำหนดร้อยละของการวิเคราะห์สัญญาณตกหายอยู่ระหว่างร้อยละ 20 ถึง 50 (ณัฐโชติ พรหมฤทธิ์ และสังจรรย์ ไวจรรยา, 2564) โดยปกติการวิเคราะห์สัญญาณตกหายจะกำหนดที่ชั้นซ่อนก่อนหน้าชั้นส่งออกโดยกำหนดจำนวนชั้นสูงสุดสำหรับการใช้งานถอยกลับมาจากชั้นส่งออกได้ไม่เกิน 3 ชั้นซ่อน (เจรอน, 2566)



รูปที่ 2.38 การวิเคราะห์สัญญาณตกหาย

นอกจากการปรับปรุงประสิทธิภาพของแบบจำลองโดยใช้การปรับค่าตัวแปรเกินแล้ว ได้มีผู้คิดค้นอัลกอริทึมที่ช่วยในการฝึกฝนแบบจำลองให้มีประสิทธิภาพสูงขึ้น โดยใช้การคำนวณทางคณิตศาสตร์และสถิติ โดยจะยกตัวอย่างอัลกอริทึมที่ถูกใช้งานบน Neural Network Toolbox บนซอฟต์แวร์ MATLAB ดังนี้

1) Scaled conjugate gradient algorithm (SCG) อัลกอริทึม SCG นั้นเป็นอัลกอริทึมที่ใช้ในการทำการแพร่ย้อนกลับของแบบจำลองโครงข่ายประสาทเทียมแบบ FFNN โดยใช้ในซอฟต์แวร์ MATLAB โดยใช้เทคนิคการทำ Conjugate gradient โดยเป็นเทคนิคการหาค่าเหมาะสมที่สุดที่มีการกำหนดทิศทาง และขนาดการปรับค่าน้ำหนักอย่างชัดเจนในการฝึกฝนแบบจำลอง (Moller, 1993)

2) Levenberg-Marquardt algorithm (LM) อัลกอริทึม LM เป็นอัลกอริทึมสำหรับการแพร่ย้อนกลับของแบบจำลอง เช่นเดียวกับ SCG โดยใช้ในการแก้ปัญหาที่ไม่เป็นเชิงเส้น เป็นอัลกอริทึมที่จะเป็นการผสมการใช้การประมาณค่าแบบ Gauss-Newton และการลดลงขั้นสุด (Binu and Rajakumar, 2021)

3) Bayesian regularization (BR) อัลกอริทึม BR เป็นแบบจำลองที่ถูกพัฒนาขึ้นให้มีประสิทธิภาพดีกว่าแบบจำลองโครงข่ายประสาทเทียมที่ใช้วิธีการแพร่ย้อนกลับแบบปกติ โดยใช้กระบวนการทางคณิตศาสตร์เพื่อใช้ในการแก้ปัญหาคงการถดถอยแบบไม่เป็นเชิงเส้น เพื่อลดความผิดพลาดในการปรับค่าน้ำหนักจากการใช้อัลกอริทึม Levenberg-Marquardt (Foresee and Hagan, 1997; Mackay, 1992)

2.5 งานวิจัยที่เกี่ยวข้อง

ปัจจุบันการทำเกษตรกรรมมีการอาศัยเทคโนโลยีในหลากหลายศาสตร์มาประยุกต์ใช้ร่วมกัน เพื่อแก้ไขปัญหา ลดต้นทุนในการผลิต และเพิ่มขีดความสามารถในการผลิตเรียกว่า การทำเกษตรแบบแม่นยำ (Precision Agriculture) จากการศึกษาของ Gyarmati and Mizik (2020) ได้กล่าวว่าในปี 2016 อุปกรณ์ในการทำเกษตรแบบดั้งเดิมถูกแทนที่ด้วยระบบอัตโนมัติ ระบบนำทาง (Equipment guidance) การระบุตำแหน่งบนพื้นโลก และระบบควบคุมด้วยคอมพิวเตอร์ เพื่อวัตถุประสงค์ที่แตกต่างกัน อาทิ การวางแผน การใส่ปุ๋ย การชลประทาน และการฉีดพ่นสาร นอกจากนี้ การทำเกษตรแบบแม่นยำยังอยู่บนพื้นฐานของข้อมูล โดยจำนวนข้อมูลที่นำมาใช้งานอาจมีการเก็บรวบรวมไว้ในหลากหลายปีเป็นจำนวนมาก อาจกล่าวได้ว่าพัฒนาการของการทำเกษตรแบบแม่นยำขึ้นอยู่กับระบบของข้อมูลมหัต (Bigdata) โดยความท้าทายสำคัญของการทำเกษตรแบบแม่นยำคือ การเก็บ รวบรวม และใช้ข้อมูลด้วยอุปกรณ์ต่าง ๆ

อากาศยานไร้คนขับเป็นหนึ่งในเครื่องมือสำคัญของการสำรวจระยะไกลในปัจจุบัน โดยใช้ในการเก็บรวบรวมข้อมูลด้วยอุปกรณ์ตรวจวัดจากทางอากาศ อากาศไร้คนขับสามารถทำงานโดยวิธีการควบคุมด้วยมือของนักบินภาคพื้น หรือใช้ระบบอัตโนมัติในการบินตามแผนการบินที่ได้วางแผนไว้ล่วงหน้า นอกจากนี้อากาศยานไร้คนขับยังสามารถบรรทุกน้ำหนักบรรทุก (Payload) เพื่อใช้ในวัตถุประสงค์ต่าง ๆ เช่น การขนส่งสิ่งของ การบรรทุกสารฉีดพ่น ด้วยเหตุนี้อากาศยานไร้คนขับจึงเป็นเครื่องมือหนึ่งที่กำลังเข้ามามีบทบาทอย่างมากต่อการทำเกษตรแบบแม่นยำในปัจจุบัน Austin (2010) กล่าวว่าอากาศยานไร้คนขับมักจะถูกติดตั้งด้วยกล้องบันทึกภาพที่มีคุณภาพสูง เพื่อใช้ในการถ่ายภาพจำนวนมากระหว่างทำการบิน ภาพถ่ายดังกล่าวถูกนำมาใช้ในการสร้างแบบจำลองพื้นผิวภูมิประเทศเชิงเลข และแผนที่ภาพถ่ายความละเอียดสูงด้วยเทคโนโลยีโฟโตแกรมเมตรี ผลผลิตดังกล่าวให้ข้อมูลทางกายภาพของวัตถุ และข้อมูลในเชิงพื้นที่ โดย Matese et al. (2015) กล่าวว่าอากาศยานไร้คนขับให้ข้อมูลภาพที่มีความละเอียดสูงกว่าภาพถ่ายจากดาวเทียม และเครื่องบิน นอกจากนี้ยังมีต้นทุนที่ต่ำกว่าอย่างมีนัยสำคัญเมื่อเทียบกับอากาศยานทั่วไป เช่น เครื่องบิน เฮลิคอปเตอร์ หรือ เครื่องร่อน อีกทั้งอากาศยานไร้คนขับยังสามารถทำการบินด้วยระบบอัตโนมัติได้จึงเป็นข้อดีอีกอย่างหนึ่งในการเลือกใช้งาน สำหรับข้อเสียของอากาศยานไร้คนขับคือ มีช่วงเวลาและระยะทางในการบินที่จำกัดโดยขึ้นกับแหล่งพลังงานที่อากาศยานได้รับ เช่น แบตเตอรี่ หรือเชื้อเพลิง Sylvester (2018) กล่าวถึงข้อได้เปรียบของอากาศยานไร้คนขับในด้านการทำเกษตรแบบแม่นยำในเรื่องใช้เวลาในการวางแผนและดำเนินการที่สั้นในแต่ละภารกิจการบิน ทำให้เกษตรกรสามารถรวบรวมข้อมูลได้อย่างทันท่วงทีในเวลาอันสั้น เพื่อให้สามารถประมาณการณ์ในการตัดสินใจ และแก้ไขปัญหาที่เกิดขึ้นภายในแปลงได้อย่างรวดเร็ว โดยประโยชน์ใช้สอยที่สามารถได้จากการสำรวจด้วยอากาศยานไร้คนขับ เช่น การสำรวจแปลง การติดตามการชลประทาน การตรวจจับโรคพืช และวัชพืช เป็นต้น

การบูรณาการระหว่างเทคโนโลยีปัญญาประดิษฐ์ และภูมิสารสนเทศมีบทบาทอย่างมากต่อการพัฒนาทางด้านการเกษตรเป็นหนึ่งในการทำเกษตรแบบแม่นยำ โดยการสำรวจระยะไกลจะให้ข้อมูลในเชิงพื้นที่ช่วยในการระบุลักษณะที่ปรากฏบนพื้นที่เกษตรกรรมผ่านการวัดด้วยเครื่องมือ หรือเซนเซอร์ที่มีความแม่นยำสูงในการตรวจวัด ซึ่งถูกติดตั้งอยู่บนดาวเทียม เครื่องบิน หรืออากาศยานไร้คนขับ เมื่อได้ข้อมูลบนพื้นที่เป้าหมายจึงนำข้อมูลมาผ่านกระบวนการประมวลผลภาพเพื่อสร้างค่าดัชนีต่าง ๆ จากนั้นสกัดค่าดัชนีออกเป็นตัวเลขเพื่อใช้ในการแสดงด้วยค่าทางสถิติ เพื่อช่วยในการตัดสินใจ ข้อมูลดังกล่าวถูกนำมาใช้ในการวิเคราะห์สถานะต่าง ๆ ภายในแปลงด้วยแบบจำลองการเรียนรู้แบบมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน เพื่อใช้ในงานด้านการจำแนก การทำนาย หรือการจัดกลุ่มของข้อมูล โดยถูกประยุกต์ใช้ในวัตถุประสงค์ที่หลากหลาย อาทิ การตรวจสอบความสมบูรณ์ของพืช การทำนายผลผลิต การจัดการชลประทาน การนับจำนวนพืช การวิเคราะห์ดิน การตรวจจับโรคพืช เป็นต้น Yang and Anderson (1999) ได้พัฒนาการนำข้อมูลภาพแบบหลายช่วงคลื่นที่บันทึกจากทางอากาศด้วยเครื่องบิน เพื่อใช้ในการแบ่งพื้นที่แปลงเกษตรกรรมออกเป็น 4 ส่วนด้วยกระบวนการเรียนรู้แบบไม่มีผู้สอนในการจำแนก และใช้ในการประเมินผลผลิตธัญพืชล่วงหน้า โดยเทคนิคการเก็บข้อมูลของ Everitt, Escobar, Cavazos, Noriega and Davis (1995) ถูกนำมาใช้ในการกระบวนการเก็บข้อมูล โดยเป็นการเก็บข้อมูลด้วยกล้องจำนวน 3 กล้องที่มีความยาวช่วงคลื่นแตกต่างกันคือ ช่วงคลื่นสีเขียว (Green) ด้วยความยาวคลื่น 555-556 นาโนเมตร ช่วงคลื่นสีแดง (Red) ด้วยความยาวคลื่น 625-635 นาโนเมตร และช่วงคลื่นอินฟราเรดย่านใกล้ (NIR) ด้วยความยาวคลื่น 845-857 นาโนเมตร โดยช่วงคลื่นทั้งสามชนิดถูกนำมาแปลงเป็นค่าตัวเลข และผสมรวมกันได้ภาพดิจิทัลแบบสีเทา (Grey scale) ที่เรียกว่า Color-Infrared (CIR) ค่าของข้อมูลดังกล่าวสามารถใช้ในการจำแนกพื้นที่ทางการเกษตรได้จากค่าของพิกเซลที่มีค่าใกล้เคียงกัน โดยค่าดังกล่าวเป็นตัวบ่งชี้ถึงลักษณะของพืชพรรณหรือดินในแต่ละบริเวณ และยังสามารถใช้ในการบริหารจัดการในเชิงพื้นที่ได้อีกด้วย ในการประเมินผลผลิตทางการเกษตรมีความจำเป็นที่จะต้องมีการเก็บข้อมูลในแต่ละช่วงเวลาเพื่อติดตามการเจริญเติบโตของพืช Yang and Everitt (2002) ได้ศึกษาความสัมพันธ์ระหว่างการติดตามข้อมูลปริมาณผลผลิตกับภาพถ่ายทางอากาศ 3 ช่วงคลื่นคือ Red Green และ NIR ใน 5 ช่วงเวลาที่แตกต่างกันในฤดูเพาะปลูก โดยมีความละเอียดจุดภาพที่ 8.7 เมตร พบว่าการวิเคราะห์การถดถอย (Regression Analysis) สามารถนำมาใช้ในการประเมินผลผลิตภายในแปลงได้ ด้วยการหาค่าสัมประสิทธิ์แสดงการตัดสินใจของความสัมพันธ์ระหว่างค่าเฉลี่ยของช่วงคลื่น หรือค่าดัชนีพืชพรรณชนิดต่างๆ กับค่าปริมาณผลผลิตภายในแปลง อย่างไรก็ตามความสัมพันธ์ของสมการการถดถอยดังกล่าวนี้มีความจำเพาะอย่างยิ่งต่อพื้นที่ที่เก็บรวบรวมข้อมูล โดยมีการแสดงให้เห็นว่าหากมีการเปลี่ยนแปลงพื้นที่ ช่วงเวลาในการเพาะปลูก หรือชนิดของพืช ความสัมพันธ์ดังกล่าวก็也将มีความแตกต่างไปอีกด้วย

งานวิจัยจำนวนมากได้นำเสนอแนวทางการการคาดการณ์ปริมาณผลผลิตทางการเกษตรโดยใช้ข้อมูลภาพถ่ายทางอากาศจากเซนเซอร์ที่ติดตั้งบนอากาศยานไร้คนขับ โดยข้อมูลภาพจะเป็นข้อมูลที่ได้จากการสะท้อนของวัตถุด้วยภาพ RGB และภาพถ่ายแบบหลายช่วงคลื่น (Multispectral) ข้อมูลค่าการสะท้อนจะถูกนำมาคำนวณด้วยสมการเพื่อหาค่าดัชนีพืชพรรณในการแสดงบริเวณที่เป็นพืช โดยงานวิจัยของโพธิ์ธูมิ บุญเรือง และคณะ (2564) ทำการศึกษาวิธีการทำนายปริมาณผลผลิตของน้ำหนักของอ้อยในช่วง 3 เดือนก่อนเก็บเกี่ยวภายในแปลงด้วยภาพถ่ายจากอากาศยานไร้คนขับที่มีค่า GSD เท่ากับ 1 เมตร ใช้ในการหาค่าสหสัมพันธ์ระหว่างค่าสะท้อนแสงสีแดง เขียว น้ำเงิน และค่าความสูง พบว่ามีความสัมพันธ์ที่มากกับค่าสะท้อนแสงสีแดง น้ำเงิน และค่าความสูง จึงเลือกตัวแปรดังกล่าวไปใช้ในการสร้างสมการเส้นตรง พบว่าให้ค่าสัมประสิทธิ์แสดงการตัดสินใจ เท่ากับ 0.62

Yang and Anderson (2000) ได้วิเคราะห์ค่าสหสัมพันธ์ (Correlation) ระหว่างปริมาณผลผลิตภายในแปลงกับดัชนี NDVI พบว่าค่าดัชนีดังกล่าวให้ค่าสัมประสิทธิ์สหสัมพันธ์เท่ากับ 0.95 โดยค่าดัชนีดังกล่าวสามารถประเมินได้จากค่าพิกเซลที่ได้จากภาพถ่ายหลายช่วงคลื่นบนอากาศยานพรหมชัย สุพรรณ และคณะ (2561) ได้ศึกษาวิธีการติดตามการเจริญเติบโตของข้าวด้วยภาพถ่ายจากอากาศยานไร้คนขับโดยใช้ดัชนีพืชพรรณ Normalize Red Blue Difference Index ที่คำนวณจากแสงในช่วงคลื่นสีแดงและน้ำเงินที่ได้จากภาพถ่าย RGB ในการติดตามการเจริญเติบโตในระยะข้าวแตกกอจนถึงเมล็ดข้าวสุกจากการศึกษาพบว่าความสัมพันธ์ของการสะท้อนแสงสองชนิดสามารถใช้ในการติดตามการเจริญเติบโตของพืชได้ ดัชนีพืชพรรณที่ได้จากภาพถ่ายด้วยกล้องถ่ายภาพแบบหลายช่วงคลื่น จะสามารถเก็บข้อมูลภาพถ่ายในช่วงคลื่นอินฟราเรดย่านใกล้ได้โดยเป็นที่นิยมอย่างมากในการคำนวณหาดัชนี NDVI เพื่อใช้ในการติดตามพื้นที่เพาะปลูก

มีผู้ทำการการเปรียบเทียบประสิทธิภาพในการใช้ดัชนีพืชพรรณแต่ละชนิดโดยงานวิจัยของปริญญ์ จุลถาวร (2563) ได้ศึกษาประสิทธิภาพของการใช้ดัชนี NDVI เปรียบเทียบกับดัชนีที่ได้จากภาพถ่าย RGB ในการติดตามการเจริญเติบโตของนาข้าว พบว่าดัชนี Excess Green (ExG), Visible Difference Vegetation Index (VDVI) และ Green Red Vegetation Index (GRVI) มีความสัมพันธ์ในระดับสูงกับค่าดัชนี NDVI ที่ระยะข้าวแตกกอ และพบว่าดัชนี GRVI ให้ความถูกต้องสูงสุดที่ร้อยละ 90.32 Tumlisian (2017) ได้ศึกษาการคาดการณ์ผลผลิตข้าวโพดโดยใช้ดัชนีพืชพรรณจากภาพถ่ายด้วยอากาศยานไร้คนขับด้วยกล้อง RGB จำนวน 7 ดัชนี ได้แก่ ExG, CIVE, VEG, ExGR, NGRDI และ COM โดยหาความสัมพันธ์ระหว่างค่าดัชนีพืชพรรณ ปริมาณผลผลิตและชีวมวลของพืชโดยใช้สมการถดถอยเชิงเส้นการศึกษาพบว่าดัชนี ExG ให้พบที่แม่นยำสูงสุดที่ร้อยละ 50.03 จีรวัดน์ โนดไธสง และคณะ (2562) ได้ศึกษาวิธีการทำนายผลผลิตของอ้อยโดยใช้ภาพถ่ายจากกล้อง Multispectral ที่ติดตั้งบนอากาศยานไร้คนขับ เพื่อคำนวณดัชนีพืชพรรณ NDVI และ CI red edge ร่วมกับข้อมูลปริมาตรแบบจำลองพื้นผิวเชิงตัวเลข (Volume of Digital Surface Model) เพื่อนำมาหา

ความสัมพันธ์กับผลผลิตภายในแปลง การศึกษานี้พบว่าการใช้ข้อมูล DSM ให้ค่า R^2 สูงที่สุดที่ร้อยละ 0.82 สำหรับดัชนี NDVI และ CI red edge ให้ค่า R^2 ที่ร้อยละ 0.77 และ 0.78 ตามลำดับ ทั้งนี้ข้อมูล DSM บ่งบอกถึงปริมาตรของอ้อยซึ่งมีผลโดยตรงต่อปริมาณผลผลิตของอ้อยแต่ไม่ได้ให้ข้อมูลเกี่ยวกับความสมบูรณ์ของลำต้นอ้อย และงานวิจัยนี้ยังไม่ได้ทำการตัดส่วนที่ไม่ใช่พืชออกจากข้อมูลภาพที่ใช้ในการสร้างสมการทำนายจึงทำให้เกิดความผิดพลาดขึ้น (Wahab, Hall and Jirström, 2018) ประเมินค่าความเขียวของใบพืช และผลผลิตด้วยดัชนี GNDVI ในแปลงข้าวโพดเลี้ยงสัตว์ จากภาพถ่ายด้วยอากาศยานไร้คนขับแบบขึ้นลงแนวดิ่ง VTOL มีขนาดพิกเซล 16 ตารางเมตร ประเมินหาค่าสหสัมพันธ์ของแบบจำลองสมการการถดถอยเชิงเส้น พงศ์ หลวงมูล และถาวร อ่อนประไพ (2564) ใช้ดัชนีพืชพรรณ NDVI GNDVI Canopy Cover TGI และความสูงของพืช ร่วมกันในการประเมินผลผลิตข้าวพันธุ์ชัยนาท 1 ด้วยแบบจำลองสมการการถดถอยเชิงเส้นแบบหลายตัวแปร ได้ค่าสัมประสิทธิ์แสดงการตัดสินใจ เท่ากับ 0.879 งานวิจัยของ Sun et al. (2020) ได้ศึกษาการทำนายปริมาณผลผลิตของมันฝรั่ง ซึ่งเป็นพืชหัวโดยใช้ข้อมูลภาพถ่ายแบบหลายช่วงคลื่นจากอากาศยานไร้คนขับโดยมีการควบคุมให้น้ำต่างกันในแต่ละแปลง ผลการศึกษาพบว่าแบบจำลองการเรียนรู้ของเครื่องให้ค่า R^2 สูงสุดที่ 0.63 โดยผลการทำนายปริมาณผลผลิตมีความแตกต่างกันตรงตามลักษณะการให้น้ำภายในแปลงตัวอย่าง

สำหรับการทำนายปริมาณผลผลิตมันสำปะหลังนั้นงานวิจัยของ วลัยพร ศะศิประภา และคณะ (2555) ใช้ข้อมูลดัชนี NDVI จากดาวเทียมไทยโชต (THEOS) ประเมินผลผลิตน้ำหนักของมันสำปะหลังพันธุ์ระยอง 5 และคละพันธุ์แบบปลูกปีเดียว และปลูกข้ามปี โดยใช้แบบจำลองสมการการถดถอยเชิงเส้นพบว่ามันสำปะหลังพันธุ์ระยอง 5 และคละสายพันธุ์ ที่ปลูกภายในปีเดียว มีค่าสหสัมพันธ์ในเชิงบวกกับผลผลิตที่ค่า 0.526 และ 0.668 ตามลำดับ จากงานวิจัยดังที่ได้กล่าวมาข้างต้นจะเห็นได้ว่าแบบจำลองการเรียนรู้ของเครื่องอาจมีความสามารถไม่เพียงพอต่อการฝึกฝนแบบจำลองที่ต้องการทำนายผลข้อมูลที่มีความซับซ้อนสูงแบบจำลองโครงข่ายประสาทเทียม (ANN) จึงถูกนำมาใช้ในการวิจัยเพื่อทำนายผลผลิตพืชด้วยข้อมูลจากการรับรู้ระยะไกล

งานวิจัยของ Fieuzal et al. (2017) ได้ศึกษาวิธีการทำนายผลผลิตข้าวโพดโดยใช้ภาพถ่ายจากดาวเทียม TerraSAR-X และ Radarsat-2 เพื่อคำนวณหาค่าดัชนี NDVI จากนั้นสร้างแบบจำลอง ANN เพื่อทำนายปริมาณผลผลิตหลังเก็บเกี่ยว พบว่าให้ค่าสัมประสิทธิ์แสดงการตัดสินใจ เท่ากับ 0.77 งานวิจัยที่ได้ดังกล่าวมาเป็นการนำเอาระบบการกำหนดตำแหน่งบนพื้นโลก ระบบสารสนเทศภูมิศาสตร์ และเทคนิคการประมวลผลภาพมาใช้ภายในพื้นที่การเกษตร จากการนำกระบวนการจำแนกด้วยวิธีการเรียนรู้แบบไม่มีผู้สอนในการแบ่งพื้นที่แปลง และการใช้ค่าดัชนีพืชพรรณในการประเมินผลผลิตทางการเกษตรด้วยวิธีการเก็บข้อมูลจากภาพถ่ายทางอากาศ งานวิจัยของ Basir et al. (2021) ได้เปรียบเทียบการใช้แบบจำลอง ANN กับแบบจำลองสมการถดถอย เพื่อทำนายผลผลิต

ข่าวในประเทศบังกลาเทศพบว่าแบบจำลอง ANN ให้ความแม่นยำสูงสุดที่ค่า R^2 เท่ากับ 0.994 และมีค่า RMSE เท่ากับ 0.4577

จากเนื้อหาทฤษฎีและงานวิจัยที่ได้กล่าวมาในบทที่ 2 งานวิจัยนี้จึงมุ่งเน้นที่จะพัฒนาวิธีการทำนายผลผลิตมันสำปะหลังโดยใช้แบบจำลองการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมแบบหลายชั้น เพื่อพิจารณาการทำนายปริมาณผลผลิตของมันสำปะหลังจากค่าดัชนีพืชพรรณที่ได้จากภาพถ่ายด้วยกล้องที่ถูกติดตั้งบนอากาศยานไร้คนขับ



บทที่ 3

วิธีดำเนินการวิจัย

งานวิจัยนี้นำเสนอแบบจำลองการทำนายปริมาณผลผลิตมันสำปะหลังโดยพิจารณาการทำนายค่า น้ำหนักของหัวมันสำปะหลัง และปริมาณแป้งในหัวมันสำปะหลัง โดยใช้ข้อมูลภาพถ่ายจากอากาศยานไร้คนขับแบบหลายช่วงคลื่นในการคำนวณค่าดัชนีพืชพรรณ และนำมาศึกษาความเป็นไปได้ในการทำนายผลผลิตมันสำปะหลังด้วยเทคโนโลยีปัญญาประดิษฐ์ ด้วยวิธีการเรียนรู้ของเครื่อง และวิธีการเรียนรู้เชิงลึก

3.1 ขั้นตอนการศึกษาวิจัย

ขั้นตอนการศึกษาวิจัยแบ่งหัวข้อการศึกษาได้ ดังนี้

3.1.1 ศึกษาวิธีการทำนายผลผลิตภาพถ่ายจากอากาศยานไร้คนขับ

3.1.1.1 ศึกษาวิธีการทำนายปริมาณผลผลิตมันสำปะหลัง

3.1.1.2 ศึกษาวิธีการวางแผนการบินและการเก็บข้อมูล

3.1.1.3 ศึกษาหาค่าดัชนีพืชพรรณที่ใช้ในการทำนายปริมาณผลผลิตมันสำปะหลัง

3.1.1.4 ศึกษาแบบจำลองที่ใช้ในการทำนายปริมาณผลผลิตมันสำปะหลัง

3.1.2 เก็บข้อมูลในแปลงมันสำปะหลังตัวอย่าง

3.1.2.1 เก็บข้อมูลภาพถ่ายด้วยอากาศยานไร้คนขับ

3.1.2.2 เก็บข้อมูลปริมาณผลผลิต ได้แก่ น้ำหนักหัวมันสำปะหลังสด และปริมาณแป้งในหัวมันสำปะหลังต่อหน่วยพื้นที่

3.1.3 การประมวลผลข้อมูลภาพ

3.1.3.1 ประมวลผลข้อมูลภาพเพื่อสร้างแผนที่ภาพถ่ายความละเอียดสูงหรือแผนภาพออร์โธ (Ortho Photo) และแบบจำลองพื้นผิวภูมิประเทศเชิงเลข (DSM)

3.1.3.2 คำนวณดัชนีพืชพรรณ

3.1.4 การเตรียมชุดข้อมูลสำหรับแบบจำลอง

จัดทำชุดข้อมูลสำหรับแบบจำลองการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก โดยจัดทำเป็นตารางแสดงค่าตัวเลขของปริมาณผลผลิตที่ตรวจวัดได้ภายในแปลง และดัชนีพืชพรรณที่ใช้ในการทำนายปริมาณผลผลิต ในแต่ละช่วงเวลาของแต่ละกลุ่มตัวอย่าง


3.1.5 การเลือกค่าดัชนีพืชพรรณที่ใช้ในการทำนายผลผลิตมันสำปะหลัง

ศึกษาการวิเคราะห์การถดถอยและสหสัมพันธ์ของดัชนีพืชพรรณแต่ละชนิดกับปริมาณผลผลิตมันสำปะหลัง

3.1.6 การสร้างแบบจำลองเพื่อทำนายน้ำหนัก และปริมาณแป้งมันสำปะหลัง

สร้างแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ปรับปรุงแบบจำลอง และเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลอง

3.1.7 วิเคราะห์สรุปผล และจัดทำเล่มรายงาน




รูปที่ 3.1 ขั้นตอนการศึกษาวิจัย

3.2 พื้นที่ศึกษาวิจัย

งานวิจัยนี้ศึกษาบนแปลงมันสำปะหลังพันธุ์ระยอง 72 ของเกษตรกรในพื้นที่ตำบลเฉลียง อำเภอบุรี จังหวัดนครราชสีมา พิกัด $14^{\circ}22'33.4416''\text{N}$ $102^{\circ}17'54.73622''\text{E}$ โดยมีพื้นที่เพาะปลูกที่ใช้ในการศึกษารวม 12,800 ตารางเมตร แสดงในรูปที่ 3.2 มีระยะห่างระหว่างแถว 120 เซนติเมตร. ระยะระหว่างต้น 70 เซนติเมตร. ให้น้ำด้วยระบบสายน้ำหยดเพื่อควบคุมการได้รับน้ำของพืช ซึ่งส่งผลโดยตรงต่อการเจริญเติบโตของต้นมันสำปะหลังภายในแปลง (K. Sriroth, S. Piyachomkwan, & Oates, 2001; T. Machikowa, T. Thong-ob and S. Wonprasaid, 2020; V. Santisopasri et al., 2001) แปลงตัวอย่างปลูกเมื่อวันที่ 14 พฤษภาคม พ.ศ. 2564 ข้อมูลที่ใช้ในการศึกษาประกอบด้วยตัวแปรสำคัญจำนวน 5 ตัวแปร ได้แก่ ดัชนีพืชพรรณ 3 ชนิด คือ NDVI, ExG และ GRVI น้ำหนักของหัวมันสำปะหลังสดเฉลี่ย และปริมาณแป้งในหัวมันสำปะหลังสดเฉลี่ย ข้อมูลการวิเคราะห์ดินในแปลงตัวอย่างแสดงใน ตารางที่ 3.1

ตารางที่ 3.1 การวิเคราะห์ดินในแปลงตัวอย่าง

pH (1:1)	EC (1:5)	%OM	P (ppm)	K (ppm)	Ca (ppm)	Mg (ppm)
5.98	0.046	3.13	2.27	352.4	1611.3	975.0



รูปที่ 3.2 พื้นที่ศึกษาวิจัย อำเภอบุรี จังหวัดนครราชสีมา

3.3 เครื่องมือและอุปกรณ์ในการศึกษาวิจัย

3.3.1 เครื่องมือที่ใช้ในการศึกษาวิจัย

เครื่องมือหลากหลายชนิดที่นำมาใช้ในการดำเนินงานวิจัยนี้ถูกนำมาใช้ในวัตถุประสงค์ที่แตกต่างกันตามชนิดของข้อมูลที่ต้องการ อาทิ การเก็บข้อมูลด้วยเซนเซอร์หรือกล้องที่ติดตั้งอยู่บนอากาศยานไร้คนขับ การเก็บข้อมูลในพื้นที่แปลงตัวอย่าง การประมวลผลข้อมูลภาพถ่าย การประมวลผลข้อมูลเชิงตัวเลข การสร้างแบบจำลองทำนายปริมาณผลผลิต และการดำเนินการทางสถิติ รายการเครื่องมือแสดงดังตารางที่ 3.2

ตารางที่ 3.2 เครื่องมือที่ใช้ในการดำเนินงานวิจัย

ชื่อเครื่องมือ	วัตถุประสงค์ในการใช้งาน
อากาศยานไร้คนขับรุ่น DJI Phantom 4 Pro	- ใช้ในการเก็บข้อมูลภาพถ่ายในช่วงคลื่น RGB - ติดตั้งกล้องถ่ายภาพแบบหลายช่วงคลื่น และ Sunshine sensor
Phantom 4 Pro remote controller	- ใช้ในการควบคุมอากาศยานแบบบังคับมือ และใช้ในการเชื่อมต่ออากาศยานกับ Apple I-pad generation 6
กล้องถ่ายภาพแบบหลายช่วงคลื่น รุ่น Parrot SEQUOIA	- ใช้ในการเก็บข้อมูลภาพถ่ายในช่วงคลื่น Red, Green, Red-edge และ NIR
Sunshine sensor รุ่น Parrot Sequoia	- ใช้ในการสอบเทียบค่าแสงในการถ่ายภาพของกล้องถ่ายภาพแบบหลายช่วงคลื่น
Apple I-pad generation 6	- ใช้ในการควบคุมอากาศยาน และใช้ในการวางแผนการบินแบบอัตโนมัติผ่านแอปพลิเคชัน Pix4D Capture
iPhone Xs Max	- ใช้ในการควบคุมกล้องถ่ายภาพแบบหลายช่วงคลื่น
MacBook pro 16 นิ้ว (2019)	- ใช้ในการประมวลผลภาพถ่ายด้วยซอฟต์แวร์ Pix4D mapper
Acer Aspire VX15 core i7	- ใช้ในการสร้างแผนที่และคำนวณดัชนีพืชพรรณด้วยซอฟต์แวร์ QGIS 3.20.3
Reimann scale balance	- ใช้ในการวัดปริมาณแป้งในหัวมันสำปะหลังสด
ตราชั่งสปริง	- ใช้ในการชั่งน้ำหนักหัวมันสำปะหลังสด
จอบ เสียม และถุงบรรจุตัวอย่าง	- ใช้ในการเก็บตัวอย่างมันสำปะหลัง
ตลับเมตร	- ใช้ในการวัดพื้นที่เก็บตัวอย่าง

อากาศยานที่ใช้ในการเก็บข้อมูลภาพถ่าย เป็นอากาศยานไร้คนขับรุ่น DJI Phantom 4 Pro (รูปที่ 3.3) ที่มีกล้องสำหรับบันทึกภาพถ่าย RGB ภายในตัวเป็นกล้องรุ่น


CanonEOS600D-3.6-4000x3000 (DJI, 2016) นอกจากนี้ ยังได้ทำการทำการติดตั้งกล้องถ่ายภาพหลายช่วงคลื่นรุ่น Parrot SEQUOIA พร้อมด้วย Sunshine sensor (รูปที่ 3.4) โดยจะใช้ในการถ่ายภาพ 4 ช่วงคลื่น ได้แก่ Green, Red, Red Edge และ NIR แต่ละช่วงมีความถี่ 550, 660, 735 และ 790 นาโนเมตร ตามลำดับ เป็นภาพขนาด 1280 x 960 พิกเซล (Parrot, 2022) ภาพที่ได้จะถูกใช้ในการคำนวณหาค่าดัชนีพืชพรรณ รายละเอียดของอากาศยานไร้คนขับและกล้องที่ติดตั้งบนอากาศยานแสดงดังตารางที่ 3.3

ตารางที่ 3.3 สมรรถนะ ส่วนประกอบของอากาศยาน และกล้องที่ติดตั้งบนอากาศยาน

รายการ	รายละเอียด
จำนวนใบพัด	4 ใบพัด
น้ำหนักอากาศยาน	1.38 กิโลกรัม
Takeoff weight	1.58 กิโลกรัม
เพดานบินสูงสุด	6,000 เมตร
ระบบระบุตำแหน่ง	GPS/GLONASS (GNSS)
แบตเตอรี่ของอากาศยาน	Lithium-polymer, 5,350 mAh, 15.20 V
น้ำหนักกล้องถ่ายภาพหลายช่วงคลื่น	197 กรัม
แบตเตอรี่กล้องถ่ายภาพหลายช่วงคลื่น	Lithium-polymer, 5,000 mAh, 5 V, 2.40 A



รูปที่ 3.3 อากาศยานไร้คนขับรุ่น DJI Phantom 4 Pro ที่มีการติดตั้งกล้องถ่ายภาพแบบหลายช่วงคลื่นและ Sunshine sensor และ Remote controller



รูปที่ 3.4 กล้องถ่ายภาพแบบหลายช่วงคลื่น รุ่น Parrot SEQUOIA และ Sunshine Sensor (Parrot, 2022)

3.3.2 ซอฟต์แวร์ที่ใช้ในการศึกษาวิจัย

ในการศึกษานี้การได้มาซึ่งข้อมูล การสกัดข้อมูล การวิเคราะห์ข้อมูล และการพัฒนาแบบจำลอง รวมไปถึงการจัดทำรายงานสรุป จำเป็นอย่างยิ่งที่ต้องมีซอฟต์แวร์ช่วยในการดำเนินการร่วมกับวัสดุอุปกรณ์ที่ได้กล่าวมาข้างต้น โดยรายการซอฟต์แวร์และแอปพลิเคชันที่ใช้ในการศึกษาวิจัยแสดงดังตารางที่ 3.4

ตารางที่ 3.4 ซอฟต์แวร์ที่ใช้ในการดำเนินงานวิจัย

ชื่อซอฟต์แวร์	วัตถุประสงค์ในการใช้งาน
Pix4D capture	- ใช้สำหรับวางแผนการบิน และการเก็บข้อมูลภาพถ่าย
Pix4D mapper	- ใช้ประมวลผลข้อมูลภาพถ่ายจากอากาศยาน เพื่อสร้างแผนที่ภาพถ่ายความละเอียดสูงและแบบจำลองพื้นผิวภูมิประเทศเชิงเลข
DJI GO 4 App	- ใช้ในการเชื่อมต่ออากาศยาน ตรวจสอบสถานะของอากาศยาน และควบคุมอากาศยานแบบบังคับมือ
Parrot SEQUOIA HTML Interface	- ใช้ในการเชื่อมต่อกับกล้องถ่ายภาพแบบหลายช่วงคลื่น
QGIS 3.20.3	- ใช้ในการจัดการข้อมูลเชิงภูมิสารสนเทศ และคำนวณดัชนีพืชพรรณ และการสร้างแผนที่
Jupyter Notebook บน Anaconda 3	- ใช้เป็นเครื่องมือในการเขียนโปรแกรมภาษาไพธอน เพื่อการฝึกฝนแบบจำลองโครงข่ายประสาทเทียม

ตารางที่ 3.4 ซอฟต์แวร์ที่ใช้ในการดำเนินงานวิจัย (ต่อ)

ชื่อซอฟต์แวร์	วัตถุประสงค์ในการใช้งาน
Jupyter Notebook บน Google Colaboratory	- ใช้เป็นเครื่องมือในการเขียนโปรแกรมภาษาไพธอน เพื่อการวิเคราะห์การถดถอย คำนวณค่าสหสัมพันธ์ และการฝึกฝนแบบจำลองโครงข่ายประสาทเทียม
MATLAB® R2018a	- ใช้ในการฝึกฝนแบบจำลองโครงข่ายประสาทเทียม
Google Drive	- ใช้ในการเก็บชุดข้อมูลสำหรับประมวลผลใน Google Collabratory
Microsoft OneDrive	- ใช้ในการเก็บข้อมูลภาพถ่าย ใช้ในการเก็บข้อมูล ภาพถ่ายแผนที่ความละเอียดสูง และแบบจำลองพื้นผิว ภูมิประเทศเชิงเลข
Microsoft Excel	- ใช้ในการจัดทำชุดข้อมูล วิเคราะห์ข้อมูล และทำสื่อนำเสนอข้อมูล
Microsoft Word	- ใช้ในการจัดทำเอกสารประกอบการศึกษา และจัดทำเล่มวิทยานิพนธ์

3.4 การเก็บข้อมูลภาพถ่ายด้วยอากาศยานไร้คนขับ

การเก็บข้อมูลภาพถ่ายด้วยกล้อง RGB ที่ติดตั้งบนอากาศยานไร้คนขับ และกล้องถ่ายภาพแบบหลายช่วงคลื่น โดยเริ่มจากการวางแผนการบินถ่ายภาพด้วยกล้อง RGB ที่ติดตั้งบนอากาศยานด้วยซอฟต์แวร์ Pix4D Capture (ดูที่ภาคผนวก ข.) การตั้งค่าการถ่ายภาพของกล้องถ่ายภาพแบบหลายช่วงคลื่น และการกำหนดความถี่ในการเก็บข้อมูล

3.4.1 การวางแผนการบิน

การวางแผนการบินถ่ายภาพเพื่อเก็บข้อมูลแปลงมันสำปะหลังตัวอย่าง จะกำหนดค่าการถ่ายภาพเป็นแบบ Grid แสดงดังรูปที่ 3.5 โดยมีลักษณะเป็นโครงข่ายเส้นขนานเพื่อให้สามารถบินเก็บภาพได้อย่างครอบคลุมแม่นยำ กำหนดค่าอัตราส่วนการซ้อนทับกับ 80% และส่วนเกยทับกับ 70% เพื่อให้ภาพสามารถต่อกันได้โดยกำหนดค่าอัตราส่วนซ้อนและส่วนเกยทับขั้นต่ำที่ 75% และ 60% ตามลำดับ (กรมโยธาธิการและผังเมือง, สำนักวิศวกรรมการผังเมือง, 2564) แผนการบินครอบคลุมพื้นที่ขนาด 12,800 ตารางเมตร กำหนดความสูงในการบิน 30 เมตร ความเร็วในการบิน 4 เมตร/วินาที อากาศยานจะเคลื่อนที่และปรับความเร็วเพื่อถ่ายภาพบนเส้นทางการบินที่ตามตัวแปรที่ถูกกำหนดไว้ โดยอาศัยตำแหน่งจากระบบกำหนดพิกัดที่ติดตั้งภายในตัวเครื่องของอากาศยาน หรือ On board Global Navigation Satellite System (GNSS) ดังที่แสดงในรูปที่ 3.5



รูปที่ 3.5 การกำหนดเส้นทางการบิน

โดยค่าความสูงเป็นตัวแปรที่ใช้ในการกำหนดค่า Ground Sampling Distance (GSD) มีค่าประมาณ 0.8 เซนติเมตร ซึ่งเป็นค่าที่บ่งบอกถึงค่าความถูกต้องทางรายละเอียดที่ระดับความเชื่อมั่น 95% นอกจากนี้ความสูงยังส่งผลโดยตรงต่อระยะเวลาที่ใช้ในการบิน และจำนวนภาพที่เพิ่มขึ้นจากความสูงที่ลดลง เวลาที่เหมาะสมในการบินเก็บข้อมูลต้องคำนึงถึงการเกิดเงาสะท้อนจากมุมรังสีของดวงอาทิตย์โดยกำหนดช่วงเวลาในการบินระหว่างเวลา 9.00 น. ถึงเวลา 15.00 น. ซึ่งเป็นเวลาที่ดวงอาทิตย์อยู่สูงกว่ามุม 45 องศาจากเส้นขอบฟ้า (กรมโยธาธิการและผังเมือง, สำนักวิศวกรรม การผังเมือง, 2564)

3.4.2 การถ่ายภาพด้วยกล้องถ่ายภาพแบบหลายช่วงคลื่น

สำหรับการตั้งค่าการถ่ายภาพด้วยกล้องถ่ายภาพแบบหลายช่วงคลื่น รุ่น Parrot SEQUOIA นั้นสามารถเชื่อมต่อผ่านระบบ WI-FI ของตัวกล้อง โดยตั้งค่าความเร็วในการถ่ายภาพผ่านทาง Parrot SEQUOIA HTML Interface โดยจะตั้งค่า %overlap ที่ 80 ทำให้ได้ค่า Timelapse interval อยู่ที่ 1.4 วินาทีจากการคำนวณรายละเอียดการตั้งค่าแสดงได้ดังตารางที่ 3.5

ในการกำหนดค่าความสูงในการบินนั้นถูกกำหนดอยู่ที่ 30 เมตร จากความสูงที่นำเครื่องขึ้น เพื่อให้มีความละเอียดต่อจุดภาพ (GSD) ของภาพที่ได้จากกล้องถ่ายภาพแบบหลายช่วงคลื่นอยู่ที่ประมาณ 3 เซนติเมตร (Parrot, 2022)

สำหรับค่าการซ้อนทับถูกกำหนดที่ 80% เนื่องจากการสำรวจด้วยอากาศยานไร้คนขับ ไม่สามารถควบคุมความเร็วและทิศทางการบินได้อย่างสม่ำเสมอตลอดระยะเวลาในการถ่ายภาพ ดังนั้นการกำหนดค่าการซ้อนทับของภาพถ่าย จึงมีความสำคัญต่อการต่อภาพในซอฟต์แวร์ Pix4D Mapper

ตารางที่ 3.5 การตั้งค่าการถ่ายภาพบน Parrot SEQUOIA HTML Interface

รายละเอียด/ตัวแปร	ค่าที่กำหนด	หมายเหตุ
Capture Mode	Time-lapse	
ความสูง	30 เมตร	คำแนะนำ (Parrot, 2022)
ความเร็ว	4 เมตร/วินาที	ความเร็วโดยประมาณ
Overlap	80%	อัตราส่วนซ้อนทับ
Timelapse interval	1.4 วินาที	ค่าจากการคำนวณ
Resolution	1.2 MPix	ค่าเริ่มต้น
Bit depth	10 bit	ค่าเริ่มต้น
Main Camera Resolution	16 MPix	ค่าเริ่มต้น

การสอบเทียบค่าแสงสำหรับกล้องถ่ายภาพแบบหลายช่วงคลื่นรุ่น Parrot SEQUOIA เป็นการสอบเทียบค่าแสงจาก Sunshine sensor และค่าแสงของภาพที่ได้จากกล้อง เพื่อให้ข้อมูลภาพถ่ายในแต่ละช่วงที่เก็บข้อมูลมีค่าการสะท้อนของพืชที่ถูกต้อง สามารถนำข้อมูลภาพไปใช้ในการสร้างดัชนีพืชพรรณที่แม่นยำ และสามารถเปรียบเทียบค่ากับข้อมูลที่เก็บในช่วงเวลาอื่นได้ (Parrot, 2022) สำหรับกล้องถ่ายภาพแบบหลายช่วงคลื่นรุ่น Parrot SEQUOIA จะใช้แผ่นสอบเทียบที่มีการกำหนดแนวระดับน้ำและเข็มทิศ เพื่อให้สามารถคำนวณค่าแสงได้อย่างแม่นยำ การสอบเทียบให้ทำก่อนหรือหลังการถ่ายภาพโดยทำในสภาพแวดล้อมที่มีแสงแบบเดียวกัน การสอบเทียบทำได้โดยการถ่ายภาพแผ่นสอบเทียบด้วยกล้องถ่ายภาพแบบหลายช่วงคลื่นที่ความสูงเหนือแผ่นสอบเทียบประมาณ 1 เมตร การสอบเทียบค่าแสงแสดงในรูปที่ 3.6 (ดูในภาคผนวก ข.)



รูปที่ 3.6 การสอบเทียบค่าแสง

3.4.3 ความถี่ในการเก็บข้อมูลภาพถ่าย

การศึกษานี้จะเก็บข้อมูลภาพถ่ายพร้อมกับการเก็บข้อมูลตัวอย่างมันสำปะหลัง ภายในแปลงในช่วง 8 – 12 เดือนหลังปลูก (ประมาณ 240 – 360 วันหลังปลูก) ระหว่างเดือน ธันวาคม พ.ศ. 2564 ถึงมีนาคม พ.ศ. 2565 ดำเนินการเก็บข้อมูลในช่วงเวลาระหว่างเวลา 9.00 น. ถึง เวลา 14.00 น. ความถี่ในการเก็บข้อมูลทุก 30 วัน โดยแบ่งการเก็บข้อมูลออกเป็น 4 รอบ วันที่เก็บ ข้อมูล จำนวนไฟล์ภาพถ่ายนามสกุล .JPG แสดงดังตารางที่ 3.6

ตารางที่ 3.6 ระยะเวลาการเก็บข้อมูล และจำนวนภาพถ่ายจากแปลงตัวอย่างในแต่ละรอบ

รอบที่	วันที่	จำนวนภาพถ่าย	จำนวนภาพถ่าย
		RGB (รูป)	Multispectral (รูป)
1	28 ธันวาคม พ.ศ. 2564	531	3,044
2	29 มกราคม พ.ศ. 2565	493	1,924
3	29 กุมภาพันธ์ พ.ศ. 2565	618	1,749
4	28 มีนาคม พ.ศ. 2565	511	2,408

3.5 การเก็บข้อมูลปริมาณผลผลิต

การเก็บข้อมูลปริมาณผลผลิตจะมีความถี่ในการเก็บเช่นเดียวกับการเก็บข้อมูลภาพถ่าย โดยจะเก็บภายหลังจากการถ่ายภาพแปลงด้วยกล้องที่ติดตั้งบนอากาศยานไร้คนขับ และมีการตรวจวัดน้ำหนักและปริมาณแบ่งในห้วงนํ้าสำหรับหลังภายในวันเดียวกันเพื่อให้สามารถใช้ข้อมูลดัชนีพืชพรรณที่สกัดได้จากภาพมาใช้ในการทำนายปริมาณผลผลิตได้


การเก็บข้อมูลในพื้นที่แปลงตัวอย่างจะทำการศึกษาข้อมูล 2 ลักษณะคือ น้ำหนักของห้วงนํ้าสำหรับหลังสดด้วยเครื่องชั่งสปริง และวัดปริมาณแบ่งในห้วงนํ้าสำหรับหลังสดด้วยเครื่อง Reimann Scale Balance แสดงในรูปที่ 3.7



รูปที่ 3.7 Reiman Scale Balance

การสุ่มตัวอย่างภายในแปลงด้วยวิธีการ Simple Random Sampling โดยเป็นการสุ่มเก็บตัวอย่างกระจายทั่วถึงภายในแปลงเพื่อให้ได้ข้อมูลที่เป็นตัวแทนของตัวอย่างที่เก็บภายในแปลง โดยแบ่งออกเป็นแปลงย่อยหรือพล็อต (plot) และภายในแปลงย่อยจะมีการแบ่งเป็นแปลงย่อยหรือซับพล็อต (sub-plot) การสุ่มตัวอย่างห้วงนํ้าสำหรับหลังสดภายในแปลงเพื่อจัดทำข้อมูลปริมาณผลผลิตในแต่ละรอบการเก็บข้อมูลนั้น จำเป็นต้องเก็บข้อมูลที่สามารถเป็นตัวแทนโดยภาพรวมของข้อมูลปริมาณผลผลิตทั้งหมดภายในแปลงได้ โดยวิธีการเก็บข้อมูลแบบ Simple Random Sampling ที่เหมาะสมกับการเก็บข้อมูลเชิงปริมาณโดยเหมาะสมกับข้อมูลที่มีลักษณะคล้ายคลึงกันในพื้นที่เดียวกัน เพื่อเป็นตัวแทนของข้อมูลทั้งหมด (Noor et al., 2022) และยังถูกใช้งานอย่างแพร่หลายในการเก็บข้อมูลปริมาณผลผลิตทางการเกษตร

การแบ่งพื้นที่แปลงขนาด 12,800 ตารางเมตร โดยแบ่งพื้นที่เก็บข้อมูลออกเป็น 3 แปลง โดยมีขนาดแปลงละประมาณ 4,260 ตารางเมตร พิจารณาจากการวางแผนระบบสายน้ำหยด แต่ละแปลงแบ่งออกเป็น 4 แปลงย่อยโดยมีขนาดแปลงละประมาณ 900 ตารางเมตร แสดงในรูปที่ 3.8 แต่ละแปลงย่อยมีการสุ่มเก็บข้อมูลกลุ่มตัวอย่าง 10 จุด เพื่อหาค่าเฉลี่ยต่อหน่วยพื้นที่ (ตารางเมตร) ได้จำนวนแปลงละ 10 ตัวอย่างเพื่อให้ได้ข้อมูลที่เป็นตัวแทนของข้อมูลแปลงทั้งหมด รวมข้อมูลทั้งหมดในแต่ละรอบการเก็บข้อมูลจำนวน 120 ข้อมูล โดยเมื่อรวมข้อมูลทั้งหมดในการเก็บข้อมูล 4 รอบ มีจำนวนข้อมูลทั้งหมด 480 ข้อมูล



รูปที่ 3.8 การแบ่งพื้นที่ศึกษาวิจัยออกเป็นแปลงย่อย



รูปที่ 3.9 การเก็บข้อมูลในหนึ่งจุดของกลุ่มตัวอย่าง

3.6 การประมวลผลข้อมูลภาพ

ข้อมูลภาพถ่ายทั้งแปลงจากอากาศยานไร้คนขับจะถูกนำมาประมวลผลเพื่อสร้างแผนที่ภาพถ่ายความละเอียดสูง ในรูปแบบของข้อมูลราสเตอร์ (Raster) โดยใช้ซอฟต์แวร์ Pix4D Mapper โดยจะมีการประมวลผลข้อมูลแยกกันระหว่างภาพที่ได้จากกล้อง RGB และภาพถ่ายจากกล้องถ่ายภาพหลายช่วงคลื่นที่ติดตั้งบนอากาศยานทำให้ได้แผนที่ภาพถ่ายความละเอียดสูงจำนวน 2 ภาพของแต่ละรอบการเก็บข้อมูล สำหรับข้อมูลภาพถ่าย RGB จะถูกประมวลผลใน Template 3D Map ได้แผนที่ภาพถ่ายออร์โธที่ประกอบด้วยการซ้อนทับกันของภาพในช่วงคลื่นสีแดง เขียว และน้ำเงิน สำหรับภาพที่ได้จากกล้องถ่ายภาพหลายช่วงคลื่นจะถูกนำไปประมวลผลใน Template AgMultispectral ได้แผนที่ภาพถ่ายออร์โธของช่วงคลื่น Green, Red, Red Edge และ NIR โดยภาพการสะท้อนของช่วงคลื่นต่าง ๆ จะถูกแปลงเป็นค่าข้อมูลเชิงเลข (Digital Number) หรือ DN ในแต่ละพิกเซลสำหรับคำนวณดัชนีพืชพรรณ ขั้นตอนในการประมวลผลข้อมูลภาพโดยทั่วไปมี 3 ขั้นตอน ดังต่อไปนี้

3.6.1 ขั้นตอน Initial processing


เป็นขั้นตอนแรกในการนำเข้าภาพ เพื่อทำการคำนวณและกำหนดตำแหน่งของข้อมูลภาพถ่ายในแต่ละภาพที่ถูกอัปโหลดเข้าสู่ซอฟต์แวร์ ระบุจุดควบคุมภาพถ่าย (Ground control point) หากมีตำแหน่งจุดควบคุมภาพถ่าย และตั้งค่าการประมวลผลเมื่อประมวลผลเสร็จสิ้นจะได้รายงานการประมวลผล (Quality report) ตัวอย่างแสดงในภาคผนวก ค.

3.6.2 ขั้นตอน Point cloud and Mesh


เป็นการสร้างกลุ่มของจุดในพิกัดสามมิติ หรือ Point cloud จำนวนมาก เพื่อให้ได้รายละเอียดข้อมูลในการประมวลผลที่ชัดเจน และนำข้อมูลจุดสามมิติไปประมวลผลต่อเพื่อสร้าง Mesh Model สำหรับสร้างข้อมูลพื้นที่ผิว โดยมีโครงสร้างแบบเวกเตอร์ที่สามารถแสดงลักษณะรูปร่างของโมเดลเพื่อนำไปใช้ในการสร้างแบบจำลองพื้นผิวภูมิประเทศเชิงเลข และแผนที่ภาพถ่ายความละเอียดสูง

3.6.3 ขั้นตอน DSM, Orth-mosaic and Index


เป็นขั้นตอนสุดท้ายในการประมวลผลภาพถ่าย DSM, Orth-mosaic and Index จะได้ข้อมูลภาพแบบจำลองพื้นผิวภูมิประเทศเชิงเลขและแผนที่ภาพถ่ายความละเอียดสูง (รูปที่ 3.11 และ 3.12) ในรูปแบบของไฟล์ .tiff หรือ .tif ซึ่งเป็นข้อมูลราสเตอร์ที่ใช้ประมวลผลโดยใช้ซอฟต์แวร์ QGIS และการคำนวณดัชนีพืชพรรณในขั้นตอนต่อไป



รูปที่ 3.10 ขั้นตอนการประมวลผลภาพถ่ายด้วย Pix4D Mapper



รูปที่ 3.11 แผนที่ภาพถ่ายความละเอียดสูง และแบบจำลองพื้นผิวภูมิประเทศเชิงเลข ของภาพที่ได้จากกล้องถ่ายภาพ RGB




รูปที่ 3.12 แผนที่ภาพถ่ายความละเอียดสูงของแต่ละช่วงคลื่น และแบบจำลองพื้นผิวภูมิประเทศเชิงเลขของภาพที่ได้จากกล้องถ่ายภาพแบบหลายช่วงคลื่น

ภายหลังจากการประมวลผลทั้ง 3 ขั้นตอนแล้วจะได้ไฟล์รายงานการประมวลผลฉบับสมบูรณ์เพื่อใช้ประกอบในการพิจารณาคุณภาพของแผนที่ภาพถ่ายความละเอียดสูงและแบบจำลองพื้นผิวภูมิประเทศเชิงเลขว่าตรงตามความต้องการหรือไม่ สำหรับวิธีการตั้งค่าในการประมวลทุกขั้นตอนแสดงได้ดังภาคผนวก ข.

3.7 การคำนวณดัชนีพืชพรรณ

ค่าดัชนีพืชพรรณเป็นหนึ่งในเครื่องมือในการจำแนกพืชออกจากวัตถุอื่นภายในภาพ ใช้ในการระบุความหนาแน่นและความสมบูรณ์ของพืชพรรณ และติดตามการเจริญเติบโตของพืช (Jiang et al., 2020) การคำนวณค่าดัชนีพืชพรรณในงานวิจัยนี้แบ่งออกเป็น 2 ส่วน คือ การคำนวณค่าดัชนีพืชพรรณจากภาพถ่าย RGB จำนวน 2 ชนิด คือ ดัชนีพืชพรรณ ExG และดัชนีพืชพรรณ GRVI และการคำนวณค่าดัชนีพืชพรรณ NDVI จากภาพถ่ายด้วยกล้องถ่ายภาพแบบหลายช่วงคลื่นที่มีการถ่ายภาพในช่วงคลื่น NIR

ดัชนีพืชพรรณทั้ง 3 ชนิดในงานวิจัยนี้ถูกคำนวณจากภาพที่ได้จากการประมวลผลในขั้นตอนก่อนหน้า โดยทำการคำนวณภายในซอฟต์แวร์ QGIS 3.20.3 โดยใช้เครื่องมือ Raster Calculator (ชิงชัย หุมห่อง, 2563) จากนั้นจึงสกัดค่าดัชนีพืชพรรณเฉลี่ยของแต่ละดัชนีในบริเวณที่มีการเก็บตัวอย่าง วิธีการใช้งานซอฟต์แวร์ QGIS แสดงในภาคผนวก ง. ตัวอย่างแผนที่ภาพถ่ายความละเอียดสูงที่ถูกนำไปคำนวณค่าดัชนีพืชพรรณ 3 ชนิด คือ ExG, GRVI และ NDVI เทียบกับภาพ RGB แสดงในรูปที่ 3.13 โดยค่าแถบสีแสดงถึงค่าของดัชนีในแต่ละภาพ



รูปที่ 3.13 แผนที่ภาพถ่ายความละเอียดสูงของ (a) ภาพถ่าย RGB และดัชนีพืชพรรณ (b) ExG (c) GRVI (d) NDVI

ภายหลังจากที่แผนที่ภาพถ่ายความละเอียดสูงถูกนำไปคำนวณหาค่าดัชนีพืชพรรณแล้ว จะถูกนำไปสกัดค่าเพื่อหาค่าเฉลี่ยของดัชนีพืชพรรณของแต่ละตัวอย่างโดยการจำแนกส่วนที่เป็นพื้นและส่วนที่ไม่ใช่พืชออกจากกันโดยใช้ค่าขีดแบ่งสำหรับดัชนีพืชพรรณแต่ละชนิดบนซอฟต์แวร์ QGIS แสดงวิธีการใช้งานในภาคผนวก ก. ข้อมูลดังกล่าวจะถูกนำไปเข้าสู่กระบวนการเตรียมข้อมูลด้วยซอฟต์แวร์ Microsoft Excel เพื่อใช้เป็นส่วนหนึ่งในตัวแปรของชุดข้อมูลที่ใช้ในการฝึกฝนแบบจำลอง

3.8 การเตรียมชุดข้อมูล การออกแบบโครงสร้างของแบบจำลอง และการประเมินประสิทธิภาพของแบบจำลอง

3.8.1 การเตรียมชุดข้อมูล

ข้อมูลที่ใช้ในการศึกษานี้ประกอบด้วยข้อมูลน้ำหนักหัวมันสำปะหลังสด (กิโลกรัม/ตารางเมตร) และปริมาณแป้งในหัวมันสำปะหลังสด (%) ภายในแปลงและข้อมูลดัชนีพืชพรรณที่เก็บจากภาพถ่ายแบบหลายช่วงคลื่นที่ได้จากกล้องบนอากาศยานไร้คนขับ ข้อมูลที่เก็บได้เป็นข้อมูลที่เก็บจากแปลงมันสำปะหลังตัวอย่างพันธุ์ระยอง 72 ที่มีอายุ 8 ถึง 12 เดือนหลังปลูกโดยมีความถี่ในการ

เก็บข้อมูลทุก 30 วัน รวมรอบการเก็บข้อมูล 4 รอบ มีจำนวนตัวอย่างที่ได้จากการเก็บข้อมูลในแต่ละรอบที่ 120 ข้อมูล รวมจำนวนข้อมูลทั้งหมดที่ได้จากการเก็บตัวอย่างเท่ากับ 480 ข้อมูล ข้อมูลจะถูกนำมาจัดทำเป็นชุดข้อมูล (Dataset) โดยใช้ซอฟต์แวร์ Microsoft Excel แบ่งออกเป็นข้อมูลดัชนีพืชพรรณ 3 ชนิด และข้อมูลปริมาณผลผลิต 2 ชนิด เก็บอยู่ในรูปแบบไฟล์ .xlsx และ .csv ชุดข้อมูลในการศึกษานี้แสดงภาคผนวก จ.

3.8.2 การเลือกใช้ค่าดัชนีพืชพรรณ

สำหรับการเลือกใช้ค่าดัชนีพืชพรรณที่เหมาะสมในการทำนายของแบบจำลองจะใช้การวิเคราะห์การถดถอยและสหสัมพันธ์ เพื่อหาว่าข้อมูลดัชนีพืชพรรณชนิดใดมีความเหมาะสมที่สุดในการพัฒนาแบบจำลอง การหาค่าดัชนีพืชพรรณที่เหมาะสมที่สุดแสดงในบทถัดไป

3.8.3 การเตรียมชุดข้อมูล และออกแบบโครงสร้างของแบบจำลอง

การเตรียมข้อมูลสำหรับแบบจำลองโครงข่ายประสาทเทียมด้วยการเขียนโปรแกรมภาษาไพธอนบน Jupyter Notebook ด้วยชุดคำสั่ง Keras และ TensorFlow (ภาคผนวก ฉ.) จะแบ่งข้อมูลออกเป็นข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบในอัตราส่วน (Train-Test split ratio) เท่ากับ 80 ต่อ 20 สำหรับแบบจำลองจะมีการปรับจำนวนชั้นซ่อน ระหว่าง 1-10 ชั้นซ่อน โดยในแต่ละชั้นซ่อนจะประกอบด้วยจำนวนโหนดเท่ากัน กำหนดให้มีการปรับค่าจำนวนโหนดเป็น 8, 16, 32 และ 64 โหนดตามลำดับ และมีการประมวลผลที่รอบการประมวลผลสูงสุดที่ 1,500 Epochs ตัวแปรที่เกี่ยวข้องในการประมวลผลมีการกำหนดให้เป็นค่าเดียวกันทั้งหมดโดยกำหนดดังตารางที่ 3.7

ตารางที่ 3.7 การออกแบบโครงสร้างแบบจำลองด้วยการเขียนโปรแกรมภาษาไพธอน

ตัวแปรการออกแบบ	จำนวน/ชนิด
สัดส่วนข้อมูลชุดฝึกฝน และชุดทดสอบ	80:20
จำนวนชั้นซ่อน	1-10
จำนวนโหนด	8, 16, 32 และ 64
จำนวนรอบการประมวลผล	1,500
อัตราการเรียนรู้ (Learning rate)	0.001
ขนาดของกลุ่มข้อมูล (Batch size)	16
ฟังก์ชันกระตุ้น	ReLU, Linear (ที่ชั้นส่งออก)
Feature scaling	Standard Scaler
Optimizer	Adam
การเร็กคิวลารีเซชัน: การวิเคราะห์สัญญาณตกหาย	20%

```

[ ] from sklearn.model_selection import train_test_split
    from tensorflow.keras import Sequential
    from tensorflow.keras.layers import Dense, Dropout
    from sklearn.metrics import mean_squared_error, r2_score

    # Train-Test-Split
    x2 = data['NDVI'].values.reshape(-1,1)
    y2 = data['Yield_weight'].values.reshape(-1,1) # Yield_weight Percent_strach
    X_train, X_test, y_train, y_test = train_test_split(x2, y2, test_size = 0.2, random_state=1)
    #X_train.shape, X_test.shape, y_train.shape, y_test.shape

    # Build Model
    learning_rate = 0.001
    node=8
    model = Sequential()
    model.add(Dense(node, activation='relu',input_shape=(1,))) #Input layer
    model.add(Dense(node,activation='relu')) # Hidden layer 1
    model.add(Dense(node,activation='relu')) # Hidden layer 2
    model.add(Dense(node,activation='relu')) # Hidden layer 3
    model.add(Dense(node,activation='relu')) # Hidden layer 4
    #model.add(Dense(node,activation='relu')) # Hidden layer 5
    model.add(Dense(1,activation='linear')) #Output layer
    #model.summary()
    model.compile(loss='mean_squared_error', optimizer='Adam', metrics=['Accuracy']) #with default LearningRate
    model.fit(X_train,y_train, epochs=1500, verbose=0, batch_size=16)

    <keras.src.callbacks.History at 0x7f772e66ece0>

[ ] #model evaluate Loss
    score = model.evaluate(X_train, y_train, verbose=0)
    score1 = model.evaluate(X_test, y_test, verbose=0)
    RMSE_train = np.sqrt(score)
  
```

รูปที่ 3.14 การสร้างแบบจำลองบน Google Colaboratory

การเตรียมข้อมูลสำหรับแบบจำลองโครงข่ายประสาทเทียมด้วยการใช้ซอฟต์แวร์ MATLAB® R2018a ข้อมูลจะถูกนำไปลดขนาดโดยใช้ Standard Scaler ก่อนจะแบ่งข้อมูลออกเป็นข้อมูลชุดฝึกฝน ชุดตรวจสอบ และชุดทดสอบ (Train-Validation-Test split ratio) ในอัตราส่วนเท่ากับ 80 ต่อ 10 ต่อ 10 สำหรับการฝึกฝนแบบจำลองโครงข่ายประสาทเทียมด้วย Neural Network Toolbox แสดงวิธีการฝึกฝนแบบจำลองได้ใน ภาคผนวก ช. เลือกใช้อัลกอริทึมสำหรับการประมวลผล (Training Algorithms) 3 ชนิดคือ Scaled conjugate gradient algorithm (SCG), Levenberg-Marquardt algorithm (LM) และ Bayesian regularization (BR) สำหรับจำนวนรอบการประมวลผลและจำนวนโหนดในการประมวลผล ซอฟต์แวร์จะคำนวณหาจำนวนรอบที่ได้ประสิทธิภาพสูงที่สุดในการฝึกฝนแบบจำลอง รายละเอียดตัวแปรในการประมวลผลแสดงได้ดังตารางที่ 3.8

ตารางที่ 3.8 การออกแบบโครงสร้างแบบจำลองด้วยการใช้ซอฟต์แวร์ MATLAB® R2018a

ตัวแปรการออกแบบ	จำนวน/ชนิด	หมายเหตุ
อัลกอริทึมสำหรับฝึกฝน	LM, SCG และ BR	
สัดส่วนข้อมูลชุดฝึกฝน ตรวจสอบ และทดสอบ	80:10:10	LM และ SCG
สัดส่วนข้อมูลชุดฝึกฝน และทดสอบ	80:20	BR
จำนวนชั้นซ่อน	1 – 10	
อัตราการเรียนรู้	0.001	

3.8.4 การประเมินประสิทธิภาพของแบบจำลอง

การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมเป็นการใช้แบบจำลองสำหรับการทำนายจึงเลือกใช้ค่า R^2 สำหรับการประเมินประสิทธิภาพความแม่นยำในการทำนายของแบบจำลอง และเลือกใช้ฟังก์ชันการสูญเสียคือค่า MSE และค่า RMSE โดยค่า RMSE มีหน่วยเป็น (กิโลกรัม/ตารางเมตร) สำหรับการทำนายน้ำหนักมันสำปะหลัง และ (%) สำหรับการทำนายปริมาณแป้ง ประสิทธิภาพของแบบจำลองแสดงในภาคผนวก ซ.



บทที่ 4

การวิเคราะห์การถดถอยและสหสัมพันธ์ระหว่างดัชนีพืชพรรณ กับปริมาณผลผลิตมันสำปะหลัง

การศึกษานี้เป็นการหาค่าดัชนีพืชพรรณที่เหมาะสมที่สุดในการประเมินปริมาณผลผลิตมันสำปะหลังสด โดยการหาค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) ระหว่างค่าดัชนีพืชพรรณ ExG, GRVI และ NDVI กับปริมาณผลผลิต ได้แก่ น้ำหนักของหัวมันสำปะหลังสด และปริมาณแป้งในหัวมันสำปะหลังสด

การวิเคราะห์การถดถอยและสหสัมพันธ์ในการศึกษานี้จะทำให้สามารถเลือกค่าดัชนีพืชพรรณที่เหมาะสมต่อการประเมินปริมาณผลผลิตมันสำปะหลังด้วยแบบจำลองการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึกในการศึกษาในบทถัดไป

4.1 การวิเคราะห์สหสัมพันธ์

การหาความสัมพันธ์ระหว่างดัชนีพืชพรรณกับปริมาณผลผลิตมันสำปะหลัง เป็นขั้นตอนในการหาความสัมพันธ์ระหว่างตัวแปร (Correlate) เรียกว่า การวิเคราะห์สหสัมพันธ์ (Correlation) เป็นการศึกษาขนาดความสัมพันธ์เชิงเส้นระหว่างตัวแปรอิสระ (Independence variable หรือ X) กับตัวแปรเป้าหมายหรือตัวแปรตาม (Dependence variable หรือ Y)

การวิเคราะห์สหสัมพันธ์จะถูกวัดด้วยค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) หรือสหสัมพันธ์แบบเพียร์สัน (Pearson correlation) คิดค้นขึ้นโดย คาร์ล เพียร์สัน (Karl Pearson) ในคริสต์ศักราช 1900 ในชื่อ Product-moment coefficient of correlation หรือ Pearson correlation (Glass and Hopkins, 1984) สหสัมพันธ์แบบเพียร์สันเขียนแทนด้วย r โดยมีค่าอยู่ระหว่าง -1 ถึง 1 โดยหากค่า r มีค่าเข้าใกล้ 1 แสดงถึงตัวแปร Y สามารถประมาณค่าได้ใกล้เคียง X มาก หรือมีความสัมพันธ์ไปในทิศทางเดียวกัน เรียกว่า สหสัมพันธ์เชิงบวก (Positive correlation) ในทางกลับกันหาก r มีค่าเข้าใกล้ -1 แสดงถึงตัวแปร Y และ X มีความสัมพันธ์มากแต่มีทิศทางตรงกันข้าม เรียกว่า สหสัมพันธ์เชิงลบ (Negative correlation) หากค่า r มีค่าเป็น 0 แสดงว่าตัวแปรไม่มีความสัมพันธ์กัน (สุกมาส อังศุโชติ, ม.ป.ป.) สำหรับการคำนวณหาค่าสัมประสิทธิ์สหสัมพันธ์แสดงได้ดังสมการที่ 4.1

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (4.1)$$

กำหนดให้	r	คือ	ค่าสัมประสิทธิ์สหสัมพันธ์
	x_i	คือ	ค่าตัวแปร x ชุดข้อมูลที่ i
	$\bar{x}$	คือ	ค่าเฉลี่ยของตัวแปร x
	y_i	คือ	ค่าตัวแปร y ชุดข้อมูลที่ i
	$\bar{y}$	คือ	ค่าเฉลี่ยของตัวแปร y

การแปลความหมายว่าตัวแปรมีความสัมพันธ์กันมากน้อยเพียงใดต้องนำค่าสัมประสิทธิ์สหสัมพันธ์เทียบกับตารางการแปลความหมาย โดยได้มีการกำหนดช่วงของค่าสัมประสิทธิ์สหสัมพันธ์แสดงดังตารางที่ 4.1

ตารางที่ 4.1 การแปลความหมายค่าสัมประสิทธิ์สหสัมพันธ์

ค่าสัมประสิทธิ์สหสัมพันธ์	ระดับความสัมพันธ์
0.81 – 1.00	มีความสัมพันธ์กันมาก
0.51 – 0.80	มีความสัมพันธ์กันปานกลาง
0.21 – 0.50	มีความสัมพันธ์กันน้อย
0.01 – 0.20	มีความสัมพันธ์กันน้อยมาก
0.00	ไม่มีความสัมพันธ์กัน

หมายเหตุ จาก Best, 1977

4.2 การวิเคราะห์การถดถอย

การวิเคราะห์การถดถอยเป็นการศึกษาความสัมพันธ์ของตัวแปรในการศึกษาที่ได้จากการใช้ค่า X เพียงตัวเดียวในการประมาณค่า Y หรือความสัมพันธ์ระหว่างตัวแปร X และ Y เป็นเชิงเส้นตรงเรียกว่า การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression) โดยเป็นแบบจำลองทางคณิตศาสตร์ที่อาศัยความสัมพันธ์เชิงเส้น เกี่ยวกับการศึกษาตัวแปรอิสระที่ส่งอิทธิพลต่อตัวแปรตาม (ปิยะ นากสงค์, 2566: ผุสดี บุญรอด และกรวัฒน์ พลเยี่ยม, 2560) แสดงได้ดังสมการที่ 4.2

$$Y = \alpha + \beta X \quad (4.2)$$


กำหนดให้	Y	คือ	ตัวแปรตาม
	X	คือ	ตัวแปรอิสระ
	α	คือ	สัมประสิทธิ์การถดถอยซึ่งเป็นจุดตัดบนแกน Y
	β	คือ	สัมประสิทธิ์การถดถอยซึ่งเป็นความชันของเส้นตรง

แบบจำลองสมการถดถอยเชิงเส้นอย่างง่ายเป็นการหาสมการทางคณิตศาสตร์ที่ใช้อธิบายความสัมพันธ์ระหว่างตัวแปรต้น X และตัวแปรตาม Y โดยสร้างสมการเชิงเส้นตรงที่มีค่าสัมประสิทธิ์การถดถอยซึ่งเป็นความชันของเส้นตรง หรือ β และสัมประสิทธิ์การถดถอยซึ่งเป็นจุดตัดบนแกน Y หรือ α และเมื่อแทนค่าตัวแปรต้น ลงในแบบจำลองสมการถดถอยเชิงเส้นจะได้ค่าตัวแปรตามจากการทำนาย

การประเมินประสิทธิภาพของแบบจำลองสมการถดถอย จะใช้ค่าสัมประสิทธิ์การตัดสินใจ (R^2) เป็นการศึกษาความสัมพันธ์ระหว่างตัวแปรตามหรือข้อมูลเป้าหมาย กับตัวแปรตามจากการทำนาย โดยมีค่าระหว่าง 0 ถึง 1 หาก R^2 มีค่าเท่ากับ 1 หมายถึงแบบจำลองทำนายได้ตรงตามเป้าหมายทั้งหมด หากมีค่าเท่ากับ 0 หมายถึงแบบจำลองมีประสิทธิภาพเท่ากับการทำนายโดยใช้ค่าเฉลี่ยของข้อมูลทั้งหมด และหากมีค่าน้อยกว่า 0 หมายความว่าแบบจำลองทำนายผลได้แย่กว่าการใช้ค่าเฉลี่ยเป็นคำตอบ (กิตติสุชาติ พสุภา, 2564)

4.3 ผลและอภิปรายการศึกษา

การคำนวณค่าสัมประสิทธิ์สหสัมพันธ์ในการศึกษานี้ทำได้โดยการนำเข้าชุดข้อมูล ด้วยการเขียนโปรแกรมภาษาไพธอนบน Jupyter Notebook ด้วย Google Colaboratory โดยใช้ชุดคำสั่ง `seaborn.heatmap` ผลการคำนวณค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปรแต่ละชนิดแสดงได้ดังรูปที่ 4.1 เมื่อเปรียบเทียบค่าสัมประสิทธิ์สหสัมพันธ์ของปริมาณผลผลิตมันสำปะหลังเทียบกับดัชนีพืชพรรณแต่ละชนิด สามารถแสดงได้ดังตารางที่ 4.2



รูปที่ 4.1 ตารางค่าสหสัมพันธ์แสดงความสัมพันธ์ระหว่างดัชนีพืชพรรณ ExG, GRVI และ NDVI กับ น้ำหนักของหัวมันสำปะหลังสด (Yield_weight) และปริมาณแป้งในหัวมันสำปะหลังสด (Percent_strach)

ตารางที่ 4.2 เปรียบเทียบค่าสหสัมพันธ์ระหว่างดัชนีพืชพรรณ ExG, GRVI และ NDVI กับข้อมูล น้ำหนักหัวมันสำปะหลังสด และปริมาณแป้งในหัวมันสำปะหลังสด

ดัชนีพืชพรรณ	ExG	GRVI	NDVI
น้ำหนักหัวมันสำปะหลัง	0.76	0.64	0.89
ปริมาณแป้งในหัวมันสำปะหลัง	-0.51	-0.52	-0.21

จากตาราง 4.2 พบว่า เมื่อพิจารณาสหสัมพันธ์ระหว่างน้ำหนักหัวมันสำปะหลังสดกับดัชนีพืชพรรณ ดัชนี NDVI มีค่าสหสัมพันธ์เชิงบวกสูงที่สุดที่ค่า 0.89 โดยมีระดับความสัมพันธ์ที่มาก ขณะที่ ดัชนี ExG และ GRVI มีความสัมพันธ์กับน้ำหนักหัวมันสำปะหลังสดในระดับกลาง และเมื่อพิจารณาปริมาณแป้งในหัวมันสำปะหลังสดพบว่ามีค่าสหสัมพันธ์ในเชิงลบโดยดัชนี GRVI กับ ExG มีความสัมพันธ์กับปริมาณแป้งในหัวมันสำปะหลังสดในระดับกลาง และดัชนี NDVI มีความสัมพันธ์กับปริมาณแป้งในหัวมันสำปะหลังสดในระดับน้อย

แบบจำลองสมการถดถอยเชิงเส้นอย่างง่ายในการศึกษานี้ใช้การเขียนโปรแกรมภาษาไพธอนบน Jupyter Notebook ด้วย Google Colaboratory โดยใช้ชุดคำสั่ง sklearn.linear_model โดยกำหนดให้ตัวแปรต้นเป็นค่าดัชนีพืชพรรณทั้ง 3 ชนิด และตัวแปรตาม คือ ข้อมูลปริมาณผลผลิต 2 ชนิด โดยเป็นการศึกษาความสัมพันธ์ระหว่างตัวแปรต้น 1 ตัวกับตัวแปรตาม 1 ตัวได้ชุดความสัมพันธ์

6 ชุด ข้อมูลในการศึกษานี้จะถูกแบ่งออกเป็นข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ ในอัตราส่วนร้อยละ 80 ต่อ 20 ตามลำดับ

เมื่อได้สมการถดถอยจากข้อมูลชุดฝึกฝน นำข้อมูลจากการทำนายค่าน้ำหนักหัวมันสำปะหลัง และค่าปริมาณแป้งในหัวมันสำปะหลัง มาใช้ในการคำนวณหาค่า R^2 , MSE และ RMSE ผลการประเมินประสิทธิภาพของแบบจำลองสมการถดถอย ด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบแสดงได้ดังตารางที่ 4.3

ตารางที่ 4.3 ประสิทธิภาพของแบบจำลองสมการถดถอยเชิงเส้นอย่างง่ายกับดัชนีพืชพรรณ ExG, GRVI และ NDVI กับข้อมูลน้ำหนักหัวมันสำปะหลัง

ดัชนีพืชพรรณ	ชุดข้อมูล	R^2	MSE	RMSE (กก./ตร.ม.)
ExG	ชุดฝึกฝน	0.7978	0.2221	0.4713
	ชุดทดสอบ	0.6786	0.2570	0.5070
GRVI	ชุดฝึกฝน	0.7750	0.2236	0.4729
	ชุดทดสอบ	0.4784	0.4172	0.6459
NDVI	ชุดฝึกฝน	0.8527	0.1618	0.4023
	ชุดทดสอบ	0.8197	0.1442	0.3798

ผลการศึกษาดำเนินการด้วยข้อมูลชุดฝึกฝนดังตารางที่ 4.3 ให้ค่า R^2 ของแบบจำลองการคาดการณ์ปริมาณผลผลิตน้ำหนักด้วยดัชนี NDVI มากที่สุดที่ 0.8527 และได้ค่า R^2 ของแบบจำลองที่ใช้ดัชนี GRVI น้อยที่สุดที่ค่า 0.7750 ขณะที่แบบจำลองการคาดการณ์ปริมาณแป้งพบว่าดัชนี NDVI ให้ค่า R^2 มากที่สุดที่ 0.3859 และ GRVI น้อยที่สุดที่ 0.0287 โดยค่า R^2 ที่ได้จากการคำนวณด้วยข้อมูลปริมาณผลผลิตจริงเทียบกับปริมาณผลผลิตที่จากการทำนายด้วยแบบจำลองบ่งบอกถึงประสิทธิภาพในการทำนาย โดยหากมีค่าเข้าใกล้ 1 จะบ่งบอกถึงแบบจำลองมีประสิทธิภาพในการทำนายที่สูง และหากมีค่าเข้าใกล้ 0 หมายถึงแบบจำลองมีประสิทธิภาพในการทำนายต่ำ (กิตติสุชาติ พสุภา, 2564) สำหรับการประเมินความคลาดเคลื่อนของค่าที่ได้จากการทำนายด้วยแบบจำลองด้วย RMSE ตารางที่ 4.3 จะบ่งชี้ถึงค่าความผิดพลาดในการทำนายในหน่วยเดียวกันกับข้อมูลเป้าหมายที่ใช้ในการฝึกฝนแบบจำลอง โดยพบว่าการคาดการณ์ปริมาณผลผลิตน้ำหนักด้วยดัชนี NDVI มีค่า RMSE ต่ำที่สุดที่ 0.4023 กิโลกรัม/ตารางเมตร ขณะที่ดัชนี GRVI มีค่า RMSE สูงที่สุดที่ 0.4729 กิโลกรัม/ตารางเมตร

สำหรับการผลการฝึกฝนแบบจำลองด้วยข้อมูลชุดฝึกฝนการประเมินผลผลิตด้วยค่าดัชนี NDVI มีความแม่นยำสูงสุดเนื่องมาจากการคำนวณค่าการสะท้อนของแสงในช่วงคลื่น NIR และ Red โดย NIR จะบ่งบอกถึงความสมบูรณ์ของใบพืชโดยตรง (Tucker, 1979) ขณะที่ดัชนี GRVI และ ExG คำนวณจากการสะท้อนแสงในช่วงคลื่น RGB ที่ตามองเห็นได้ ซึ่งบ่งบอกได้ถึงความเร็วและความหนาแน่นของพืชเท่านั้น

ผลการศึกษาการประเมินน้ำหนักของหัวมันสำปะหลังสดภายในแปลงด้วยข้อมูลชุดทดสอบพบว่า ดัชนี NDVI ให้มีค่า R^2 สูงที่สุดที่ 0.8197 โดยมีความหมายว่าแบบจำลองสามารถทำนายค่าปริมาณผลผลิตได้ใกล้เคียงข้อมูลปริมาณผลผลิตจริงภายในแปลงสูงที่สุดที่ร้อยละ 81.97 ในขณะที่ค่าดัชนี GRVI ให้ค่า R^2 ต่ำที่สุดในการศึกษานี้คือ 0.4784 ทั้งนี้เนื่องจากค่าดัชนี NDVI มีการพิจารณาการสะท้อนแสงในช่วงคลื่น NIR ที่สามารถใช้ในการจำแนกพืชพรรณและวัตถุที่ปกคลุมดินจากคุณสมบัติค่าความแตกต่างการสะท้อนของช่วงคลื่น NIR กับช่วงคลื่นแสงสีแดง ในขณะที่ดัชนี ExG และ GRVI คำนวณจากการสะท้อนและดูดกลืนแสงในช่วงคลื่น RGB ซึ่งเป็นช่วงคลื่นแสงที่ตามองเห็นเท่านั้น สำหรับค่า RMSE ของแบบจำลองพบว่า NDVI มีค่าต่ำที่สุดกล่าวคือ มีความผิดพลาดในการทำนายน้ำหนักของผลผลิตอยู่ที่ 0.3798 กิโลกรัม/ตารางเมตร ในขณะที่ GRVI มีความผิดพลาดสูงที่สุดที่ 0.6459 กิโลกรัม/ตารางเมตร

การศึกษานี้บ่งชี้ว่าดัชนีพืชพรรณ NDVI มีความเหมาะสมในการประเมินน้ำหนักมันสำปะหลังสดด้วยภาพถ่ายจากอากาศยานไร้คนขับสูงที่สุด รองลงมาคือดัชนี ExG และ GRVI ตามลำดับ โดยการศึกษานี้ชี้ให้เห็นว่าดัชนีพืชพรรณมีความสอดคล้องกับปริมาณผลผลิตมันสำปะหลังด้วยอาศัยข้อมูลจากการถ่ายภาพด้วยภาพถ่ายทางอากาศ สอดคล้องกับงานวิจัยของวลัยพร ศะศิประภา และคณะ (2555) ที่มีการใช้ภาพถ่ายจากดาวเทียมไทยโชตที่มีความละเอียดจุดภาพ 15 เมตร ในการประเมินผลผลิตมันสำปะหลัง อย่างไรก็ตามการใช้ภาพถ่ายจากอากาศยานไร้คนขับที่มีความละเอียดจุดภาพสูงกว่าในหน่วย เซนติเมตร จะให้ความถูกต้องแม่นยำของแบบจำลองสูงกว่า โดยงานวิจัยของพงศ์ หลวงมูล และถาวร อ่อนประไพ (2564) ได้ใช้อากาศยานไร้คนขับในการคาดการณ์ปริมาณผลผลิตข้าวโดยใช้ดัชนีพืชพรรณ NDVI TGI และ GNDVI พบว่าค่าการทำนายปริมาณผลผลิตมีความใกล้เคียงกับผลผลิตจริง นอกจากนี้ยังมีงานวิจัยก่อนหน้านี้ที่ใช้ดัชนีพืชพรรณในการประมาณผลผลิตทางการเกษตรของพืชเศรษฐกิจในประเทศไทย อาทิ อ้อย (จิรวุฒน์ โนดไธสงค์ และคณะ, 2562; โพธิ์วุฒิ บุญเรืองและคณะ, 2565;) ข้าว (ปริญธร จุนถาวร, 2563; พรหมชัย สุพรรณ และคณะ, 2561) และมันสำปะหลัง (วลัยพร ศะศิประภา และคณะ, 2555) โดยหากพิจารณาเลือกใช้ดัชนีพืชพรรณจากภาพถ่ายด้วยกล้องที่เก็บข้อมูลในช่วงคลื่น RGB ดัชนี ExG มีความเหมาะสมกว่า GRVI ในด้านความแม่นยำ ดัชนี ExG ต้นทุนที่ต่ำกว่าดัชนี NDVI ที่เก็บข้อมูลด้วยกล้องถ่ายภาพหลายช่วงคลื่นที่ติดตั้งบน

อากาศยานไร้คนขับการประเมินผลผลิตทางการเกษตร (สิตาวิร์ ชีร์วิรุฬห์, 2559) อย่างไรก็ตามดัชนี ExG ยังมีข้อจำกัดที่ความแม่นยำของแบบจำลองเมื่อเทียบกับดัชนี NDVI

สำหรับผลการประเมินประสิทธิภาพของการทำนายด้วยแบบจำลองโดยใช้ข้อมูลค่าปริมาณแป้งในหัวมันสำปะหลังสดจริงและค่าปริมาณแป้งในหัวมันสำปะหลังสดจากการทำนาย ค่า R^2 MSE และ RMSE ของแบบจำลองด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบแสดงได้ดังตารางที่ 4.4

ตารางที่ 4.4 ประสิทธิภาพของแบบจำลองสมการถดถอยเชิงเส้นอย่างง่ายกับดัชนีพืชพรรณ ExG, GRVI และ NDVI กับข้อมูลปริมาณแป้งในหัวมันสำปะหลังสด

ดัชนีพืชพรรณ	ชุดข้อมูล	R^2	MSE	RMSE (%)
ExG	ชุดฝึกฝน	0.1319	5.0864	2.2553
	ชุดทดสอบ	0.3434	11.2399	3.3526
GRVI	ชุดฝึกฝน	0.0287	5.6911	2.3856
	ชุดทดสอบ	0.1021	15.3711	3.9206
NDVI	ชุดฝึกฝน	0.3859	3.5979	1.8968
	ชุดทดสอบ	0.3386	11.3219	3.3648

จากตารางที่ 4.4 การประเมินปริมาณแป้งในหัวมันสำปะหลังสดด้วยการใช้ค่าดัชนีพืชพรรณจากภาพถ่ายที่จากเซนเซอร์ที่ติดตั้งบนอากาศยานนิกบิน พบว่า ที่ข้อมูลชุดฝึกฝนดัชนี NDVI ให้ค่า RMSE ต่ำที่สุดที่ 1.8968% ขณะที่ดัชนี GRVI ให้ค่า RMSE สูงที่สุดที่ 2.3856% ทั้งนี้ เป็นการคาดการณ์ปริมาณแป้งเฉลี่ยต่อหนึ่งหน่วยพื้นที่ที่ทำการเก็บตัวอย่าง

ผลการศึกษาจากการใช้ข้อมูลชุดทดสอบพบว่า มีค่า R^2 ค่อนข้างต่ำโดยดัชนี ExG ให้ค่าสูงที่สุดเท่ากับ 0.3434 และมีค่า RMSE สูงถึง 3.3526% และใกล้เคียงกับดัชนีที่มีค่า R^2 เท่ากับ 0.3386 และค่า RMSE เท่ากับ 3.3648% ทั้งนี้เนื่องจากปริมาณแป้งในหัวมันสำปะหลังจะเปลี่ยนแปลงไปตามระยะการเจริญเติบโตของต้นสำปะหลัง อีกทั้งยังเปลี่ยนแปลงตามสภาพอากาศในพื้นที่ปลูก ฤดูกาลที่เริ่มปลูก รูปแบบการให้น้ำ และฤดูกาลเก็บเกี่ยว (A. Janket et al., 2020, K. Sriroth et al., 2001; V. Santisopasri et al., 2001) ดังนั้น การประมาณปริมาณแป้งในหัวมันสำปะหลังจึงไม่อาจทำการประมาณได้จากภาพถ่ายที่ได้จากเซนเซอร์บนอากาศยานไร้คนขับเท่านั้น จำเป็นต้องอาศัยข้อมูลที่เกี่ยวข้องกับการเพาะปลูก อาทิ พันธุ์ ฤดูกาลเพาะปลูก รูปแบบการให้น้ำ เป็นต้น

4.4 สรุปผลการศึกษา

การศึกษาการประเมินผลผลิตมันสำปะหลังโดยใช้ดัชนีพืชพรรณ NDVI, ExG และ GRVI ที่คำนวณจากภาพถ่ายที่ได้จากเซนเซอร์บนอากาศยานไร้คนขับและข้อมูลที่ได้จากการเก็บในแปลงตัวอย่าง โดยใช้แบบจำลองสมการถดถอยเชิงเส้นอย่างง่าย พบว่าการประเมินน้ำหนักของหัวมันสำปะหลังสดด้วยดัชนีพืชพรรณ NDVI ให้ค่า R^2 สูงที่สุด รองลงมาคือ ExG และ GRVI ตามลำดับ โดยดัชนี NDVI ให้ความผิดพลาดในการคาดการณ์ปริมาณผลผลิตเพียง 0.3798 กิโลกรัม/ตารางเมตร และมีความสัมพันธ์สูงที่สุดที่ 0.89 มีระดับความสัมพันธ์ในระดับมาก เนื่องจากคุณสมบัติของการดูดกลืนและสะท้อนแสงในช่วงคลื่นอินฟราเรดย่านใกล้และคลื่นแสงสีแดงของใบพืช และเมื่อพิจารณาการประเมินปริมาณแป้งในหัวมันสำปะหลังสดด้วยดัชนีพืชพรรณ NDVI, ExG และ GRVI พบว่าผลการประเมินมีความถูกต้องที่ค่อนข้างต่ำโดยที่ข้อมูลชุดทดสอบดัชนี ExG และดัชนี NDVI ให้ค่าความผิดพลาดต่ำที่สุดที่ 3.3526% และ 3.3648% ตามลำดับ โดยความสัมพันธ์ของดัชนี ExG มีความสัมพันธ์กับปริมาณแป้งในหัวมันสำปะหลังสดในระดับกลาง ขณะที่ดัชนี NDVI มีความสัมพันธ์กับปริมาณแป้งในหัวมันสำปะหลังสดในระดับน้อย เนื่องจากการเก็บข้อมูลภาพด้วยกล้องที่ติดตั้งบนอากาศยานแสดงถึงความอุดมสมบูรณ์ของพืชจากสมบัติการสะท้อนแสงของใบเท่านั้น ไม่ได้พิจารณาถึงสภาพของดินและสภาพอากาศภายในแปลง โดยหากต้องการความแม่นยำที่สูงขึ้นควรมีการศึกษาการใช้ข้อมูลภาพถ่ายจากอากาศยานไร้คนขับร่วมกับข้อมูลอื่นที่เกี่ยวข้องกับการเพาะปลูกด้วยจึงจะช่วยให้แบบจำลองมีความแม่นยำที่สูงขึ้น การศึกษาความสัมพันธ์ของดัชนีพืชพรรณกับปริมาณผลผลิตด้วยการวิเคราะห์การถดถอยและสหสัมพันธ์ในการศึกษานี้ ให้ข้อสรุปว่าดัชนี NDVI มีความเหมาะสมมากที่สุดในการประเมินผลผลิตมันสำปะหลัง เนื่องจากมีความสัมพันธ์ในระดับมาก และมีความแม่นยำสูงที่สุดเมื่อเทียบกับดัชนีพืชพรรณอื่นในภาพรวม การศึกษาต่อไปจึงเลือกใช้ค่าดัชนี NDVI ในการศึกษาหาวิธีการคาดการณ์ปริมาณผลผลิตด้วยแบบจำลองการเรียนรู้เชิงลึก

บทที่ 5

การสร้างแบบจำลองการทำนายน้ำหนักของหัวมันสำปะหลังสด ด้วยการเรียนรู้เชิงลึก

น้ำหนักของหัวมันสำปะหลังสดเป็นปัจจัยที่สำคัญอย่างยิ่งต่อภาพรวมของอุตสาหกรรมการผลิตและแปรรูปมันสำปะหลัง โดยข้อมูลน้ำหนักมันสำปะหลังถูกใช้ในการวางแผนการผลิตและการใช้ทรัพยากรในการผลิตให้เกิดประสิทธิภาพ อีกทั้งข้อมูลน้ำหนักมันสำปะหลังยังถูกใช้ในการคาดการณ์ปริมาณพืชผลทางการเกษตรของประเทศต่อหน่วยพื้นที่ในแต่ละช่วงเวลาเพื่อการวางแผนนโยบายของภาครัฐและภาคเอกชน การพัฒนาแบบจำลองในการทำนายปริมาณผลผลิตมันสำปะหลังในรายพื้นที่ที่จะช่วยในการวางแผนของเกษตรกร และภาคอุตสาหกรรมในระดับท้องถิ่น และสามารถขยายผลต่อไปได้ในระดับประเทศ

ในบทนี้เป็นการศึกษาการใช้วิธีการเรียนรู้เชิงลึกโดยใช้แบบจำลองโครงข่ายประสาทเทียมในการทำนายปริมาณน้ำหนักของหัวมันสำปะหลังสดภายในแปลงโดยใช้ค่าดัชนีพืชพรรณ NDVI แบบจำลองโครงข่ายประสาทเทียมในการศึกษานี้พัฒนาขึ้นด้วยการเขียนโปรแกรมภาษาไพธอนโดยใช้เครื่องมือ Integrated Development Environment หรือ IDE บน Jupyter Notebook ด้วยชุดคำสั่ง Keras บน TensorFlow และการใช้ซอฟต์แวร์ MATLAB® R2018a โดยใช้คำสั่ง Neural Network Toolbox

5.1 การสร้างแบบจำลองด้วยการเขียนโปรแกรมภาษาไพธอน

ในการศึกษานี้โครงข่ายประสาทเทียม (Artificial neural network: ANN) ถูกใช้เป็นแบบจำลองในการทำนายปริมาณน้ำหนักของหัวมันสำปะหลังสด โครงข่ายประสาทเทียมในการศึกษานี้จะมีการปรับจำนวนชั้นซ่อนระหว่าง 1 ถึง 10 ชั้น ในแต่ละชั้นจะมีจำนวนโหนดเท่ากัน โดยมีการปรับจำนวนโหนดเป็น 8, 16, 32 และ 64 โหนดตามลำดับ รอบการประมวลผลแบบจำลองสูงสุดที่ 1,500 Epochs และมีการประเมินผลแบบจำลองโดยใช้ค่า R^2 , MSE และ RMSE ตามลำดับ

การศึกษานี้เป็นการศึกษาผลของการปรับปรุงจำนวนชั้นซ่อนและจำนวนโหนดของโครงข่ายประสาทเทียมเพื่อหาแบบจำลองที่มีความเหมาะสมที่สุดในการประเมินน้ำหนักของหัวมันสำปะหลังสดภายในแปลงจากภาพถ่ายหลายช่วงคลื่นบนอากาศยานไร้คนขับ แบบจำลองที่มีความเหมาะสมที่สุดจะมีความแม่นยำสูงสุดและมีความผิดพลาดต่ำที่สุด กล่าวคือ มีค่า R^2 สูงที่สุด และมีค่า MSE และ RMSE ต่ำที่สุด

ในการหาแบบจำลองที่มีความเหมาะสมมากที่สุด จึงมีการกำหนดขอบเขตของเกณฑ์ในการประเมินประสิทธิภาพของแบบจำลองไว้คือค่า R^2 ควรมีค่ามากกว่า 0.80 ค่า MSE และ RMSE มีค่าไม่เกิน 0.01 และ 0.10 กิโลกรัม/ตารางเมตร ตามลำดับ

5.1.1 ผลการเปลี่ยนแปลงจำนวนโหนดของแบบจำลอง

การศึกษานี้เป็นการศึกษาผลของการเปลี่ยนแปลงจำนวนโหนดของแบบจำลองโครงข่ายประสาทเทียมแบบมีชั้นซ่อนเพียงชั้นเดียว เพื่อหาว่าจำนวนโหนดมีผลอย่างไรต่อค่าประสิทธิภาพในการทำนายของแบบจำลอง โดยประเมินจากค่า R^2 , MSE และ RMSE ผลการประเมินประสิทธิภาพของแบบจำลองที่รอบการประมวลผล 500 1,000 และ 1,500 Epochs ด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ แสดงได้ดังตารางที่ 5.1 และ ตารางที่ 5.2

ตารางที่ 5.1 ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลงจำนวนโหนดของแบบจำลองสำหรับทำนายน้ำหนักร่มน้ำป่าหลังด้วยข้อมูลชุดฝึกฝน

จำนวนโหนด	จำนวน Epoch	R^2	MSE	RMSE (กก./ตร.ม.)
8	500	0.5593	0.4590	0.6775
	1,000	0.7871	0.2217	0.4709
	1,500	0.8565	0.1495	0.3866
16	500	0.7403	0.2705	0.5201
	1,000	0.8425	0.1640	0.4050
	1,500	0.8609	0.1448	0.3806
32	500	0.8144	0.1933	0.4396
	1,000	0.8587	0.1472	0.3836
	1,500	0.8590	0.1469	0.3833
64	500	0.8445	0.1620	0.4024
	1,000	0.8616	0.1442	0.3797
	1,500	0.8614	0.1444	0.3800

จากตารางที่ 5.1 พบว่าที่รอบการประมวลผล 500 Epochs ประสิทธิภาพของแบบจำลองที่มีจำนวนโหนดต่างกันมีความแตกต่างกันอย่างชัดเจน แบบจำลองที่มีประสิทธิภาพต่ำสุดคือที่ 8 โหนดมีค่า RMSE เท่ากับ 0.6775 กิโลกรัม/ตารางเมตร มีค่า R^2 เท่ากับ 0.5593 ขณะที่ประสิทธิภาพสูงที่สุดที่ 64 โหนด มีค่า RMSE เท่ากับ 0.4024 กิโลกรัม/ตารางเมตร มีค่า R^2 เท่ากับ


0.8445 กล่าวคือ เมื่อมีจำนวนโหนดมากขึ้นแบบจำลองจะมีประสิทธิภาพที่ดียิ่งขึ้นคือ มีค่า R^2 สูงขึ้น มีค่า MSE และ RMSE ต่ำลง อาจกล่าวได้ว่าที่รอบการประมวลผลต่ำแบบจำลองที่มีความซับซ้อนมาก จะมีประสิทธิภาพที่ดีกว่าแบบจำลองที่มีความซับซ้อนต่ำ โดยแบบจำลองมีโหนดน้อยกว่าจะทำให้มีจำนวนหน่วยประมวลผลน้อยกว่า (เจรอน, 2566) อย่างไรก็ตามเมื่อเพิ่มรอบการประมวลผลที่ 1,000 และ 1,500 Epochs พบว่า แบบจำลองมีประสิทธิภาพใกล้เคียงกันโดยที่ 1,500 Epochs แบบจำลอง มีค่า RMSE อยู่ระหว่าง 0.3800 – 0.3866 กิโลกรัม/ตารางเมตร และมีค่า R^2 อยู่ระหว่าง 0.8565 – 0.8614

ตารางที่ 5.2 ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลงจำนวนโหนดของแบบจำลองสำหรับทำนายน้ำหนักรากไม้สำหรับป่าหลังจากข้อมูลชุดทดสอบ

จำนวนโหนด	จำนวน Epoch	R^2	MSE	RMSE (กก./ตร.ม.)
8	500	0.4120	0.5896	0.7678
	1,000	0.5986	0.4024	0.6344
	1,500	0.7213	0.2794	0.5286
16	500	0.5415	0.4597	0.6780
	1,000	0.6833	0.3175	0.5635
	1,500	0.7326	0.2681	0.5178
32	500	0.6376	0.3634	0.6028
	1,000	0.7301	0.2707	0.5202
	1,500	0.7323	0.2684	0.5181
64	500	0.6894	0.3115	0.5581
	1,000	0.7330	0.2677	0.5174
	1,500	0.7348	0.2659	0.5157

จากตารางที่ 5.2 แสดงค่าฟังก์ชันความสูญเสีย MSE RMSE และค่า R^2 ของแบบจำลองที่มีการเพิ่มจำนวนโหนดของข้อมูลชุดทดสอบ ผลการประเมินประสิทธิภาพบ่งชี้ว่าการเพิ่มจำนวนโหนด จะทำให้ฟังก์ชันความสูญเสียมีค่าลดลง ขณะที่ค่า R^2 มีแนวโน้มเพิ่มขึ้น และการเพิ่มจำนวนรอบการประมวลผลส่งผลให้ประสิทธิภาพของแบบจำลองสูงขึ้น โดยผลการประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมที่มี 64 โหนดที่รอบการประมวลผล 1,500 Epochs มีประสิทธิภาพของแบบจำลองสูงที่สุด โดยมีค่า R^2 , MSE และ RMSE เท่ากับ 0.7348

0.2659 และ 0.5157 กิโลกรัม/ตารางเมตร ตามลำดับ อย่างไรก็ตามเมื่อเปรียบเทียบกับตารางที่ 5.1 ค่าฟังก์ชันความสูญเสียของการประเมินด้วยข้อมูลชุดทดสอบมีค่ามากกว่าชุดฝึกฝนและมีค่า R^2 ต่ำกว่าข้อมูลชุดฝึกฝน การศึกษานี้ชี้ให้เห็นว่าแบบจำลองยังไม่เหมาะสมกับชุดข้อมูลมากนัก หรือแบบจำลองนี้มีความเหมาะสมกับข้อมูลต่ำเกินไป การเพิ่มจำนวนชั้นซ่อนอาจช่วยให้แบบจำลองมีความซับซ้อนเหมาะสมกับชุดข้อมูลมากขึ้นได้ (เจรอน, 2566)



รูปที่ 5.1 Loss curve ของแบบจำลองที่มีจำนวน 64 โหนด

รูปที่ 5.1 แสดงค่าฟังก์ชันความสูญเสีย MSE ของแบบจำลอง โดยแสดงค่า MSE ของข้อมูลชุดฝึกฝน (mean_squared_error) และข้อมูลชุดทดสอบ (val_mean_squared_error) ที่จำนวนรอบการประมวลผลสูงที่สุดที่ 1,500 Epochs จากรูปจะพบว่าเกิดความเหมาะสมกับข้อมูลต่ำเกินไป โดยค่า MSE ของข้อมูลชุดฝึกฝนมีค่าต่ำกว่าข้อมูลชุดทดสอบ อีกทั้งกราฟยังมีแนวโน้มที่ลดลงไปอีก


5.1.2 ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง

โดยทั่วไปโครงข่ายประสาทเทียมถูกใช้ในการศึกษาที่มีความสัมพันธ์แบบเชิงเส้น เนื่องจากแบบจำลองไม่มีความซับซ้อนมากนัก ข้อมูลที่มีลักษณะไม่เป็นเชิงเส้นตรงจึงอาจมีความจำเป็นต้องใช้แบบจำลองที่มีความซับซ้อนมากยิ่งขึ้นเพื่อให้ได้ผลการทำนายที่มีความถูกต้องสูง แบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้น (MLP) เป็นแบบจำลองการเรียนรู้เชิงลึกที่ใช้ในการแก้ปัญหาการทำนาย และการจำแนกที่มีความซับซ้อนมากได้


การปรับปรุงจำนวนชั้นซ่อนของแบบจำลองจะทำให้แบบจำลองมีความซับซ้อนเหมาะสมกับปัญหา โดยการปรับปรุงเพิ่มลดจำนวนของชั้นซ่อน จะมีผลต่อจำนวนของหน่วย

ประมวลผลหรือโหนด อย่างไรก็ตามแบบจำลองที่มีจำนวนชั้นซ่อนมากหรือมีความซับซ้อนมากก็อาจส่งผลให้แบบจำลองนั้นมีความเหมาะสมกับข้อมูลมากเกินไป กล่าวคือแบบจำลองนั้นมีความผิดพลาดต่ำเมื่อประเมินจากข้อมูลชุดฝึกฝนแต่อาจทำงานได้ไม่ดีนักในข้อมูลชุดอื่น ๆ (กอบเกียรติ สระอุบล, 2565; กิตีสุชาติ พสุภา, 2564; เจริณ, 2566)

การศึกษานี้เป็นการศึกษาผลของการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้น เพื่อหาจำนวนชั้นซ่อนที่เหมาะสมต่อการประเมินผลผลิตน้ำหนักของหัวมันสำปะหลังสดที่มีการกำหนดจำนวนโหนดจากการศึกษาก่อนหน้าที่ 64 โหนด และประมวลผลที่รอบการประมวลผล 1,500 Epochs ค่าประสิทธิภาพในการทำนายของแบบจำลองประเมินด้วยค่า MSE และ R^2 แสดงดังรูปที่ 5.2 และ 5.3




รูปที่ 5.2 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า MSE



รูปที่ 5.3 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ้อนต่อค่า R^2

ผลการศึกษาจากรูปที่ 5.2 พบว่าที่ข้อมูลชุดฝึกฝนแบบจำลองมีแนวโน้มของค่า MSE ลดต่ำลง ตามจำนวนชั้นซ้อนที่เพิ่มขึ้น ขณะที่ข้อมูลชุดทดสอบว่ามีแนวโน้มที่ค่า MSE จะเพิ่มขึ้น เมื่อจำนวนชั้นซ้อนเพิ่มขึ้น และจากรูปที่ 5.3 ค่า R^2 ของแบบจำลองชุดฝึกฝนมีแนวโน้มเพิ่มขึ้น เล็กน้อยในช่วง 0.86 – 0.89 ขณะที่ในชุดทดสอบค่า R^2 ของแบบจำลองมีแนวโน้มลดลง โดยหากพิจารณาแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่มีประสิทธิภาพสูงที่สุดสำหรับการศึกษานี้ พบว่าเป็นแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่มีจำนวนชั้นซ้อน 6 ชั้นซ้อน โดยมีค่า R^2 และ MSE เท่ากับ 0.7809 และ 0.2440 ตามลำดับที่ข้อมูลชุดทดสอบ



รูปที่ 5.4 Loss curve ของแบบจำลองที่มี 6 ชั้นซ่อน


การศึกษานี้จะเห็นได้ว่าแนวโน้มของค่า R^2 ของแบบจำลองที่ข้อมูลชุดฝึกฝนมีแนวโน้มเพิ่มขึ้น ขณะที่แนวโน้มของค่า R^2 ของแบบจำลองมีค่าลดลง และเมื่อพิจารณาที่ค่าฟังก์ชันความสูญเสียของแบบจำลองข้อมูลชุดฝึกฝนจะมีแนวโน้มลดลง ขณะที่ข้อมูลชุดทดสอบมีแนวโน้มลดลงก่อนที่จะเพิ่มขึ้นเมื่อถึงจุดหนึ่ง (รูปที่ 5.4) สิ่งนี้เป็นการอธิบายถึงการที่แบบจำลองมีความเหมาะสมกับชุดข้อมูลมากเกินไป ซึ่งทำให้แบบจำลองสามารถทำงานทำนายผลได้ดีบนข้อมูลชุดฝึกฝน แต่ทำนายผลได้ผิดพลาดมากในข้อมูลชุดทดสอบ การเพิ่มประสิทธิภาพของแบบจำลองสามารถทำได้โดยใช้เทคนิคการเรกัลไรเซชัน

5.1.3 ผลการเพิ่มประสิทธิภาพของแบบจำลอง


การศึกษาก่อนหน้าพบว่ายิ่งฝึกฝนแบบจำลองมากขึ้นแบบจำลองจะมีความซับซ้อนมากขึ้น ส่งผลให้ความผิดพลาดในการประเมินประสิทธิภาพของข้อมูลชุดฝึกฝนหรือความผิดพลาดในเชิงประจักษ์น้อยลงแปรผันไปตามความซับซ้อนของแบบจำลอง และความผิดพลาดจากการประเมินด้วยข้อมูลชุดทดสอบหรือความผิดพลาดจริงก็จะลดลงเช่นกัน จนกระทั่งเมื่อถึงระยะหนึ่งความผิดพลาดจริงจะเพิ่มขึ้นตามความซับซ้อนของแบบจำลอง แต่ความผิดพลาดในเชิงประจักษ์ยังคงลดลงอย่างต่อเนื่อง หมายความว่าแบบจำลองนั้นมีความซับซ้อนมากเกินไป เนื่องมาจากมีความเหมาะสมกับข้อมูลมากเกินไป จึงได้มีการปรับปรุงประสิทธิภาพของแบบจำลองด้วยเทคนิคการวิเคราะห์สัญญาณตกหาย

จากตารางที่ 3.7 ได้มีการกำหนดร้อยละของการวิเคราะห์สัญญาณตกหายที่ร้อยละ 20 โดยได้มีการกำหนดให้ใช้เทคนิคนี้ที่ชั้นซ่อนสุดท้ายของโครงข่ายประสาทเทียมแบบหลายชั้น

ผลการปรับปรุงแบบจำลองด้วยเทคนิคการเรีกกิรวาไรซ์เซชันด้วยการวิเคราะห์สัญญาณตกหาย แสดงได้ดังรูปที่ 5.5




รูปที่ 5.5 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า MSE



รูปที่ 5.6 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า R^2

ผลการศึกษาจากรูปที่ 5.5 พบว่าที่แบบจำลองโครงข่ายประสาทเทียมมีค่า MSE ของข้อมูลชุดฝึกฝนอยู่ในช่วง 0.12 – 0.15 โดยมีค่า MSE ต่ำสุดที่ 0.1211 โครงข่ายประสาทเทียมที่มี 7 ชั้นซ่อน และที่แบบจำลองที่มีการเปลี่ยนแปลงชั้นซ่อนนั้นมีค่า MSE เปลี่ยนแปลงไม่มากนัก ขณะที่ข้อมูลชุดทดสอบพบว่าค่า MSE มีแนวโน้มลดลง และจากรูปที่ 5.6 การเปรียบเทียบค่า R^2 ของแบบจำลองข้อมูลชุดฝึกฝนมีค่ามากกว่าค่า R^2 ของข้อมูลชุดทดสอบ โดยผลการศึกษาพบว่าแบบจำลองโครงข่ายประสาทเทียมที่มีจำนวนชั้นซ่อน 7 ชั้นซ่อนมีค่า R^2 มากที่สุดเมื่อพิจารณาจากข้อมูลชุดทดสอบ Loss curve ภายหลังการปรับปรุงประสิทธิภาพของแบบจำลองแสดงดังรูปที่ 5.7



รูปที่ 5.7 Loss curve ของแบบจำลองที่มี 7 ชั้นซ่อนที่มีการวิเคราะห์สัญญาณตกหาย

5.1.4 สรุปผลการศึกษา

การศึกษการพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่มีการใช้เทคนิคการวิเคราะห์สัญญาณตกหายนี้ แบบจำลองที่มีจำนวนชั้นซ่อน 7 ชั้นซ่อนมีความเหมาะสมมากที่สุดในการทำนายน้ำหนักของมันเป็นผลมาจากการเขียนโปรแกรมภาษาไพธอน โดยเมื่อเปรียบเทียบแบบจำลองก่อนและหลังการใช้เทคนิคการวิเคราะห์สัญญาณตกหายดังตารางที่ 5.3 ในข้อมูลชุดทดสอบแบบจำลองที่ไม่ใช้เทคนิคนี้มีค่า R^2 สูงกว่าภายหลังการใช้เทคนิคที่ค่า 0.7809 และ 0.7535 ตามลำดับ เนื่องจากการปิดการทำงานของโหนดการประมวลผลลงทำให้การเรียนรู้ของแบบจำลองเกิดขึ้นน้อยลง ขณะที่ค่าฟังก์ชันการสูญเสีย MSE ของแบบจำลองที่มีการใช้เทคนิคการวิเคราะห์สัญญาณตกหามีค่า MSE ต่ำกว่าที่ค่า 0.1932 ขณะที่ก่อนใช้มีค่า MSE เท่ากับ 0.2440 เนื่องจากการลดการเกิดความเหมาะสมกับข้อมูลมากเกินไปจากการใช้เทคนิคดังกล่าว

ตารางที่ 5.3 ผลการเปรียบเทียบค่า R^2 MSE และ RMSE ของแบบจำลองสำหรับทำนายน้ำหนักมันสำปะหลังก่อนและหลังการวิเคราะห์สัญญาณตกหาย

Regularization	ชุดข้อมูล	R^2	MSE	RMSE (กก./ตร.ม.)
ไม่มี	ชุดฝึกฝน	0.8809	0.1308	0.3617
	ชุดทดสอบ	0.7809	0.2440	0.4940
	ชุดฝึกฝน	0.8611	0.1211	0.3480
	ชุดทดสอบ	0.7535	0.1932	0.4395

ผลการศึกษาชี้ให้เห็นแนวทางในการพัฒนาแบบจำลองสำหรับการทำนายน้ำหนักของมันสำปะหลังภายในแปลงด้วยการใช้ชุดคำสั่ง Scikit-Learn ในการเขียนโปรแกรมภาษาไพธอน โดยมีการปรับจำนวนโหนด และจำนวนชั้นซ่อนของโครงข่ายประสาทเทียมแบบหลายชั้น และลดปัญหาความเหมาะสมกับข้อมูลมากเกินไปด้วยเทคนิคการวิเคราะห์สัญญาณตกหาย โดยหาประเมินความผิดพลาดต่ำที่สุดที่อาจเกิดขึ้นจากการทำนายโดยใช้แบบจำลองในเชิงพื้นที่จะพบว่ามีค่าเท่ากับ 0.3480 กิโลกรัม/ตารางเมตร สำหรับข้อมูลชุดฝึกฝน และ 0.4395 กิโลกรัม/ตารางเมตร สำหรับข้อมูลชุดทดสอบ

5.2 การสร้างแบบจำลองโดยใช้ซอฟต์แวร์ MATLAB

ซอฟต์แวร์ MATLAB ® R2018a เป็นเครื่องมือหนึ่งที่สามารถใช้ในการพัฒนาแบบจำลองปัญญาประดิษฐ์ได้ โดยเครื่องมือ Neural Network Toolbox ถูกใช้อย่างแพร่หลายในการสร้างแบบจำลองโครงข่ายประสาทเทียม และโครงข่ายประสาทเทียมเชิงลึก

การศึกษานี้ใช้ข้อมูลดัชนีพืชพรรณ NDVI เป็นข้อมูลนำเข้า (Input data) และใช้ข้อมูลน้ำหนักของต้นไม้ป่าหลังเป็นข้อมูลส่งออก (Output data) โดยการศึกษานี้มีการกำหนดอัลกอริทึมที่ใช้ในการประมวลผล 3 ชนิด ได้แก่ SCG, LM และ BR เพื่อหาแบบจำลองที่มีความเหมาะสมกับการทำนายปริมาณน้ำหนักมากที่สุดจึงมีการปรับปรุงจำนวนชั้นซ่อนของแบบจำลองระหว่าง 1 ถึง 10 ชั้นซ่อน และประเมินประสิทธิภาพของแบบจำลองด้วยค่า R^2 และค่าฟังก์ชันความสูญเสีย ได้แก่ MSE และ RMSE เพื่อหาแบบจำลองที่มีความเหมาะสมมากที่สุด

5.2.1 ผลการเปลี่ยนแปลงชนิดอัลกอริทึมของแบบจำลอง

การศึกษานี้เป็นการประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมที่มีเพียง 1 ชั้นซ่อน เพื่อหาว่าการเปลี่ยนแปลงชนิดของอัลกอริทึมในการประมวลผลส่งผลอย่างไรต่อประสิทธิภาพของแบบจำลอง โดยผลการศึกษานี้จะคำนึงถึงความเร็วในการประมวลผลจากจำนวนรอบการวนซ้ำต่อการประมวลผลในหนึ่งรอบ (Iterations) ความแม่นยำในการประมวลผลโดยใช้สัมประสิทธิ์แสดงการตัดสินใจ (R^2) และค่าฟังก์ชันความสูญเสีย ได้แก่ MSE และ RMSE ผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนแสดงได้ดังตารางที่ 5.4

ตารางที่ 5.4 การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูลชุดฝึกฝน

อัลกอริทึม	จำนวน Iterations	R^2	MSE	RMSE (กก./ตร.ม.)
SCG	125	0.7326	0.01524	0.1235
LM	9	0.6761	0.01493	0.1222
BR	24	0.7769	0.01519	0.1232

จากตารางที่ 5.4 แสดงจำนวนรอบในการวนซ้ำสำหรับประมวลผลที่ทำให้แบบจำลองมีประสิทธิภาพสูงสุด โดยหากพิจารณาที่ความเร็วในการประมวลผล LM ให้ประสิทธิภาพสูงสุดเพียง 9 Iterations ขณะที่ SCG มีจำนวน 125 Iterations หากพิจารณาที่ค่าการประเมินประสิทธิภาพของแบบจำลองการทำนาย ค่า R^2 MSE และ RMSE พบว่า BR ให้ค่า R^2 สูงที่สุดที่ 0.7769 ให้ค่า MSE และ RMSE เท่ากับ 0.01519 และ 0.1232 กิโลกรัม/ตารางเมตร

ตามลำดับ ขณะที่ LM ให้ค่า R^2 ต่ำที่สุดที่ 0.6761 และยังให้ค่า MSE และ RMSE ต่ำที่สุดเท่ากับ 0.01493 และ 0.1222 กิโลกรัม/ตารางเมตร ตามลำดับ

ผลการศึกษาข้างต้นเป็นการศึกษาที่ข้อมูลชุดฝึกฝนกล่าวคือทั้ง 3 อัลกอริทึมมีจำนวนข้อมูลเท่ากันที่ร้อยละ 80 อย่างไรก็ตามมีความจำเป็นต้องพิจารณาประสิทธิภาพของแบบจำลองด้วยว่าสามารถทำงานได้ดีหรือไม่ในข้อมูลชุดอื่น ได้แก่ ข้อมูลชุดตรวจสอบ และข้อมูลชุดทดสอบ โดยแบบจำลองที่ใช้อัลกอริทึมต่างกันจะทำการแบ่งชุดข้อมูลที่ไม่เท่ากันโดยสำหรับอัลกอริทึม LM และ SCG ใช้การแบ่งที่ข้อมูลชุดฝึกฝนข้อมูล ชุดทดสอบ และข้อมูลชุดตรวจสอบ 80 ต่อ 10 ต่อ 10 ขณะที่ BR ไม่มีการแบ่งข้อมูลชุดตรวจสอบ จึงมีการแบ่งข้อมูลออกเป็นชุดฝึกฝนและชุดทดสอบ ในอัตราส่วน 80 ต่อ 20 การประเมินประสิทธิภาพของแบบจำลองแสดงได้ดังตารางที่ 5.5


ตารางที่ 5.5 การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมในแต่ละชุดข้อมูล

ชุดข้อมูล	อัลกอริทึม	R^2	MSE	RMSE (กก./ตร.ม.)
ชุดฝึกฝน	SCG	0.7919	0.01235	0.1111
	LM	0.7940	0.01245	0.1116
	BR	0.7788	0.01290	0.1136
ชุดทดสอบ	SCG	0.7326	0.01524	0.1235
	LM	0.6761	0.01493	0.1222
	BR	0.7769	0.01519	0.1232
ชุดตรวจสอบ	SCG	0.7664	0.01434	0.1197
	LM	0.7674	0.01278	0.1130


ตารางที่ 5.5 เมื่อพิจารณาที่ข้อมูลชุดทดสอบพบว่า แบบจำลองที่ใช้อัลกอริทึม BR ให้ค่า R^2 สูงสุดที่ 0.7769 ตามมาด้วย SCG ให้ค่า R^2 เท่ากับ 0.7326 ขณะที่ LM ให้ค่า MSE ต่ำที่สุดเท่ากับ 0.01493 และเมื่อพิจารณาที่ข้อมูลชุดฝึกฝน LM ให้ค่า R^2 สูงที่สุดเท่ากับ 0.7940 และ MSE เท่ากับ 0.01245 เมื่อพิจารณาผลการประเมินประสิทธิภาพของแบบจำลองพบว่ายังให้ค่าความแม่นยำไม่สูงมากนัก การเพิ่มความซับซ้อนของแบบจำลองโดยการเพิ่มจำนวนชั้นซ่อนเพื่อหาแบบจำลองที่มีความเหมาะสมในการใช้งานมากที่สุด (Kaul, Hill, and Walthall, 2005; V. Phunpeng, K. Saensuriwong, K. Thongchart and P. Uangpairoj, 2022) จึงถูกนำไปพิจารณาในหัวข้อถัดไป

5.2.2 ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง

การศึกษาในส่วนนี้เป็นการประเมินประสิทธิภาพของแบบจำลองที่มีการปรับปรุงจำนวนชั้นซ่อนระหว่าง 1 ถึง 10 ชั้นซ่อน ผลการประเมินประสิทธิภาพของแบบจำลองหลังการปรับปรุงจำนวนชั้นซ่อนของแบบจำลองด้วยข้อมูลชุดฝึกฝนแสดงได้ดังรูปที่ 5.8 และ 5.9




รูปที่ 5.8 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า MSE




รูปที่ 5.9 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า R^2

จากรูปที่ 5.8 แบบจำลองที่มีค่า MSE ต่ำหมายถึงแบบจำลองนั้นมีความผิดพลาดในการทำนายน้อย ผลการปรับปรุงจำนวนชั้นซ้อนพบว่าแบบจำลองที่ใช้อัลกอริทึม LM ที่ 8 ชั้นซ้อนให้ค่า MSE ต่ำสุด ขณะที่อัลกอริทึม BR และ SCG ให้ค่า MSE ต่ำสุดที่ 7 ชั้นซ้อน และจากรูปที่ 5.9 แบบจำลองที่มีค่า R^2 สูงหมายความว่าแบบจำลองนั้นมีความแม่นยำในการทำนายผลสูงด้วย โดยแบบจำลองในการทำนายผลโดยใช้อัลกอริทึมทั้ง 3 ชนิดนี้ที่ 6 ชั้นซ้อนขึ้นไปมีค่า R^2 มากกว่า 0.80 และ MSE น้อยกว่า 0.01 อย่างไรก็ตามจำเป็นต้องมีการประเมินผลด้วยข้อมูลชุดทดสอบด้วย ผลการประเมินประสิทธิภาพของแบบจำลองหลังการปรับปรุงจำนวนชั้นซ้อนของแบบจำลองด้วยข้อมูลชุดทดสอบแสดงได้ดังรูปที่ 5.10 และ 5.11



รูปที่ 5.10 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า MSE



รูปที่ 5.11 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า R^2

จากรูปที่ 5.10 และ 5.11 เมื่อประเมินประสิทธิภาพด้วยข้อมูลชุดทดสอบ ค่า MSE ของแบบจำลองทุกแบบจำลองมีค่าต่ำสุดที่ 7 ชั้นซ่อน และพบว่าค่า R^2 ของแบบจำลองมีแนวโน้มเพิ่มสูงขึ้นโดยมีค่ามากกว่า 0.80 ที่ 7 ชั้นซ่อน โดยอัลกอริทึม BR ให้ค่า R^2 สูงที่สุดที่ 9 ชั้นซ่อน ตามมาด้วย SCG และ LM ตามลำดับ ผลการศึกษานี้ชี้ให้เห็นว่าเพื่อให้ได้แบบจำลองที่เหมาะสมที่สุดต่อการใช้ในการทำนายน้ำหนักมันสำปะหลังด้วยแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้น แบบจำลองที่ใช้จำนวนชั้นซ่อนที่ 7 ชั้นซ่อนมีความเหมาะสมมากที่สุด

หากพิจารณาจากความแม่นยำของแบบจำลองด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ อาจไม่เพียงพอต่อการตัดสินใจเลือกแบบจำลองที่มีความเหมาะสมมากที่สุด โดยอาจต้องพิจารณาจากชุดข้อมูลทั้งหมดด้วย (All data) (กรณามิตร แสนสุริวงศ์, 2565) แสดงในตารางที่ 5.6 พบว่าแบบจำลองที่ใช้อัลกอริทึม LM ให้ค่า MSE และ RMSE ต่ำที่สุดเท่ากับ 0.0098 และ 0.0990 กิโลกรัม/ตารางเมตร ตามลำดับ และยังให้ค่า R^2 สูงที่สุดที่ 0.8241 โดยพบว่า แบบจำลองนี้มีความเหมาะสมตามเกณฑ์การประเมินที่ถูกตั้งไว้ข้างต้น ทั้งนี้ อาจเนื่องมาจากการที่อัลกอริทึม LM มีการทำการแพร่ย้อนกลับ (Backpropagation) ซึ่งมีความแตกต่างจากอัลกอริทึมอื่น


อาจกล่าวได้ว่าแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่มีจำนวนชั้นซ่อน 7 ชั้นประมวลผลด้วยอัลกอริทึม LM มีความเหมาะสมมากที่สุดในการทำนายน้ำหนักของมันสำปะหลังจากชุดข้อมูลที่น่าสนใจ

ตารางที่ 5.6 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบกับข้อมูลทั้งหมด


ชุดข้อมูล	อัลกอริทึม	R^2	MSE	RMSE (กก./ตร.ม.)
ชุดทดสอบ	SCG	0.8093	0.01034	0.1017
	LM	0.8040	0.01048	0.1024
	BR	0.8098	0.01021	0.1010
ข้อมูลทั้งหมด	SCG	0.8008	0.0112	0.1058
	LM	0.8241	0.0098	0.0990
	BR	0.8150	0.0106	0.1030

หากพิจารณาจากผลการประมวลผลบนซอฟต์แวร์ MATLAB รูปที่ 5.12 แสดงการลู่เข้าสู่ 0 ของค่าฟังก์ชันความสูญเสียของแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่มีจำนวนชั้นซ่อน 7 ชั้นประมวลผลด้วยอัลกอริทึม LM โดยการลู่เข้าสู่ 0 บ่งบอกถึงแบบจำลองมีความผิดพลาด

ในการทำนายที่ลดลง สำหรับรูปที่ 5.13 แสดงถึงความผิดพลาด (Error) ที่เป็นผลต่างระหว่างค่าจริง (Target) และค่าจากการทำนาย (Output) ของแบบจำลองตามจำนวนข้อมูล (Instance).




รูปที่ 5.12 ค่า MSE ของแบบจำลองที่ใช้อัลกอริทึม LM



รูปที่ 5.13 ความต่างระหว่างค่าข้อมูลจริงและค่าจากการทำนายของแบบจำลอง

การประมวลผลด้วยซอฟต์แวร์ MATLAB เป็นการศึกษาโดยใช้สมการถดถอยร่วมกับอัลกอริทึมในการประมวลผล โดยจะให้ผลของค่า R^2 การแต่ละชุดข้อมูลและสมการถดถอยเชิงเส้นในการทำนายผลของแบบจำลอง โดยในรูปที่ 5.14 แสดงพล็อตการฝึกฝนของแบบจำลอง (Fit Regression) ด้วยข้อมูลชุดต่าง ๆ และข้อมูลทั้งหมด (All) จุดวงกลมคือจุดของข้อมูลตัวอย่าง เส้น Fit คือเส้นที่ได้จากสมการของแบบจำลองหลังการฝึกฝน และเส้น $Y=T$ คือ เส้นที่ผ่านจุดของข้อมูลมากที่สุด โดยหากเส้น Fit ใกล้กับเส้น $Y=T$ มากจะทำให้มีความผิดพลาดในการทำนายผลที่ต่ำ




รูปที่ 5.14 การถดถอยของแบบจำลองในข้อมูลชุดต่าง ๆ

5.3 ผลการทำนายน้ำหนักมันสำปะหลังจากแบบจำลอง

การศึกษาการใช้ซอฟต์แวร์ MATLAB ในการทำนายน้ำหนักของมันสำปะหลังนี้เป็นการหาแบบจำลองที่มีความเหมาะสมที่สุดในการทำนายผลน้ำหนักจากค่าดัชนีพืชพรรณ โดยหลังจากได้ฝึกฝนแบบจำลองและประเมินประสิทธิภาพของแบบจำลองทั้งหมดพบว่าแบบจำลองที่มีชั้นซ่อนจำนวน 7 ชั้นซ่อนมีความเหมาะสมที่สุดในการประเมินน้ำหนักมันสำปะหลังโดยมีค่า R^2 สูงกว่า 0.8 และมีค่า MSE ต่ำกว่า 0.01 โดยค่าดังกล่าวถูกกำหนดขึ้นเป็นตัวชี้วัดของแบบจำลองที่มีความเหมาะสมในการประเมินผลผลิตในการศึกษา

การเปรียบเทียบเทียบค่าน้ำหนักของมันสำปะหลังจากการเก็บในแปลงตัวอย่างกับค่าน้ำหนักจากการทำนายด้วยแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นซ่อนที่มี 7 ชั้นซ่อนของ 3 อัลกอริทึมแสดงในรูปที่ 5.15



รูปที่ 5.15 การเปรียบเทียบค่าน้ำหนักของหัวมันสำปะหลังสดจากข้อมูลจริงภายในแปลงกับข้อมูลจากการทำนายโดยใช้อัลกอริทึม SCG LM และ BR

5.4 สรุปผลการวิจัย

การศึกษาในบทนี้เป็นการศึกษาการใช้ค่าดัชนีพืชพรรณ NDVI ในการทำนายค่าน้ำหนักของหัวมันสำปะหลังสดภายในแปลง (กิโลกรัม/ตารางเมตร) โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่พัฒนาขึ้นจากการเขียนโปรแกรมภาษาไพธอนด้วยชุดคำสั่ง TensorFlow และ Kears และการใช้เครื่องมือ Neural Network Toolbox บนซอฟต์แวร์ MATLAB ® R2018a การประเมินประสิทธิภาพของแบบจำลองด้วยความแม่นยำคือค่า R^2 ใช้ค่าฟังก์ชันความสูญเสียคือ MSE อีกทั้งได้มีการคำนวณหาค่า RMSE เพื่อแปลงออกมาเป็นค่าความคลาดเคลื่อนในหน่วยเดียวกันกับข้อมูลตัวอย่าง (กิโลกรัม/ตารางเมตร) ชุดข้อมูลในการศึกษาถูกแบ่งออกเป็นข้อมูลชุดฝึกฝน ข้อมูลชุดทดสอบ และข้อมูลชุดตรวจสอบ โดยจะพิจารณาจากแนวโน้มของข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ

ในการพิจารณาความเหมาะสมของแบบจำลองจะพิจารณาจากค่า MSE และ R^2 โดยกำหนดขอบเขตที่ค่า MSE ไม่สูงกว่า 0.01 หรือมีความคลาดเคลื่อนในหน่วยพื้นที่ RMSE เท่ากับ 0.1 กิโลกรัม/ตารางเมตร และมีค่า R^2 ไม่ต่ำกว่า 0.80 จากขอบเขตดังกล่าวแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่มีจำนวนชั้นซ่อน 7 ชั้นประมวลผลด้วยอัลกอริทึม Levenberg-Marquardt (LM) ที่ใช้ซอฟต์แวร์ MATLAB มีความเหมาะสมมากที่สุดในการทำนายปริมาณน้ำหนักของหัวมันสำปะหลังสดภายในแปลงด้วยความคลาดเคลื่อน 0.0990 กิโลกรัม/ตารางเมตร ขณะที่แบบจำลองที่พัฒนาขึ้นจากการเขียนโปรแกรมภาษาไพธอนยังมีค่าฟังก์ชันความสูญเสียสูงกว่าขอบเขตที่กำหนดเท่ากับ 0.4395 กิโลกรัม/ตารางเมตร

จากผลการศึกษาหากต้องการพัฒนาแบบจำลองให้มีความแม่นยำสูงขึ้น จำเป็นต้องใช้ชุดข้อมูลปริมาณมากขึ้นในการฝึกฝนแบบจำลอง อีกทั้งอาจจำเป็นต้องใช้พื้นที่ศึกษาที่หลากหลาย และมีตัวอย่างที่หลากหลายมากขึ้นแบบจำลองจึงจะสามารถใช้งานได้ดีในทุกพื้นที่เพาะปลูก อีกทั้งการศึกษานี้เป็นการใช้เพียงค่าดัชนีพืชพรรณในการศึกษาเพียงอย่างเดียว ข้อมูลที่เกี่ยวข้องภายในแปลงเช่นปริมาณธาตุอาหารในดินในพื้นที่เพาะปลูก การวัดความชื้นในแต่ละช่วงเวลาก็อาจมีส่วนช่วยในการเพิ่มความแม่นยำของแบบจำลอง แต่เนื่องจากการเก็บข้อมูลมีต้นทุนสูง การใช้ดัชนีพืชพรรณโดยการเก็บภาพถ่ายจากอากาศยานไร้คนขับจึงเป็นแนวทางที่สะดวกและใช้ต้นทุนไม่สูงนัก อีกทั้งหากมีการพัฒนาแบบจำลองที่มีประสิทธิภาพสูงในข้อมูลชุดต่าง ๆ จะเป็นแนวทางที่ดีในการพัฒนาภาคการเกษตรของประเทศไทยได้ต่อไป

บทที่ 6

การสร้างแบบจำลองการทำนายปริมาณแฉ่งในหัวมันสำปะหลังสด

ปริมาณแฉ่งภายในหัวมันสำปะหลังสดเป็นตัวแปรหนึ่งที่มีความสำคัญอย่างมากในการซื้อขายมันสำปะหลังสด โดยค่าร้อยละของปริมาณแฉ่งในมันสำปะหลังสดจากการสุ่มตัวอย่างวัดด้วยเครื่องวัดปริมาณแฉ่ง จะถูกนำไปใช้ราคาในการซื้อขายที่จุดรับซื้อหน้าโรงงาน อีกทั้งปริมาณแฉ่งยังเป็นตัวแปรสำคัญในการคาดการณ์การผลิตแฉ่งมันสำปะหลังของโรงงานอุตสาหกรรม การพัฒนาแบบจำลองเพื่อทำนายปริมาณแฉ่งจึงมีความสำคัญอย่างมากต่อภาคการเกษตร และภาคอุตสาหกรรม

ในบทที่ 5 เป็นการศึกษาการใช้โครงข่ายประสาทเทียมในการทำนายน้ำหนักของหัวมันสำปะหลังสดภายในแปลงต่อหน่วยพื้นที่ ในบทนี้จะเป็นการศึกษาการใช้วิธีการเรียนรู้เชิงลึกโดยใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับการทำนายปริมาณแฉ่งภายในหัวมันสำปะหลังสดภายในแปลงโดยใช้ค่าดัชนีพืชพรรณ NDVI แบบจำลองสำหรับการทำนายพัฒนาขึ้นด้วยการเขียนโปรแกรมภาษาไพธอน และการใช้ซอฟต์แวร์ MATLAB® R2018a เช่นเดียวกับการศึกษาที่ผ่านมา

6.1 ผลการสร้างแบบจำลองด้วยการเขียนโปรแกรมภาษาไพธอน

ในการศึกษาการวิเคราะห์การถดถอยและสหสัมพันธ์ระหว่างดัชนีพืชพรรณกับปริมาณแฉ่งในหัวมันสำปะหลังสดในบทที่ 4 ผลการวิเคราะห์ค่าสหสัมพันธ์ไม่ได้อยู่ในระดับสูง เนื่องจากการวิเคราะห์ค่าสหสัมพันธ์เป็นการศึกษาแนวโน้มในแนวเส้นตรงเท่านั้น การศึกษานี้จึงใช้แบบจำลองการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมเพื่อศึกษาความเป็นไปได้ในการทำนายปริมาณแฉ่งภายในหัวมันสำปะหลังสด

แบบจำลองในการศึกษานี้ถูกพัฒนาขึ้นเช่นเดียวกับแบบจำลองในบทที่ 5 โดยเป็นแบบจำลองโครงข่ายประสาทเทียมที่มีการปรับจำนวนชั้นซ่อนระหว่าง 1 ถึง 10 ชั้น ในแต่ละชั้นจะมีจำนวนโหนดเท่ากัน โดยมีการปรับจำนวนโหนดเป็น 8, 16, 32 และ 64 โหนดตามลำดับ การประมวลผลแบบจำลองมีรอบการประมวลผลสูงสุดที่ 1,500 Epochs และมีการประเมินผลแบบจำลองโดยใช้ค่า R^2 , MSE และ RMSE ตามลำดับ โดยค่า RMSE มีหน่วยเป็น %

6.1.1 ผลการเปลี่ยนแปลงจำนวนโหนดของแบบจำลอง

การศึกษานี้เป็นการศึกษาผลของการเปลี่ยนแปลงจำนวนโหนดของแบบจำลองโครงข่ายประสาทเทียมแบบมีชั้นซ่อนเพียงชั้นเดียว เพื่อหาว่าจำนวนโหนดมีผลอย่างไรต่อค่าประสิทธิภาพในการทำนายของแบบจำลอง โดยประเมินจากค่า R^2 , MSE และ RMSE ผลการประเมินประสิทธิภาพของแบบจำลองที่รอบการประมวลผล 500 1,000 และ 1,500 Epochs ด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ แสดงได้ดังตารางที่ 6.1 และ ตารางที่ 6.2

ตารางที่ 6.1 ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลงจำนวนโหนดของแบบจำลองสำหรับทำนายปริมาณน้ำด้วยข้อมูลชุดฝึกฝน

จำนวนโหนด	จำนวน Epochs	R^2	MSE	RMSE (%)
8	500	0.4008	4.9497	2.2248
	1,000	0.4098	5.1809	2.2762
	1,500	0.4090	5.0317	2.2431
16	500	0.4008	4.9615	2.2274
	1,000	0.4070	5.2209	2.2849
	1,500	0.4041	5.2320	2.2874
32	500	0.4014	5.0773	2.2533
	1,000	0.4050	4.8720	2.2073
	1,500	0.4097	5.2084	2.2822
64	500	0.4033	4.9272	2.2197
	1,000	0.4026	5.1435	2.2679
	1,500	0.4106	5.1514	2.2697

ตารางที่ 6.2 ผลการศึกษาค่าดัชนี NDVI กับค่า R^2 MSE และ RMSE กับการเปลี่ยนแปลงจำนวน โหนดของแบบจำลองสำหรับทำนายปริมาณแบ่งด้วยข้อมูลชุดทดสอบ

จำนวนโหนด	จำนวน Epochs	R^2	MSE	RMSE (%)
8	500	0.3510	8.9323	2.9887
	1,000	0.3517	8.2306	2.8689
	1,500	0.3415	8.5769	2.9286
16	500	0.3534	8.7688	2.9612
	1,000	0.3416	8.7942	2.9655
	1,500	0.3615	6.3979	2.5294
32	500	0.3618	8.7360	2.9557
	1,000	0.3473	7.0308	2.6516
	1,500	0.3615	7.8318	2.7985
64	500	0.3681	7.7134	2.7773
	1,000	0.3457	7.1823	2.6800
	1,500	0.3457	7.1823	2.6800

จากตารางที่ 6.1 พบว่าการเพิ่มจำนวนโหนด และจำนวนรอบการประมวลผลส่งผลโดยตรงต่อประสิทธิภาพของแบบจำลองโดยแบบจำลองที่มี 64 โหนด ประมวลผลที่ 1,500 Epochs มีประสิทธิภาพสูงสุดที่มีค่า R^2 เท่ากับ 0.4106 โดยค่า R^2 มีแนวโน้มเพิ่มขึ้นตามความซับซ้อนของแบบจำลอง ขณะที่ค่าฟังก์ชันความสูญเสียของแบบจำลองมีค่าใกล้เคียงกัน และจากตารางที่ 6.2 พบว่าประสิทธิภาพของแบบจำลองโดยรวมมีค่าใกล้เคียงกันโดยมีค่า R^2 ไม่เกิน 0.37 และมีค่า RMSE อยู่ในช่วง 2.60 – 3.00 % ซึ่งให้เห็นว่าแบบจำลองนี้ยังมีความผิดพลาดสูงในการทำนายปริมาณแบ่งในหัวมันสำปะหลังสด

ผลการศึกษาข้างต้นพบว่าจำนวนโหนดและจำนวนรอบการประมวลผลของแบบจำลองด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบมีประสิทธิภาพที่ใกล้เคียงกัน โดยข้อมูลชุดฝึกฝนมีประสิทธิภาพสูงกว่าข้อมูลชุดทดสอบ โดยเมื่อพิจารณาประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมในการศึกษานี้มีความแม่นยำค่อนข้างต่ำและมีฟังก์ชันความสูญเสียสูง อาจเนื่องมาจากแบบจำลองยังมีความซับซ้อนที่ไม่เหมาะสมเพียงพอต่อชุดข้อมูลที่ใช้ในการศึกษา หรือแบบจำลองนี้มีความเหมาะสมกับข้อมูลต่ำเกินไป


เพื่อแก้ปัญหาความเหมาะสมกับข้อมูลต่ำเกินไป การเพิ่มจำนวนชั้นซ่อนของแบบจำลองโดยการเพิ่มจำนวนชั้นซ่อน อาจทำให้แบบจำลองมีความเหมาะสมกับชุดข้อมูลที่มีความสัมพันธ์แบบไม่เชิงเส้นได้ (กอบเกียรติ สระอุบล, 2565; เจริญ, 2566) การศึกษาในหัวข้อนี้เป็นหาแบบจำลองที่มีจำนวนโหนดและจำนวนรอบการประมวลผลสูงที่สุดกับชุดข้อมูล หัวข้อถัดไปเป็นการใช้แบบจำลองที่มีการกำหนดจำนวนโหนดที่ 64 โหนด และมีจำนวนรอบประมวลผลที่ 1,500 Epochs จากการศึกษา

6.1.2 ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง


การแก้ไขปัญหาความเหมาะสมกับข้อมูลต่ำเกินไปของแบบจำลองทำได้โดยการเพิ่มความซับซ้อนของแบบจำลอง ในการศึกษาจะเป็นการเพิ่มจำนวนชั้นซ่อนภายในโครงสร้างของโครงข่ายประสาทเทียมเพื่อหาว่าโครงสร้างของแบบจำลองที่มีความซับซ้อนเท่าใดมีความเหมาะสมมากที่สุดในการทำนายปริมาณแป้งในหัวมันสำปะหลังสด

การศึกษานี้เป็นการศึกษาผลของการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นระหว่าง 1-10 ชั้นซ่อน เพื่อหาจำนวนชั้นซ่อนที่เหมาะสมต่อการทำนายปริมาณแป้งภายในหัวมันสำปะหลังสดที่มีการกำหนดจำนวนโหนดจากการศึกษาก่อนหน้าคือ 64 โหนดในแต่ละชั้นซ่อน โดยประเมินประสิทธิภาพในการทำนายของแบบจำลองด้วยค่า R^2 และ MSE โดยผลการประเมินประสิทธิภาพของแบบจำลองที่รอบการประมวลผล 1,500 Epochs แสดงได้ดังรูปที่ 6.1 และ 6.2





รูปที่ 6.1 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า MSE



รูปที่ 6.2 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า R^2


จากรูปที่ 6.1 ค่า MSE ของแบบจำลองที่ข้อมูลชุดฝึกฝนมีแนวโน้มลดลงตามความซับซ้อนของแบบจำลองโดยแบบจำลองที่มีความซับซ้อนมากหรือมีจำนวนชั้นซ่อนมากจะส่งผลให้ค่า MSE มีค่าลดลง ขณะที่ข้อมูลชุดทดสอบพบว่าค่า MSE ของแบบจำลองมีแนวโน้มลดลงที่ 1 – 3 ชั้นซ่อนแรกก่อนที่จะเพิ่มขึ้นที่ชั้นซ่อนที่ 4 เป็นต้นไป และที่รูปที่ 6.2 ค่า R^2 ของแบบจำลองมีแนวโน้มเพิ่มขึ้นที่ข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ จากแนวโน้มพบว่าการฝึกฝนแบบจำลองที่ข้อมูลชุดฝึกฝนแบบจำลองยังมีความซับซ้อนมากจะทำให้มีความแม่นยำมากหรือมีค่า R^2 มากขึ้น และมีค่าความผิดพลาดในการทำนาย MSE น้อยลง ขณะเดียวกันที่ข้อมูลชุดทดสอบค่า R^2 จะเพิ่มขึ้นแต่ค่าความผิดพลาดอาจเพิ่มขึ้นตามไปด้วยส่งผลให้ค่า MSE มีค่าสูงขึ้น การที่แบบจำลองสามารถทำงานได้ที่ข้อมูลชุดฝึกฝนแต่มีความผิดพลาดมากในข้อมูลชุดทดสอบบ่งบอกถึงการเกิดความเหมาะสมกับข้อมูลมากเกินไป

6.1.3 ผลการเพิ่มประสิทธิภาพของแบบจำลอง


ในบทที่ 5 การแก้ปัญหาแบบจำลองมีความเหมาะสมกับข้อมูลชุดฝึกฝนมากเกินไปสามารถทำได้โดยการทำการเร็กกิวไรซ์เซชัน (ณัฐโชติ พรหมฤทธิ์ และสัจจาภรณ์ ไวจรรยา, 2564) โดยในงานวิจัยนี้เลือกใช้เทคนิคการวิเคราะห์สัญญาณตกหายที่ร้อยละ 20 การศึกษาในส่วนนี้เป็นการศึกษาเพื่อหาจำนวนชั้นซ่อนที่เหมาะสมที่สุดในการทำนายปริมาณแบ่งในหัวมันสำปะหลังจากแบบจำลองโครงข่ายประสาทเทียมแบบหลายใช้ที่มีการใช้เทคนิคการวิเคราะห์สัญญาณตกหาย ผลการวิเคราะห์แสดงได้ดังรูปที่ 6.3 สำหรับการประเมินด้วยค่า MSE และรูปที่ 6.4 สำหรับการประเมินด้วยค่า R^2

จากรูปที่ 6.3 ความสัมพันธ์ระหว่างค่า MSE กับจำนวนชั้นซ่อนของแบบจำลองพบว่าหากแบบจำลองมีความซับซ้อนมากขึ้นค่า MSE จะมีค่าลดลงด้วย และจากรูปที่ 6.4 ความสัมพันธ์ระหว่างค่า R^2 กับจำนวนชั้นซ่อนเป็นไปในทางเดียวกันคือ ยิ่งจำนวนชั้นซ่อนมากค่า R^2 จะยิ่งมีค่ามากขึ้นไปด้วย

จากขอบเขตการกำหนดโครงสร้างของแบบจำลองในการศึกษานี้แบบจำลองโครงข่ายประสาทเทียมที่มีจำนวนชั้นซ่อน 10 ชั้นซ่อนมีประสิทธิภาพในการทำนายสูงสุด โดยมีค่า R^2 เท่ากับ 0.4415 และ 0.3613 และมีค่า MSE เท่ากับ 2.6909 และ 4.0405 สำหรับข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบตามลำดับ



รูปที่ 6.3 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ้อนต่อค่า MSE



รูปที่ 6.4 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ้อนต่อค่า R^2

6.1.4 สรุปผลการศึกษา

การพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นด้วยการเขียนโปรแกรมภาษาไพธอนในการศึกษานี้ แบบจำลองที่มีจำนวนชั้นซ่อน 10 ชั้นซ่อน มีความเหมาะสมมากที่สุดในการใช้ในการทำนายปริมาณแป้งภายในหัวมันสำปะหลังสดสำหรับการศึกษานี้ จากผลการศึกษาและเปรียบเทียบก่อนและภายหลังจากการใช้เทคนิคการวิเคราะห์สัญญาณตกหายแสดงดังตารางที่ 6.3 พบว่าที่ข้อมูลชุดฝึกฝนแบบจำลองมีความแม่นยำที่ 0.4911 และ 0.3613 ก่อนและหลังการปรับปรุงประสิทธิภาพตามลำดับ โดยสามารถแสดงค่าความผิดพลาดในการทำนายได้เท่ากับ 2.9833% และ 2.0101% ตามลำดับ ผลการศึกษานี้แสดงให้เห็นว่าแบบจำลองยังมีความแม่นยำที่ไม่เพียงพอต่อการทำนายปริมาณแป้งในหัวมันสำปะหลังสดจึงควรที่จะมีการปรับปรุงแบบจำลองโดยใช้แบบจำลองอื่นที่ใช้เทคนิคต่างกันออกไป

ตารางที่ 6.3 ผลการเปรียบเทียบค่า R^2 MSE และ RMSE ของแบบจำลองสำหรับทำนายปริมาณแป้ง ก่อนและหลังการวิเคราะห์สัญญาณตกหาย

Regularization	ชุดข้อมูล	R^2	MSE	RMSE (%)
ไม่มี	ชุดฝึกฝน	0.4852	3.3740	1.8368
	ชุดทดสอบ	0.4911	8.9000	2.9833
	ชุดฝึกฝน	0.4415	2.6909	1.6404
	ชุดทดสอบ	0.3613	4.0405	2.0101

6.2 การสร้างแบบจำลองโดยใช้ซอฟต์แวร์ MATLAB

การศึกษานี้ใช้ข้อมูลดัชนีพืชพรรณ NDVI เป็นข้อมูลนำเข้า และใช้ข้อมูลปริมาณแป้งในมันสำปะหลังเป็นข้อมูลส่งออก โดยการศึกษานี้มีการกำหนดอัลกอริทึมที่ใช้ในการประมวลผล 3 ชนิด ได้แก่ SCG, LM และ BR เพื่อหาแบบจำลองที่มีความเหมาะสมกับการทำนายปริมาณแป้งมากที่สุดจึงมีการปรับปรุงจำนวนชั้นซ่อนของแบบจำลองระหว่าง 1 ถึง 10 ชั้นซ่อน และประเมินด้วยค่า R^2 และค่าฟังก์ชันความสูญเสียได้แก่ MSE และ RMSE เพื่อหาแบบจำลองที่มีความเหมาะสมมากที่สุด

6.2.1 ผลการเปลี่ยนแปลงชนิดอัลกอริทึมของแบบจำลอง

เช่นเดียวกับการศึกษาในบทก่อนหน้าการศึกษานี้เป็นการประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมที่มี 1 ชั้นซ่อน เพื่อหาว่าการเปลี่ยนแปลงชนิดของอัลกอริทึมในการประมวลผลส่งผลอย่างไรต่อประสิทธิภาพของแบบจำลอง ความถูกต้องแม่นยำในการประมวลผล

โดยใช้ค่า R^2 และค่าฟังก์ชันความสูญเสีย ได้แก่ MSE และ RMSE ผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนแสดงได้ดังตารางที่ 6.4

ตารางที่ 6.4 การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูลชุดฝึกฝน

อัลกอริทึม	จำนวน Iterations	R^2	MSE	RMSE (%)
Levenberg-Marquardt (LM)	10	0.6939	1.5354	1.2391
Scaled conjugate gradient (SCG)	26	0.6856	1.6633	1.2897
Bayesian regularization (BR)	31	0.6834	1.4772	1.2154

จากตารางที่ 6.4 แสดงจำนวนรอบในการวนซ้ำสำหรับประมวลผลที่ทำให้แบบจำลองมีประสิทธิภาพสูงสุด เมื่อพิจารณาที่ความเร็วในการประมวลผล LM มีประสิทธิภาพสูงสุดที่ 10 Iterations ขณะที่ BR มีจำนวนรอบการวนซ้ำมากที่สุดที่ 31 Iterations เมื่อพิจารณาค่า R^2 ของแบบจำลองที่ข้อมูลชุดฝึกฝนแบบจำลองที่ใช้อัลกอริทึม LM มีค่า R^2 สูงสุดที่ 0.6939 มีค่า MSE เท่ากับ 1.5345 และมีค่า RMSE เท่ากับ 1.2391% ตามลำดับ

การพิจารณาประสิทธิภาพของแบบจำลองจำเป็นต้องมีการพิจารณาที่ข้อมูลชุดทดสอบด้วย เพื่อให้มั่นใจว่าแบบจำลองสามารถทำงานได้ดีบนข้อมูลชุดที่ไม่เคยใช้ในการฝึกฝนมาก่อนหรือไม่ ตารางที่ 6.5 แสดงผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝน ชุดตรวจสอบ และชุดทดสอบ

ตารางที่ 6.5 การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมในแต่ละชุดข้อมูล


ชุดข้อมูล	อัลกอริทึม	R^2	MSE	RMSE (%)
ชุดฝึกฝน	SCG	0.6856	1.6633	1.2897
	LM	0.6939	1.5354	1.2391
	BR	0.6834	1.4772	1.2154
ชุดทดสอบ	SCG	0.5998	1.9694	1.4033
	LM	0.5068	2.7743	1.6656
	BR	0.6069	2.6801	1.6371
ชุดตรวจสอบ	SCG	0.6298	1.0395	1.0195
	LM	0.7048	0.9224	0.9604

จากตารางที่ 6.5 พบว่าที่ข้อมูลชุดตรวจสอบ แบบจำลองที่ใช้อัลกอริทึม LM มีค่า R^2 สูงที่สุดที่ 0.7048 และมีค่ามากกว่า SCG ขณะที่ค่า MSE ของแบบจำลองพบว่า SCG มีค่าสูงกว่าเล็กน้อยที่ 1.0395 ขณะที่ข้อมูลชุดทดสอบแบบจำลองที่ใช้อัลกอริทึม LM มีประสิทธิภาพต่ำที่สุดโดยมีค่า R^2 เท่ากับ 0.5068 และ MSE สูงที่สุดที่ 2.7743 ขณะที่อัลกอริทึม BR ให้ประสิทธิภาพสูงที่สุดที่ R^2 เท่ากับ 0.6069 และ MSE เท่ากับ 2.6801 อย่างไรก็ตามผลการศึกษานี้แบบจำลองมีความแม่นยำไม่สูงนัก และมีค่าความผิดพลาดค่อนข้างสูงเมื่อพิจารณาจากขอบเขตในการศึกษา การปรับปรุงแบบจำลองให้มีประสิทธิภาพสูงขึ้นอาจทำได้โดยการเพิ่มความซับซ้อนให้แก่แบบจำลอง การศึกษาต่อไปเป็นการศึกษาประสิทธิภาพของแบบจำลองที่มีการปรับจำนวนชั้นซ่อนระหว่าง 1-10 ชั้นซ่อน


6.2.2 ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง

เช่นเดียวกับการศึกษาก่อนหน้าเรื่องการปรับปรุงจำนวนชั้นซ่อนเพื่อเพิ่มประสิทธิภาพของแบบจำลองการศึกษาในส่วนนี้จึงเป็นการประเมินประสิทธิภาพของแบบจำลองที่มีการปรับปรุงจำนวนชั้นซ่อนระหว่าง 1 ถึง 10 ชั้นซ่อน ผลการประเมินประสิทธิภาพของแบบจำลองหลังการปรับปรุงจำนวนชั้นซ่อนของแบบจำลองด้วยข้อมูลชุดฝึกฝนแสดงได้ดังรูปที่ 6.5 และรูปที่ 6.6 สำหรับข้อมูลชุดทดสอบแสดงได้ดังรูปที่ 6.7 และรูปที่ 6.8


สำหรับข้อมูลชุดฝึกฝนแบบจำลองที่ใช้อัลกอริทึม LM มีแนวโน้มของค่า MSE ต่ำกว่าอัลกอริทึม BR และ SCG โดยแบบจำลองอัลกอริทึม LM ที่มีจำนวนชั้นซ่อนจำนวน 8 ชั้นซ่อนมีค่า MSE ต่ำที่สุดแสดงดังรูปที่ 6.5 สำหรับค่า R^2 ของแบบจำลองพบว่าอัลกอริทึม LM มีแนวโน้มที่มีค่า R^2 สูงกว่าอัลกอริทึมอื่นโดยมีค่าสูงที่สุดที่ 7 ชั้นซ่อนแสดงดังรูปที่ 6.6 สำหรับข้อมูลชุดทดสอบอัลกอริทึม LM ยังคงมีประสิทธิภาพสูงกว่าอัลกอริทึมอื่นโดยมีแนวโน้มที่ค่า MSE จะลดลงเมื่อจำนวนชั้นซ่อนมากขึ้นดังรูปที่ 6.7 และมีค่า R^2 เพิ่มขึ้นเมื่อเพิ่มจำนวนชั้นซ่อนดังรูปที่ 6.8 อย่างไรก็ตามแบบจำลองยังมีค่าประสิทธิภาพใกล้เคียงกันมากในบางชั้นซ่อนจึงทำให้ไม่อาจตัดสินได้ว่าแบบจำลองที่มีโครงสร้างแบบใดมีความเหมาะสมที่สุด การพิจารณาจากชุดข้อมูลทั้งหมดจึงเป็นหนึ่งในแนวทางการประเมินประสิทธิภาพของแบบจำลองโดยภาพรวมรูปที่ 6.9 แสดงผลการประเมินความแม่นยำของแบบจำลอง (R^2) ที่ชุดข้อมูลทั้งหมด




รูปที่ 6.5 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า MSE




รูปที่ 6.6 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า R^2



รูปที่ 6.7 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า MSE



รูปที่ 6.8 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า R^2



รูปที่ 6.9 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลทั้งหมดด้วยค่า R^2


จากรูปที่ 6.9 พบว่าแบบจำลองที่มีจำนวนชั้นซ่อนที่ 10 ชั้นซ่อนโดยภาพรวมมีแนวโน้มที่ให้ค่า R^2 สูงสุด โดยอัลกอริทึม BR ให้ค่า R^2 มากที่สุดที่ 0.7242 ใกล้เคียงกับอัลกอริทึม LM ที่ 0.7217 ทั้งนี้หากพิจารณาการเพิ่มขึ้นของจำนวนชั้นซ่อนจะพบว่ายิงแบบจำลองมีความซับซ้อนมาก ความแม่นยำของแบบจำลองจะยิ่งเพิ่มขึ้นมาก แต่อย่างไรก็ตามหากพิจารณาการขอบเขตการศึกษาแบบจำลองนี้ยังมีความแม่นยำที่ค่อนข้างต่ำและมีความผิดพลาดในการทำนายผลค่อนข้างสูง โดย R^2 มีค่าต่ำกว่า 0.80 และ MSE มีค่าสูงกว่า 0.01 ตารางที่ 6.6 แสดงผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบเทียบกับข้อมูลทั้งหมดที่ 10 ชั้นซ่อน

ตารางที่ 6.6 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบกับข้อมูลทั้งหมด


ชุดข้อมูล	อัลกอริทึม	R^2	MSE	RMSE (%)
ชุดทดสอบ	SCG	0.7885	0.8847	0.9406
	LM	0.6066	2.1783	1.4759
	BR	0.7594	1.2335	1.1106
ข้อมูลทั้งหมด	SCG	0.6970	1.5123	1.2298
	LM	0.7217	1.4642	1.2100
	BR	0.7242	1.3101	1.1446

การผลการศึกษาในตารางที่ 6.6 ที่สุดเมื่อพิจารณาจากการใช้ข้อมูลชุดทดสอบแบบจำลองที่ใช้อัลกอริทึม SCG มีประสิทธิภาพสูงที่สุด กล่าวคือมีค่า R^2 สูงที่สุดเท่ากับ 0.7885 มีค่า MSE ต่ำสุดที่ข้อมูลทั้งหมดเท่ากับ 0.8847 และมีค่า RMSE ต่ำที่สุดที่ 0.9406% ในขณะที่อัลกอริทึม BR มีประสิทธิภาพดีที่สุดเมื่อพิจารณาจากการใช้ข้อมูลทั้งหมดโดยมีค่า R^2 สูงที่สุดที่ข้อมูลทั้งหมดเท่ากับ 0.7242 มีค่า MSE ต่ำสุดที่ข้อมูลทั้งหมดเท่ากับ 1.3101 และมีค่า RMSE ต่ำที่สุดที่ 1.1446% ในรูปที่ 6.10 รูปที่ 6.11 และรูปที่ 6.12 แสดงค่า MSE ค่า Error และ Fit regression ระหว่างการฝึกฝนแบบจำลองอัลกอริทึม BR ตามลำดับ






รูปที่ 6.10 ค่า MSE ของแบบจำลองที่ใช้อัลกอริทึม BR




รูปที่ 6.11 ความต่างระหว่างค่าข้อมูลจริงและค่าจากการทำนายของแบบจำลอง



รูปที่ 6.12 การถดถอยของแบบจำลองในข้อมูลชุดต่าง ๆ

6.3 ผลการทำนายปริมาณแบ่งจากแบบจำลอง

การศึกษาพบว่าการใช้ซอฟต์แวร์ MATLAB® R2018a ในการทำนายปริมาณแบ่งนี้เป็นการหาแบบจำลองที่มีความเหมาะสมที่สุดในการทำนายปริมาณแบ่งจากค่าดัชนีพืชพรรณ โดยพิจารณาจากค่า R^2 รูปที่ 6.13 เป็นการเปรียบเทียบเทียบค่าน้ำหนักของปริมาณแบ่งในหัวมันสำปะหลังจากการเก็บในแปลงตัวอย่างกับค่าปริมาณแบ่งจากการทำนายด้วยแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นซ่อนที่มี 10 ชั้นซ่อนของ 3 อัลกอริทึม



รูปที่ 6.13 การเปรียบเทียบค่าปริมาณน้ำในห้วยน้ำลำปะหลังสดจากข้อมูลจริงภายในแปลงกับข้อมูลจากการทำนายโดยใช้อัลกอริทึม SCG LM และ BR

6.4 สรุปผลการวิจัย

การศึกษาในบทนี้เช่นเดียวกับบทก่อนหน้าคือเป็นการศึกษาการใช้ค่าดัชนีพืชพรรณ NDVI ในการทำนายปริมาณน้ำในห้วยน้ำลำปะหลังสดภายในแปลง (%) โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่พัฒนาขึ้นจากการเขียนโปรแกรมภาษาไพธอน และซอฟต์แวร์ MATLAB ® R2018a การประเมินประสิทธิภาพของแบบจำลองใช้ค่า MSE และค่า R^2 คำนวณหาค่า RMSE เพื่อแปลงออกมาเป็นค่าความคลาดเคลื่อนในหน่วย (%) ชุดข้อมูลในการศึกษาถูกแบ่งออกเป็นข้อมูลชุดฝึกฝน ข้อมูลชุดทดสอบ และข้อมูลชุดตรวจสอบ โดยจะพิจารณาจากแนวโน้มของข้อมูลชุดฝึกฝน และข้อมูลชุดทดสอบ

ในการพิจารณาความเหมาะสมของแบบจำลองจะพิจารณาจากค่า MSE และ R^2 โดยกำหนดขอบเขตที่ค่า MSE ไม่สูงกว่า 0.01 หรือมีความคลาดเคลื่อนในหน่วยพื้นที่ RMSE เท่ากับ 0.1 % และมีค่า R^2 ไม่ต่ำกว่า 0.80 จากขอบเขตดังกล่าวไม่มีแบบจำลองใดในการศึกษานี้ให้ประสิทธิภาพสูงถึงเกณฑ์ที่กำหนด เนื่องจากการศึกษาก่อนหน้านี้ในบทที่ 4 พบว่าข้อมูลปริมาณน้ำในห้วยน้ำลำปะหลังมีค่าสหสัมพันธ์กับค่าดัชนีพืชพรรณที่ใช้ในการทำนายอยู่ในเกณฑ์ปานกลางถึงต่ำ โดยแบบจำลองที่มีประสิทธิภาพสูงที่สุดคือแบบจำลองที่พัฒนาบนซอฟต์แวร์ MATLAB โดยใช้อัลกอริทึม BR ที่มีการ

กำหนดจำนวนชั้นซ้อนที่ 10 ชั้นซ้อน ความคาดเคลื่อนในการทำนายมีค่าเท่ากับ 1.1446% ขณะที่แบบจำลองที่พัฒนาจากการเขียนโปรแกรมภาษาไพธอนมีค่าความคาดเคลื่อนเท่ากับ 1.6371%

การศึกษาเรื่องการทำนายปริมาณแป้งในหัวมันสำปะหลังสดนี้เป็นก้าวแรกในการประเมินปริมาณแป้งโดยใช้ภาพถ่ายจากอากาศยานไร้คนขับสำหรับการทำนายปริมาณผลผลิตใต้ดินด้วยเทคโนโลยีการประมวลผลภาพถ่ายแบบหลายช่วงคลื่นในการสกัดค่าดัชนีพืชพรรณที่ใช้ในการบ่งบอกสุขภาพของพืชจากการสะท้อนแสงของใบ อย่างไรก็ตามการเปลี่ยนแปลงปริมาณแป้งในหัวมันสำปะหลังสดใต้ดินยังมีปัจจัยทางสภาพแวดล้อมที่เกี่ยวข้อง อาทิ ความชื้น ปริมาณธาตุอาหาร และศัตรูพืช ปัจจัยเหล่านี้เองเป็นหนึ่งในสาเหตุที่ทำให้แบบจำลองมีประสิทธิภาพไม่สูงมากนักและยังมีความผิดพลาดอยู่อีกมาก การพัฒนาแบบจำลองในการทำนายในการศึกษาหน้าควรมีการเก็บข้อมูลปัจจัยที่หลากหลายร่วมกับการเก็บข้อมูลในสภาพแวดล้อมที่แตกต่างออกไปเพื่อให้ได้แบบจำลองการเรียนรู้เชิงลึกที่มีประสิทธิภาพสูงเหมาะแก่การใช้งานในทุกสภาพแวดล้อมต่อไป



บทที่ 7

สรุปผลการวิจัย และข้อเสนอแนะ

7.1 สรุปผลการวิจัย

วิทยานิพนธ์เรื่องการคาดการณ์ผลผลิตมันสำปะหลังด้วยภาพถ่ายจากอากาศยานไร้คนขับ และการเรียนรู้เชิงลึกฉบับนี้ นำเสนอการพัฒนาแบบจำลองปัญญาประดิษฐ์สำหรับการทำนายข้อมูล ปริมาณผลผลิตมันสำปะหลัง 2 ข้อมูล ได้แก่ น้ำหนักของหัวมันสำปะหลังสด (กิโลกรัมต่อตารางเมตร) และปริมาณแป้งในหัวมันสำปะหลังสด (%) ในช่วงฤดูเก็บเกี่ยวที่ 4 – 12 เดือนหลังปลูกโดยใช้ข้อมูล ดัชนีพืชพรรณ NDVI คำนวณได้จากภาพถ่ายความละเอียดสูงจากกล้องถ่ายภาพหลายช่วงคลื่นที่ ติดตั้งบนอากาศยานไร้คนขับ

การดำเนินงานวิจัยเริ่มดำเนินการโดยเก็บข้อมูลภาคสนามภายในแปลงตัวอย่าง แบ่งออกเป็น การเก็บข้อมูลมันสำปะหลังตัวอย่างต่อหน่วยพื้นที่เป็นข้อมูลเป้าหมายในการทำนาย และการเก็บ ข้อมูลภาพถ่ายทางอากาศเพื่อนำไปประมวลผลด้วยซอฟต์แวร์ Pix4D ให้ได้ภาพถ่ายแผนที่ความ ละเอียดสูงแบบหลายช่วงคลื่น แล้วจึงนำไปใช้ในการคำนวณค่าดัชนีพืชพรรณชนิดต่าง ๆ ด้วย ซอฟต์แวร์ QGIS

ขั้นตอนถัดไป คือ การเตรียมข้อมูลโดยการจัดทำชุดข้อมูลประกอบด้วย ข้อมูลปริมาณ ผลผลิตจำนวน 2 ข้อมูล และข้อมูลดัชนีพืชพรรณจำนวน 3 ชนิด ได้แก่ ExG, GRVI และ NDVI นำชุด ข้อมูลไปวิเคราะห์การถดถอยและค่าสหสัมพันธ์ เพื่อหาชนิดของดัชนีพืชพรรณที่มีความเหมาะสม ที่สุดในการทำนายปริมาณผลผลิต ผลการวิเคราะห์พบว่าดัชนีพืชพรรณ NDVI มีค่าสหสัมพันธ์และมี ค่าการถดถอยเหมาะสมที่สุดสำหรับการพัฒนาแบบจำลอง

สำหรับแบบจำลองในการทำนายปริมาณผลผลิตเลือกใช้แบบจำลองโครงข่ายประสาทเทียม และแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้น ซึ่งเป็นแบบจำลองปัญญาประดิษฐ์ที่ใช้วิธีการ การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก การพัฒนาแบบจำลองถูกพัฒนาขึ้นด้วยการเขียนโปรแกรม ภาษาไพธอน ที่เขียนขึ้นบนเครื่องมือ Jupyter Notebook การพัฒนาโครงสร้างของแบบจำลอง โครงข่ายประสาทเทียมถูกทำขึ้นโดยใช้ชุดคำสั่ง Scikit-Learn และ TensorFlow นอกจากนี้ยังมีการ พัฒนาโครงข่ายประสาทเทียมบนซอฟต์แวร์ MATLAB® R2018a ด้วยเครื่องมือ Neural Network Toolbox เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองโดยการแบ่งข้อมูลออกเป็นข้อมูลชุดฝึกฝน ข้อมูลชุดตรวจสอบ และข้อมูลชุดทดสอบ

การพัฒนาแบบจำลองโครงข่ายประสาทเทียมมีการปรับปรุงโครงสร้างของแบบจำลองโดยการปรับจำนวนโหนดหรือหน่วยประมวลผลของแบบจำลองระหว่าง 8, 16, 32 และ 64 โหนด และมีการปรับปรุงจำนวนชั้นซ่อนของแบบจำลองระหว่าง 1 – 10 ชั้นซ่อน โดยทำการหาจำนวนโหนดที่มีความเหมาะสมมากที่สุดในการทำนายข้อมูลเป้าหมายมากที่สุด จากนั้นจึงนำจำนวนโหนดที่เหมาะสมนั้นมาใช้กับชั้นซ่อนของแบบจำลองแต่ละชั้นโดยการประเมินประสิทธิภาพการทำนายของแบบจำลอง

การประเมินประสิทธิภาพของแบบจำลองการทำนายใช้ค่า R^2 สำหรับประเมินความแม่นยำของแบบจำลอง และใช้ความผิดพลาดกำลังสองเฉลี่ยหรือ MSE เป็นฟังก์ชันความสูญเสียสำหรับประเมินความผิดพลาดของแบบจำลอง และเพื่อประเมินความผิดพลาดของแบบจำลองในหน่วยเดียวกับข้อมูลเป้าหมายค่ารากที่สองของความผิดพลาดกำลังสองเฉลี่ยหรือ RMSE ถูกนำมาใช้ในการอธิบายความผิดพลาดจากการทำนาย การศึกษานี้ได้กำหนดขอบเขตในการประเมินประสิทธิภาพของแบบจำลองโดยให้ค่า R^2 ไม่น้อยกว่าร้อยละ 80 และมีค่า MSE ไม่มากกว่า 0.01

โดยผลการศึกษาจากการพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นสำหรับทำนายน้ำหนักของหัวมันสำปะหลังสด และปริมาณแป้งในหัวมันสำปะหลังสด ที่พัฒนาขึ้นจากชุดคำสั่ง Scikit-Learn ด้วยการเขียนโปรแกรมภาษาไพธอนพบว่าการประเมินประสิทธิภาพของข้อมูลชุดทดสอบแบบจำลองมีค่า R^2 ต่ำกว่าข้อมูลชุดฝึกฝน และมีค่า MSE มากกว่าข้อมูลชุดฝึกฝน เมื่อเพิ่มความซับซ้อนโดยการเพิ่มจำนวนชั้นซ่อนของแบบจำลอง ทั้งนี้เนื่องมาจากการเกิดปัญหาความเหมาะสมกับข้อมูลมากเกินไป จึงมีการปรับปรุงแบบจำลองด้วยเทคนิคการเร็กคิวลารีเซชัน ด้วยการวิเคราะห์สัญญาณตกท้ายที่ร้อยละ 20 ผลการศึกษาพบว่าช่วยลดปัญหาการเกิดความเหมาะสมกับข้อมูลมากเกินไปได้ แต่แบบจำลองยังมีประสิทธิภาพไม่ตรงตามขอบเขตที่กำหนดไว้ จึงได้มีการพัฒนาแบบจำลองด้วยเครื่องมือบนซอฟต์แวร์ MATLAB ® R2018a โดยการใช้อัลกอริทึมในการประมวลผล 3 ชนิดของชุดเครื่องมือ ได้แก่ BR, LM และ SCG แบบจำลองสำหรับทำนายน้ำหนักของหัวมันสำปะหลังสดภายในแปลงที่มีความเหมาะสมที่สุดคือ แบบจำลองที่มีจำนวนชั้นซ่อน 7 ชั้น ประมวลผลด้วยอัลกอริทึม LM บนซอฟต์แวร์ MATLAB โดย LM ให้ค่า MSE ต่ำที่สุดเท่ากับ 0.0098 และยังให้ค่า R^2 สูงที่สุดที่ 0.8241 โดยมีความผิดพลาดในการทำนายที่ค่า RMSE เท่ากับ 0.0990 กิโลกรัมต่อตารางเมตร สำหรับทำนายปริมาณแป้งของหัวมันสำปะหลังสดภายในแปลงที่มีความเหมาะสมที่สุดคือ แบบจำลองที่มีจำนวนชั้นซ่อน 10 ชั้นซ่อนโดยใช้อัลกอริทึม BR โดยมีค่า R^2 สูงที่สุดเท่ากับ 0.7242 มีค่า MSE ต่ำที่สุดเท่ากับ 1.3101 และมีความผิดพลาดในการทำนายต่ำที่สุดที่ค่า RMSE เท่ากับ 1.1446% โดยแบบจำลองในการทำนายปริมาณแป้งยังมีค่าไม่ตรงตามขอบเขตที่กำหนดเนื่องจากข้อจำกัดของชุดข้อมูล

การผลการศึกษาพบว่ายังมีข้อจำกัดของการวิจัยที่เรื่องปริมาณข้อมูลกลุ่มตัวอย่างที่ไม่มากเพียงพอที่ใช้ในการฝึกฝนแบบจำลองเพื่อให้ได้แบบจำลองที่มีความแม่นยำสูง และความผิดพลาดต่ำ

โดยผลการประเมินประสิทธิภาพของแบบจำลองชี้ให้เห็นว่าแบบจำลองได้เรียนรู้จากชุดข้อมูลที่มีปริมาณไม่เพียงพอส่งผลให้การทำนายยังไม่แม่นยำนัก อีกทั้งการฝึกฝนแบบจำลองในการศึกษานี้ใช้เพียงข้อมูลดัชนีพืชพรรณที่มีค่าสหสัมพันธ์ (Correlation) มากที่สุดในการทำนายปริมาณผลผลิตมันสำปะหลังใต้ดิน โดยไม่ได้เลือกใช้ค่าที่เป็นสาเหตุโดยตรง (Causation) ต่อค่าเป้าหมาย ทั้งนี้เนื่องจากข้อจำกัดในเรื่องต้นทุนทางทรัพยากร และเวลา ในการเก็บข้อมูลที่จำกัด อีกทั้งวัตถุประสงค์หลักในการศึกษานี้คือ การหาแนวทางการใช้ข้อมูลภาพถ่ายทางอากาศจากอากาศยานไร้คนขับในการทำนายผลผลิตของพืชเพื่อต่อยอดการใช้ความรู้เทคโนโลยีภูมิสารสนเทศ และเทคโนโลยีปัญญาประดิษฐ์

การศึกษาในขั้นต่อไปควรที่จะมีการเก็บข้อมูลที่หลากหลายในเชิงพื้นที่ ช่วงเวลา และปริมาณข้อมูล โดยอาจเก็บข้อมูลจากแปลงตัวอย่างหลายแปลงในแต่ละช่วงอายุของพืช และเก็บข้อมูลในฤดูกาลปลูกที่แตกต่างกันเพื่อให้ได้ข้อมูลที่มากเพียงพอ อีกทั้งอาจมีการพิจารณาปัจจัยอื่นที่อาจเกี่ยวข้องกับปริมาณผลผลิตใต้ดินของมันสำปะหลัง เช่น ปริมาณธาตุอาหารภายในดิน ความชื้นระบบการให้น้ำ พันธุ์ ศัตรูพืช และโรคพืช เพื่อให้ได้แบบจำลองในการทำนายปริมาณผลผลิตที่มีความแม่นยำสูงสุด และมีความผิดพลาดต่ำสุด สำหรับให้ข้อมูลที่จำเป็นในการวางแผนการผลิต เพื่อพัฒนาขีดความสามารถของภาคการเกษตร และภาคอุตสาหกรรมของไทยต่อไปในอนาคต

7.2 ข้อเสนอแนะ


7.2.1 เนื่องจากข้อจำกัดในการเก็บข้อมูลทำให้การศึกษานี้เก็บข้อมูลจากแปลงตัวอย่างเพียงแปลงเดียว ชุดข้อมูลสำหรับฝึกฝนแบบจำลองที่ดีควรมีปริมาณที่มากเพียงพอและมีความหลากหลายในการเก็บข้อมูล โดยการเก็บข้อมูลควรมีการเก็บจากแปลงมันสำปะหลังตัวอย่างในหลายพื้นที่ สภาพแวดล้อม และหลายช่วงเวลา เพื่อให้ได้ข้อมูลมากเพียงพอสำหรับฝึกฝนแบบจำลองให้มีความเหมาะสมในการทำนายปริมาณผลผลิตบนพื้นที่ที่หลากหลาย

7.2.2 ชุดข้อมูลในการศึกษานี้มีตัวแปรที่ใช้ในการทำนายค่าตัวแปรเป้าหมายเพียงตัวแปรเดียวคือค่าดัชนีพืชพรรณ การพิจารณาใช้ตัวแปรอื่นที่หลายหลายร่วมด้วย เช่น ข้อมูลสภาพแวดล้อมที่เก็บจากแปลงตัวอย่างอาจช่วยทำให้แบบจำลองมีประสิทธิภาพสูงขึ้นได้

7.2.3 แบบจำลองในการศึกษานี้มีความจำเพาะกับชุดข้อมูลที่ใช้ในการศึกษา หากนำไปใช้งานบนชุดข้อมูลอื่นที่ปัจจัยอื่นมีการควบคุมปัจจัยในการวิจัยที่ความแตกต่างกันอาจส่งผลต่อค่าประสิทธิภาพของแบบจำลองที่อาจแตกต่างกันได้ การศึกษาในอนาคตจึงควรเริ่มพัฒนาแบบจำลองโดยพิจารณาจากแบบจำลองที่มีความซับซ้อนต่ำ เช่น แบบจำลองการทำนายด้วยการเรียนรู้ของเครื่อง จากนั้นจึงเปลี่ยนมาใช้แบบจำลองการเรียนรู้เชิงลึกต่อไป

7.2.4 การเลือกใช้ค่าในการประเมินประสิทธิภาพของแบบจำลองการทำนายด้วยค่าฟังก์ชันความสูญเสียอาจมีการเลือกใช้ค่าอื่น เช่น MAE เพื่อประเมินประสิทธิภาพ ทั้งนี้ควรพิจารณาเลือกใช้การลักษณะของชุดข้อมูล และวัตถุประสงค์ในการใช้งาน

7.2.5 การศึกษานี้เลือกใช้อากาศยานไร้คนขับแบบ 4 ใบพัด รุ่น Phantom 4 pro ในการเก็บข้อมูล เนื่องจากมีความเหมาะสมกับพื้นที่ขนาดเล็ก สำหรับการศึกษาขั้นต่อไปที่มีการเก็บข้อมูลในพื้นที่ขนาดใหญ่อาจพิจารณาเลือกใช้อากาศยานไร้คนขับแบบปีกตรึง หรืออากาศยานไร้คนขับแบบขึ้นลงแนวตั้งที่มีพิสัยการบินที่ไกลกว่าจะช่วยให้สามารถเก็บข้อมูลปริมาณมากในช่วงเวลาอันสั้นได้ ทั้งนี้อาจต้องพิจารณาจากความต้องการเรื่องความละเอียดของภาพ และคุณภาพของภาพจากรายงานการประมวลผลภาพประกอบด้วย



รายการอ้างอิง

- กรมที่ดิน. ศูนย์ข้อมูลแผนที่รูปแปลงที่ดิน. (ม.ป.ป.). คู่มือการทำแผนที่ภาพถ่ายทางอากาศเพื่อการ
รังวัดด้วยอากาศยานไร้คนขับ (UAV) สืบค้นจาก [http://bmm.doh.go.th/website/
index.php/download/manual/uav](http://bmm.doh.go.th/website/index.php/download/manual/uav)
- กรมส่งเสริมอุตสาหกรรม. สำนักพัฒนาการจัดการอุตสาหกรรม. (2559). คู่มือการเพิ่มประสิทธิภาพ
การผลิตและการใช้พลังงานสำหรับอุตสาหกรรมแปรงไม้สำหรับแปรง. กรุงเทพฯ: กระทรวง
อุตสาหกรรม.
- กรมโยธาธิการและผังเมือง. สำนักวิศวกรรมการผังเมือง. (2564). การสำรวจและจัดทำแผนที่
ด้วยอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) สืบค้นจาก
http://bmm.doh.go.th/website/download/drone/Drone_Yota.pdf
- กรมวิชาการเกษตร. (2547). เอกสารวิชาการมันสำปะหลัง. กรุงเทพฯ: กรมวิชาการเกษตร.
- กระทรวงเกษตรและสหกรณ์. สำนักงานเศรษฐกิจการเกษตร. (2564). มันสำปะหลังโรงงาน : เนื้อที่
เพาะปลูก เนื้อที่เก็บเกี่ยว ผลผลิต และผลผลิตต่อไร่ แยกตามชนิดพันธุ์ ปี 2563. สืบค้นจาก
<https://www.oae.go.th/assets/portals/1/fileups/prcaidata/files/varitties%20casava63.pdf>
- กระทรวงเกษตรและสหกรณ์. สำนักงานเศรษฐกิจการเกษตร. (2566). มันสำปะหลังโรงงาน : เนื้อที่
เพาะปลูก เนื้อที่เก็บเกี่ยว ผลผลิต และผลผลิตต่อไร่ ระดับประเทศ ภาค และจังหวัด ปี
2565. สืบค้นจาก [https://www.oae.go.th/assets/
portals/1/fileups/
prcaidata/files/cacava%2065.pdf](https://www.oae.go.th/assets/portals/1/fileups/prcaidata/files/cacava%2065.pdf)
- กระทรวงเกษตรและสหกรณ์. สำนักงานเศรษฐกิจการเกษตร. (ม.ป.ป.). ระบบฐานข้อมูลและ
การให้บริการข้อมูลการค้าเกษตรต่างประเทศของประเทศไทย. สืบค้นจาก [https://
impexpth.oae.go.th/export](https://impexpth.oae.go.th/export)
- กรุณามิตร แสนสุริวงศ์. (2565). การทำนายความต้านทานแรงดัดของวัสดุคอมโพสิตเสริมแรงด้วย
เส้นใยคาร์บอนด้วยวิธีการเรียนรู้เชิงลึก (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ). สืบค้นจาก
[http://sutir.sut.ac.th:8080/sutir/browse?type=author&value=กรุณามิตร+แสนสุริ
วงศ์&value_lang=en_US](http://sutir.sut.ac.th:8080/sutir/browse?type=author&value=กรุณามิตร+แสนสุริวงศ์&value_lang=en_US)
- กอบเกียรติ สระอุบล. (2563). *เรียนรู้ Data Science และ AI: Machine Learning ด้วย Python*.
กรุงเทพฯ: มีเดีย เนทเวิร์ค.

- กอบเกียรติ สระอุบล. (2565). เรียนรู้ AI: Deep Learning ด้วย Python. กรุงเทพฯ: อินเทอร์เน็ตมีเดีย.
- กิตติสุชาติ พสุภา. (2564). ระบบอัจฉริยะขั้นสูง: ทฤษฎี อัลกอริทึม และการประยุกต์ใช้. กรุงเทพฯ: สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.
- ฉฤณ ชินประสาทศักดิ์, ปรีชาพล อินทร์สุข, นันทนัช พุสามป็อก และณัฐพล สนพะเนา. (2566). แก่นแท้ของ Deep Learning : AI ฉบับอธิบายด้วยภาพ. นนทบุรี: เมดบายเอไอ.
- จารุพงศ์ ประสพสุข. (2554). การสู่มเก็บตัวอย่างดิน น้ำ และพืช เพื่อวิเคราะห์สารพิษตกค้าง. ขอนแก่น: กรมวิชาการเกษตร กระทรวงเกษตรและสหกรณ์.
- จิรวรรณ โนดไธสง, ขวัญตรี แสงประชานารักษ์, เจษฎา โพธิ์สม, เสรี วงศ์พิเชษฐ์, ศุภสิทธิ์ คนใหญ่, มหิธร ว่องผาติ และ Chea, C. (2562). การศึกษาความเป็นไปได้ในการทำนายผลผลิตอ้อยในแปลง โดยใช้ดัชนีพืชพรรณ NDVI, $Cl_{red\ edge}$ และปริมาณจากแบบจำลองพื้นผิวเชิงตัวเลข. เกษตร. 47, 679-694.
- เจรอน, ออเรเลียน. (2566). *Hands-On Machine Learning with Scikit-Learn, keras and TensorFlow* [Hands-On Machine Learning with Scikit-Learn, keras and TensorFlow 3rd Edition] (วิโรจน์ อัครรังสี, ผู้แปล). นนทบุรี: คอร์ฟังก์ซัน.
- ชัยวัช ไชวเจริญสุข. (2566). แนวโน้มธุรกิจ/อุตสาหกรรม ปี 2566-68 อุตสาหกรรมมันสำปะหลัง. สืบค้นจาก <https://www.krungsri.com/th/research/industry/industry-outlook/agriculture/cassava/io/cassava-2023-2025>
- ชิงชัย หุมห้อง. (2563). *คู่มือการใช้งานโปรแกรม QGIS อย่างมืออาชีพ (QGIS Professional)*. (พิมพ์ครั้งที่ 2). กำแพงเพชร: แมพพีเดีย.
- ณัฐโชติ พรหมฤทธิ์ และสัจจาภรณ์ ไฉรรยา. (2564). *Fundamental of Deep Learning in Practice*. นนทบุรี: ไอดีซี.
- ดวงกมล เดชดอน. (2562). ผลของพารามิเตอร์และโกลโฟเซตต่อการเจริญเติบโต ผลผลิต และปริมาณ แป้งของมันสำปะหลัง (วิทยานิพนธ์ปริญญาโทบริหารบัณฑิต). สืบค้นจาก <http://sutir.sut.ac.th:8080/jspui/bitstream/123456789/8706/2/Fulltext.pdf>
- ปริญญา สงวนสัตย์. (2562). Artificial Intelligence with Machine Learning, AI สร้างรายได้ด้วย Machine Learning. นนทบุรี: ไอดีซี พรีเมียร์.
- ปริญญ์ จันทวร. (2563). การศึกษานาข้าวโดยอากาศยานไร้คนขับ: การติดตามการเจริญเติบโตของข้าวด้วยดัชนีพืชพรรณ RGB และการวัดความสูงของต้นข้าวด้วยแบบจำลองพื้นผิวเชิงตัวเลข (วิทยานิพนธ์ปริญญาบัณฑิต). สืบค้นจาก <https://km-ir.arts.tu.ac.th/files/original/10731d95869daabaddc7609ca3a2392b4e922914.pdf>

- ปิยะ นากสงค์. (2566). สร้างโปรแกรมให้ฉลาดเรียนรู้ได้ด้วยตัวเอง Python + Machine Learning. กรุงเทพฯ: รีไควว่า.
- ผุสดี บุญรอด และกรวัฒน์ พลเยี่ยม. (2560). แบบจำลองการพยากรณ์ราคามันสำปะหลังโดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น. วิทยาศาสตร์และเทคโนโลยี. 25, 533-543.
- พงศ์ หลวงมูล และถาวร อ่อนประไพ. (2564). การประมาณผลผลิตข้าวด้วยค่าดัชนีพืชพรรณโดยใช้ข้อมูลภาพแบบหลายช่วงคลื่นจากอากาศยานไร้คนขับ. วารสารเกษตร. 37(2), 193-205.
- พรหมชัย สุพรรณ, ธนัช เอกเกื้อกูล, เนติ ศรีหาหนุ และศิวา แก้วปลั่ง. (2561). การติดตามการเจริญเติบโตของนาข้าวด้วยภาพถ่ายจากอากาศยานไร้คนขับ. การประชุมทางวิชาการมหาวิทยาลัยเกษตรศาสตร์ ครั้งที่ 56. บทความย่อ สืบค้นจาก https://kukr.lib.ku.ac.th/kukr_es/index.php?/BKN/search_detail/result/384300
- โพธิ์วุฒิ บุญเรือง, ชัยนต์ ภัคดีไทย และศิวา แก้วปลั่ง. (2564). การประเมินภาพถ่ายทางอากาศจากอากาศยานไร้คนขับสำหรับประมาณผลผลิตอ้อย. เกษตร. 49(1), 306-313.
- มหาวิทยาลัยนเรศวร. อุทยานวิทยาศาสตร์มหาวิทยาลัยนเรศวร. (มกราคม 2566). การส่งเสริมการประยุกต์ใช้อากาศยานไร้คนขับสำหรับภาคอุตสาหกรรม. เอกสารประกอบโครงการพัฒนาความสามารถทางเทคโนโลยีของบุคลากรภาคอุตสาหกรรม (Brain Power Skill Up), ม.ป.ท.:แมพพีเดีย.
- มูลนิธิสถาบันพัฒนามันสำปะหลังแห่งประเทศไทย. (2557). รายงานผลการติดตามภาวะการผลิตมันสำปะหลังฤดูการผลิต 2556/2557. กรุงเทพฯ: มูลนิธิสถาบันพัฒนามันสำปะหลังแห่งประเทศไทย.
- มูลนิธิสถาบันพัฒนามันสำปะหลังแห่งประเทศไทย. (2560). อัจฉรย์มันสำปะหลัง. กรุงเทพฯ: มูลนิธิสถาบันพัฒนามันสำปะหลังแห่งประเทศไทย.
- โมโรนี, ลอเรนซ์. (2564). *AI and Machine Learning for Coders* [AI and Machine Learning for Coders] (วิโรจน์ อัครรังสี, ผู้แปล). นนทบุรี: คอร์ฟิงก์ซัน.
- ยงยุทธ โอสดสภา. (2552). *ธาตุอาหารพืช*. กรุงเทพฯ: มหาวิทยาลัยเกษตรศาสตร์.
- วรารณ พรหมวิอินทร์. (2566). *AI/ML Future Foundation*. กรุงเทพฯ: ส.เอเชียเพลส(1989).
- วลัยพร ศะศิประภา, นริลักษณ์ วรรณสาย, สุภาพร ราชันติก และณิชา โปทอง. (2555). ความสัมพันธ์ระหว่างดัชนีพืชพรรณผลต่างนอร์มัลไลซ์กับผลผลิตมันสำปะหลังในจังหวัดกำแพงเพชร. วิชาการเกษตร. 30(3), 290-299.
- วัชริน มีรอด, กุลวรางค์ สุวรรณศรี และกฤษฎา บำรุงวงศ์. (2558). การศึกษาผลกระทบและเตรียมความพร้อมของภาคเกษตรไทยสู่ประชาคมอาเซียน. ปทุมธานี: สำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ.

- ศาลาว่าการกรุงเทพมหานคร. สำนักยุทธศาสตร์และประเมินผล. กองสารสนเทศภูมิศาสตร์. (ม.ป.ป.) คู่มือการใช้งานโปรแกรม Quantum GIS 3.2 (Bonn). สืบค้นจาก http://gid.bangkok.go.th/wms/qgis_manual.pdf
- ศิริรัตดา ปรีชา, ภัทรภรณ์ หิรัญวงศ์ และอภิษฎา จึงตระกูล. (2563) ส่องฐานะทางการเงินของชาวไร่ มั่นสำปะหลังบนเส้นทางที่ทำนาย: มุมมองสู่ก้าวต่อไปแนวนโยบาย. กรุงเทพฯ: ธนาคารแห่ง ประเทศไทย.
- ศูนย์วิจัยกสิกรไทย. (2560). โดรนเพื่อการเกษตรกำลังมาแรงเพื่อสร้างทางเลือกในยุคเกษตร 4.0 . สืบค้นจาก <https://www.newsdatatoday.com/images/News/OO1-2-18/8699.pdf>
- สถานีรับสัญญาณดาวเทียมจุฬารักษ์. (ม.ป.ป.). *การรับรู้ระยะไกล (Remote Sensing)*. สืบค้นจาก http://etc.csrs.ku.ac.th/pluginfile.php/626/mod_resource/content/3/Remote%20Sensing.pdf
- สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน)[GISDA]. (2018). ตำรา เทคโนโลยีอวกาศและภูมิสารสนเทศศาสตร์. สืบค้นจาก <http://learn.gistda.or.th/2018>
- สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน) [GISDA]. (2022). *THEOS-2* สืบค้นจาก https://www.gistda.or.th/news_view.php?n_id=5675&lang=TH
- สุดชล วันประเสริฐ, จิตพร มะชิโกวา, ชีระศักดิ์ ทองอบ และวรุณยุพา เชื่อมตะคุ. (ม.ป.ป.). คู่มือการปลูกมันสำปะหลังแบบมีอาชีพอายได้ระบบน้ำหยด. นครราชสีมา: สำนักวิชา เทคโนโลยีการเกษตร มหาวิทยาลัยเทคโนโลยีสุรนารี.
- สิตาวีร์ ชีรวิรุฬห์. (2559). สมาร์ทฟาร์ม (Smart farm) การทำการเกษตรที่เป็นมิตรกับสิ่งแวดล้อม. สืบค้นจาก <http://library2.parliament.go.th/ebook/content-issue/2559/hi2559-093.pdf>.
- สิริวัฒน์ สาครวาสี. (2562). *The agriculture of the future เกษตรกรรมแห่งอนาคต*. นนทบุรี: มิตรเกษตรการตลาดและโฆษณา.
- สุกมาส อังศุโชติ. (ม.ป.ป.) เทคนิคการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปร. สืบค้นจาก <https://www.stou.ac.th/offices/ore/info/cae/uploads/pdf/636366560441132172.pdf>
- อรพิน ประวัตติบริสุทธิ. (2564). คัมภีร์ Python ฉบับสมบูรณ์. กรุงเทพฯ: โปรวีชั่น.
- อาภรณ์ พลเสน. (2554). รู้จักกับอากาศยานไร้คนขับหรือยูเอวี (Unmanned Aerial Vehicle: UAV). สืบค้นจาก https://www.dti.or.th/page_bx.php?cid=24&cno=4308
- Abu-Mostafa, Y. S. (2012). *Learning Form Data*. Retrieved form <https://home.work.caltech.edu/slides/slides08.pdf>

- Austin, R. (2010). *Unmanned Aircraft Systems : UAVs Design, Development, and Deployment*. Philadelphia: Wiley.
- Basir, M. S., Chowdhury, M., Islam, M. N. & Rabbani, M. A. (2021). Artificial neural network model in predicting yield of mechanically transplanted rice from transplanting parameters in Bangladesh. *Journal of Agriculture and Food Research*. 5, 100186. doi: 0.1016/j.jafr.2021.100186
- Best, J. W. (1977) *Research in Education*. (3rd ed). New Jersey: Prentice-Hall.
- Binu, D. & Rajakumar, B.R. (2021). *Artificial Intelligence in Data Mining*. Cambridge: Academic Press.
- Chollet, F. (2017) *Deep Learning with Python*. New York: Manning.
- Chu, T., Starek, M. J., Brewer, M. J., Murray, S. C., & Pruter, L. S. (2017). Assessing loading severity over an experimental maize (*Zea mays* L.) field using UAS images. *Remote Sensing*. 9, 923.
- Dawoud, S. (2012). *GNSS principles and comparison*. Retrieved from <https://www.semanticscholar.org/paper/GNSS-principles-and-comparison-Dawoud/f77d36966cfd66be3d1feefe9faae1a6aa7e2756>
- DJI. (2016). *Phantom 4 Pro/Pro+ User Manual V1.0 2016.11*. Retrieved from https://dl.djicdn.com/downloads/phantom_4_pro/Phantom+4+Pro+Pro+Plus+User+Manual+v1.0.pdf.
- Everitt, J. H., Escobar, D. E., Cavazos, I., Noriega, J. R., & Davis, M. R. (1995). A three-camera multispectral digital video imaging system, *Remote Sensing of Environment*. 54(3), 333-337. [https://doi.org/10.1016/0034-4257\(95\)00169-7](https://doi.org/10.1016/0034-4257(95)00169-7)
- Federal Aviation Administration [FAA]. (n.d.). *Unmanned Aircraft Systems*. Retrieved from <https://www.faa.gov/uas/>
- Fieuzal, R., Sicre, C. M., & Baup, F. (2017). Estimation of corn yield using multi-temporal optical and radar satellite data and artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation*, 57, 14-23. doi: 10.1016/j.jag.2016.12.011
- Foresee, F. D. & Hagan, M. T. (1997). Gauss-Newton approximation to Bayesian learning. *Proceedings of International Conference on Neural Networks (ICNN'97)*. 3, 1930-1935. doi: 10.1109/ICNN.1997.614194.

- Glass, G. V., & Hopkins, K. D. (1984). *Statistical Methods in Education and Psychology*. (2nd ed.). New Jersey: Prentice-Hall.
- Gyarmati, G. & Mizik, T. (2020). The present and future of the precision agriculture. *Proceedings of International Conference of System of Systems Engineering (SoSE)*, 593-596. doi: 10.1109/SoSE50414.2020.9130481
- Hashim, H., Latif, A. Z., & Adnan, N. A. (2019). Urban vegetation classification with NDVI Threshold values method with very high resolution (VHR) Pleiades Imagery. *Proceedings of The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 237-240. doi: 10.5194/isprs-archives-XLII-4-W16-237-2019.
- International Civil Aviation Organization [ICAO]. (2018). Unmanned Aircraft Systems (UAS). Retrieved from <https://www.icao.int/safety/UAS/Pages/default.aspx>
- Janket, A., Vorasoot, N., Toomsan, B., Kaewpradit, W., Jogloy, S., Theerakulpisut, P., Holbrook, C. C., Kvien, C. K., & Banterng, K. (2020). Starch Accumulation and Granule Size Distribution of Cassava cv. Rayong 9 Grown under Irrigated and Rainfed Conditions Using Different Growing Seasons. *Agronomy*. 10(3), 412. doi: 0.3390/agronomy10030412
- Jensen, J. R. (2007). *Remote sensing of the environment: An Earth Resource Perspective*. New Jersey: Pearson Prentice Hall.
- Jiang, X., Gao, M., & Gao, Z. (2020). A novel index to detect green-tide using UAV-based RGB imagery. *Estuarine, Coastal and Shelf Science*. 245, 106943. doi: 10.1016/j.ecss.2020.106943
- Kaul, M., Hill, R. L., & Walthall C. (2005) Artificial neural networks for corn and soybean yield prediction, *Agricultural Systems* 85(1), 1-18. doi: 10.1016/j.agry.2004.07.009
- Khuimphukhieo, I., Marconi, T., Enciso, J. & Silva, J. A. (2023). The use of UAS-based high throughput phenotyping (HTP) to assess sugarcane yield, *Journal of Agriculture and Food Research*. 11, 100501. doi: 10.1016/j.jafr.2023.100501.
- Kim, D. W., Yun, H. S., Jeong, S. J., Kwon, Y. S., Kim, S. G., Lee, W. S., & Kim, H. J. (2018). Modeling and Testing of Growth Status for Chinese Cabbage and White Radish with UAV-Based RGB Imagery. *Remote Sensing*. 10, 563. doi: 10.3390/rs10040563

- Machikowa, T., Thong-ob, T., & Wonprasaid, S. (2020). Effect of Soil Moisture and Determination of Critical Soil Moisture Contents of Cassava. *Indian Journal of Agricultural Research*. 54(4), 483-488. doi: 10.18805/IJARE.A-491
- MacKay, D. J. C. (1992). Bayesian interpolation. *Neural computation*. 4, 415–447.
- Matese, A., Toscano, P., Di Gennaro, S.F., Genesio, L., Vaccari, F.P., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R., & Gioli, B. (2015). Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*. 7(3), 2971–2990. doi:10.3390/rs70302971
- Motohka, T., Nasahara, K., & Hiroyuki, O. (2010). Applicability of Green-Red Vegetation Index for Remote Sensing of Vegetation Phenology. *Remote Sensing*. 2(10), 2369-2387. doi: 10.3390/rs2102369
- Moller, M. (1993). A Scaled Conjugate Gradient Algorithm For Fast Supervised Learning, *Neural Networks*. 6, 525–533. doi: 10.1016/S0893-6080(05)80056-5.
- Mutanga, S. S., Schoor, C. V., Olorunju, P. L., Gonah, T., & Ramoelo, A. (2013). Determining the Best Optimum Time for Predicting Sugarcane Yield Using Hyper-Temporal Satellite Imagery. *Advances in Remote Sensing*, 2(03), 269-275. doi: 10.4236/ars.2013.23029.
- Nevavuori, P., Narra, N., Linna, P., & Lipping, T. (2020). Crop Yield Prediction Using Multitemporal UAV Data and Spatio-Temporal Deep Learning Models. *Remote Sensing*. 12(23), 4000. doi: 10.3390/rs12234000.
- Noor, S., Tajik, O., & Golzar, J. (2022). Simple Random Sampling. *International Journal of Education & Language Studies*. 1(2), 78-82. doi: 10.22034/ijels.2022.162982
- Olexy, T. (2021). *GIS Data: Availability and Applicability, Part 1*. Retrieved from <https://dai-global-digital.com/gis-data-availability-and-applicability.html>
- Parrot. (2022). *Parrot SEQUOIA User guide*. Retrieved from https://www.parrot.com/assets/s3fs-public/2021-09/bd_sequoia_integration_manual_en_0.pdf.
- Phunpeng, V., Saensuriwong, K., Thongchart, K., & Uangpairoj, P. (2022). The Flexural Strength Prediction of Carbon Fiber/Epoxy Composite Using Artificial Neural Network Approach, *Materials*. 16(15), 5301. doi: 10.3390/ma16155301

- Santisopasri, V., Kurotjanawong, K., Chotineerarat, S., Piyachomkwan, K., Sriroth, K. & Oates, C. G. (2001). Impact of water stress on yield and quality of cassava starch. *Industrial Crops and Products*. 13(2): 115-129. doi: 0.1016/S0926-6690(00)00058-3
- Sriroth, K., Piyachomkwan, S., & Oates, C. G. (2001). Environmental conditions during root development: Drought constraint on cassava starch quality. *Euphytica*. 120, 95-102. doi: 10.1023/A:1017511806128
- Starý, K., Jelínek, Z., Kumhálová, J., & Chyba, J. (2020). Comparing RGB-based vegetation indices from uav imageries to estimate hops canopy area. *Agronomy Research*. 18(4), 2592-2601. doi: 10.15159/AR.20.169
- Sun, J., Di, L., Sun, Z., Shen, Y., & Lai, Z. (2019). County-Level Soybean Yield Prediction Using Deep CNN-LSTM Model. *Sensors*, 19(20), 4363. doi: 10.3390/s19204363
- Sun, C., Feng, L., Zhang, Z., Ma, Y., Crosby, T., Naber, M., & Wang, Y. (2020). Prediction of End-Of-Season Tuber Yield and Tuber Set in Potatoes Using In-Season UAV-Based Hyperspectral Imagery and Machine Learning. *Sensors*. 20(18), 5293. doi: 10.3390/s20185293
- Sylvester, G. (Ed.). (2018). *E-agriculture in action: drones for agriculture*. Bangkok: Food and Agriculture Organization of the United Nations and International Telecommunication Union.
- Terliksiz, A. S., & Altýlar, D. T. (2019). Use Of Deep Neural Networks For Crop Yield Prediction: A Case Study Of Soybean Yield in Lauderdale County, Alabama, USA. *Proceedings of International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*, 1-4. doi: 10.1109/Agro-Geoinformatics.2019.8820257
- Tumlisan, G. Y. (2017). *Monitoring Growth development and yield estimation of maize using very high-resolution UAV-images in Gronau, Germany* (Master's thesis). Retrieved from https://library.itc.utwente.nl/papers_2017/msc/nrm/tumlisan.pdf
- Tucker, C. J. (1979). Red and photographic in-fared linear combinations for monitoring vegetation. *Remote Sensing of Environment*. 8(2), 127-150. doi: 10.1016/0034-4257(79)90013-0

- Wahub, I., Hall, O., & Jirström, M. (2018). Remote Sensing of Yields: Application of UAV Imagery-Derived NDVI for Estimating Maize Vigor and Yields in Complex Farming Systems in Sub-Saharan Africa. *Drones*. 2(3), 28. doi: 10.3390/drones2030028
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*. 38(1), 259-269. doi: 10.13031/2013.27838
- Yang, C., & Anderson, G. L. (1999). Airborne videography to identify spatial plant growth variability for grain sorghum, *Precision Agriculture*. 1, 67-79. doi:10.1023/A:1009917617316
- Yang, C. & Anderson, G. L. (2000). Mapping grain sorghum yield variability using airborne digital videography, *Precision Agriculture*. 2, 7-23. doi:10. 1023/A:1009928431735
- Yang, C. & Everitt, J. H. (2002). Relationships between yield monitor data and airborne multirate multispectral digital imagery for grain sorghum, *Precision Agriculture*. 3, 373-388. doi:10.1023/A:1021544906167
- Zhao, H., Lee, J. (2020). The feasibility of consumer RGB camera drones in evaluating multitemporal vegetation status of a selected area: a technical note. *Applied Geography*. 6, 480-488. doi: 10.1080/23754931.2020.1782974



ตารางที่ ก.1 คำศัพท์ที่ใช้ในงานวิจัย และคำแปล

ภาษาอังกฤษ	ภาษาไทย
Accuracy	ความแม่นยำ
Activation	การกระตุ้น
Agent	ตัวแทน
Artificial intelligence	ปัญญาประดิษฐ์
Artificial neural network	โครงข่ายประสาทเทียม
Backpropagation	การแพร่ย้อนกลับ
Batch	กลุ่ม
Class	ประเภทข้อมูล
Classification	การจำแนกประเภท
Clustering	การจับกลุ่ม
Coefficient of determination	ค่าสัมประสิทธิ์แสดงการตัดสินใจ
Computer vision	คอมพิวเตอร์วิทัศน์
Computer science	วิทยาศาสตร์ข้อมูล
Cost function	ฟังก์ชันต้นทุน
Data	ข้อมูล
Dataset	ชุดข้อมูล
Data mining	การทำเหมืองข้อมูล
Deep science	วิทยาศาสตร์ข้อมูล
Deep learning	การเรียนรู้เชิงลึก
Digital elevation model	แบบจำลองระดับความสูงเชิงเลข
Digital surface model	แบบจำลองพื้นผิวภูมิประเทศเชิงเลข
Dropout	สัญญาณตกหาย
Encode	การเข้ารหัส
Empirical	เชิงประจักษ์
Error	ความผิดพลาด
Epoch	จำนวนรอบการประมวลผล
Expert system	ระบบผู้เชี่ยวชาญ
Feature	คุณลักษณะ
Feedback	ป้อนกลับ

ภาษาอังกฤษ	ภาษาไทย
Feedforward	ป้อนไปข้างหน้า
Geographic information system	ระบบสารสนเทศภูมิศาสตร์
Georeferencing	การระบุพิกัด
Global navigation satellite system	ระบบกำหนดตำแหน่งบนพื้นโลกด้วยดาวเทียม
Good-fitting	เหมาะสมกับข้อมูลพอดี
Gradient descent	การลดลงขั้นสุด
Ground control point	จุดควบคุมภาคพื้นดิน
Ground sampling distance	ระยะระหว่างจุดศูนย์กลางจุดภาพบนพื้นดิน
Heatmap	แผนที่ความร้อน
Hyperparameter	ตัวแปรเกิน
Image processing	การประมวลผลภาพ
Input	รับเข้า
Insight	ข้อมูลเชิงลึก
Intelligence agent	ตัวแทนอัจฉริยะ
Iteration	การทำซ้ำ
Label	ป้ายกำกับ
Layer	ชั้น
Learning rate	อัตราการเรียนรู้
Library	ชุดคำสั่ง
Loss function	ฟังก์ชันความสูญเสีย
Machine learning	การเรียนรู้ของเครื่อง
Misclassification Rate	อัตราการจำแนกประเภทผิด
Model	แบบจำลอง
Multispectral	แบบหลายช่วงคลื่น
Natural language processing	การประมวลผลภาษาธรรมชาติ
Open-source	รหัสเปิด
Optimization	การหาค่าเหมาะสมที่สุด
Ortho photo	แผนที่ภาพถ่ายความละเอียดสูง หรือ ภาพถ่ายออร์โธ
Outliers	ค่าผิดปกติ

ภาษาอังกฤษ	ภาษาไทย
Output	ส่งออก
Overlap	ส่วนซ้อน
Over-fitting	เหมาะสมกับข้อมูลมากเกินไป
Percent starch	ปริมาณแป้ง (ในหน่วยร้อยละ)
Performance	ประสิทธิภาพ
Precision	ความเที่ยงตรง
Prediction	การทำนาย
Recurrent neural network	โครงข่ายประสาทแบบวนกลับ
Regression	การถดถอย
Reinforcement learning	การเรียนรู้แบบเสริมกำลัง
Remote sensing	การรับรู้ระยะไกล
Resolution	ความละเอียด
Semi-supervised learning	การเรียนรู้แบบกึ่งสอน
Sidelap	ส่วนเกย
Source code	รหัสต้นฉบับ
Spatial data	ข้อมูลเชิงพื้นที่
State	ค่าสถานะ
Stochastic	การสุ่ม
Supervised learning	การเรียนรู้แบบมีผู้สอน
Target	เป้าหมาย
Test	ทดสอบ
Threshold	ขีดแบ่ง
Training	การฝึกฝน
True error	ความผิดพลาดจริง
Under-fitting	เหมาะสมกับข้อมูลต่ำเกินไป
Unmanned aerial vehicle	อากาศยานไร้คนขับ
Unsupervised learning	การเรียนรู้แบบไม่มีผู้สอน
Validation	ตรวจสอบ
Vegetation Index	ดัชนีพืชพรรณ
Weight	น้ำหนัก

ภาคผนวก ข

การใช้งานซอฟต์แวร์ Pix4D
และกล้องถ่ายภาพแบบหลายช่วงคลื่น

มหาวิทยาลัยเทคโนโลยีสุรนารี

Pix4D เป็นแพลตฟอร์มที่ประยุกต์ใช้เทคโนโลยีด้านอากาศยานไร้คนขับในวัตถุประสงค์ที่หลากหลายในการสำรวจและทำแผนที่ หรือแบบจำลองสามมิติ อาทิ การก่อสร้าง งานเกษตรแม่นยำ สถาปัตยกรรม และงานวิศวกรรมโยธา

Pix4D Capture เป็นแอปพลิเคชัน สำหรับการวางแผนการบินของอากาศยานไร้คนขับเพื่อทำแผนที่ภาพถ่ายความละเอียดสูง รองรับการใช้งานกับอากาศยานไร้คนขับในเครื่องหมายการค้า DJI สามารถช่วยในการกำหนดเส้นทางการบิน และควบคุมการเก็บข้อมูลภาพถ่ายของอากาศยานตามเส้นทางที่กำหนดได้ Pix4D Capture เป็นซอฟต์แวร์ที่เปิดใช้งานได้โดยไม่เสียค่าใช้จ่าย สามารถใช้งานได้บนระบบปฏิบัติการ iOS และ Android

Pix4D Mapper เป็นซอฟต์แวร์ที่ใช้เทคนิคโฟโตแกรมเมตรี (Photogrammetry) ในการประมวลผลภาพถ่ายเพื่อให้ได้แบบจำลองแผนที่ภาพถ่ายความละเอียดสูง (Ortho photo) และแบบจำลองพื้นผิวภูมิประเทศเชิงเลข (DSM) อีกทั้งยังสามารถสร้างแผนที่ดัชนีพืชพรรณจากภาพถ่ายหลายช่วงคลื่นได้อีกด้วย Pix4D Mapper เป็นซอฟต์แวร์กรรมสิทธิ์ที่ต้องเสียค่าบริการแบบสมัครรับรายเดือน หรือรายปี (Subscription) แต่มีการเปิดให้ทดลองใช้โดยไม่เสียค่าใช้จ่ายแบบจำกัดช่วงเวลาไม่เกิน 14 วันหลังเปิดการทดลองใช้

นอกจาก Pix4D Mapper แล้วยังมีซอฟต์แวร์อื่นในการประมวลผลภาพ เช่น Drone Deploy และ WebODM ที่มีความสามารถเช่นเดียวกัน

ข.1 การใช้งานซอฟต์แวร์ Pix4D Capture

การใช้งานซอฟต์แวร์ Pix4D Capture เพื่อสำรวจและทำแผนที่ด้วยภาพถ่ายจากอากาศยานไร้คนขับรุ่น DJI Phantom 4 Pro ทั้งรุ่น V.1 และ V.2 นั้น จำเป็นจะต้องใช้งานร่วมกับแอปพลิเคชัน DJI GO4 ซึ่งเป็นซอฟต์แวร์ฟรี สำหรับควบคุมอากาศยานไร้คนขับยี่ห้อ DJI



DJI GO4



Pix4D Capture

รูปที่ ข.1 แอปพลิเคชัน DJI GO4 และ Pix4D Capture

ข.1.1 การใช้งานแอปพลิเคชัน DJI GO4

ในการเตรียมความพร้อมของระบบอากาศยานไร้คนขับ (UAS) จำเป็นต้องเชื่อมต่อการใช้งานบนแอปพลิเคชันกับอากาศยาน เพื่อตรวจสอบสถานะและการตั้งค่าก่อนการใช้งาน Pix4D Capture ดังนี้




รูปที่ ข.2 หน้าเริ่มต้น แสดงการเชื่อมต่อกับอากาศยานไร้คนขับ



รูปที่ ข.3 หน้าแสดงอากาศยานที่รองรับการใช้งานได้


(1) เปิดใช้งานแอปพลิเคชัน เลือกอากาศยานเพื่อทำการเชื่อมต่อ เมื่อเชื่อมต่อสำเร็จ กดปุ่ม “GO FLY” เพื่อเริ่มใช้งาน

(2) หน้าจอหลักและส่วนประกอบแสดงดังรูป ข.4



รูปที่ ข.4 หน้าจอหลัก


(3) สถานะของอากาศยาน มีการแบ่งออกเป็น 3 แบบคือ สีเขียว สีเหลือง และสีแดง โดย สถานะสีเขียว หมายถึงมีสัญญาณดาวเทียมเพียงพอ อากาศยานมีความพร้อมในการทำการบิน สถานะสีเหลือง หมายถึงสัญญาณดาวเทียมไม่เพียงพอ ต้องใช้ความระมัดระวังในการบินเป็นพิเศษ และสถานะสีแดง หมายถึงอากาศยานไม่มีความพร้อมในการทำการบิน ต้องแก้ไขตามคำแนะนำ เพื่อให้สถานะกลับมาเป็นสีเขียว หรือสีเหลือง



รูปที่ ข.5 สถานะของอากาศยาน

(4) การตั้งค่าทั่วไป (General Setting) ในแอปพลิเคชัน สำหรับการบินถ่ายภาพนั้น โดยปกติ หากใช้งานในการบินถ่ายภาพการทั่วไปให้ใช้การตั้งค่าในค่าเริ่มต้น (default) ของแอปพลิเคชัน หากมีการติดตั้งอุปกรณ์เสริม เช่น อุปกรณ์จับยึดกล้องถ่ายภาพแบบหลายช่วงคลื่น ที่จะมีการบดบังการทำงานของเซนเซอร์รอบเครื่อง มีความจำเป็นที่จะต้องปิดการทำงานของเซนเซอร์บางตัวในแถบ

General Setting > Visual Navigation System > Advance Setting > ปิด Enable Vision Positioning




รูปที่ ข.6 การปิดการทำงานของเซนเซอร์


ข.1.2 การใช้งานแอปพลิเคชัน Pix4D Mapper

ในการเริ่มใช้งานจะสามารถทำงานบนอุปกรณ์เดียวกับแอปพลิเคชัน DJI GO4 ได้ ขั้นตอนการใช้งานให้ทำการลงทะเบียนและเข้าสู่ระบบด้วยอีเมล

(1) เปิดแอปพลิเคชัน จะปรากฏหน้าจอเริ่มต้น (รูปที่ ข.7) ให้กดที่ปุ่ม Setting เพื่อเลือกรุ่นและกล้องสำหรับถ่ายภาพ โดยทั่วไปหากมีการต่อสาย USB ระหว่างอุปกรณ์ที่ใช้แอปพลิเคชันกับชุดอุปกรณ์ควบคุม (Remote Controller) จะมีการเชื่อมต่อให้โดยอัตโนมัติ



รูปที่ ข.7 หน้าเริ่มต้น Pix4D Mapper



รูปที่ ข.8 รุ่นของอากาศยาน และกล้อง


(2) ให้เลือก Plan new mission แบบ Grid หรือ Polygon สำหรับการทำแผนที่ภาพถ่ายความละเอียดสูง หากต้องการความแม่นยำในการทำแผนที่พื้นผิวภูมิประเทศเชิงเลข (DSM) หรือแบบจำลองสามมิติให้เลือก Double Grid เมื่อเลือกแล้วจะเข้าสู่หน้าต่างวางแผนการบิน รูปที่ ข.9



รูปที่ ข.9 หน้าต่างวางแผนการบิน

(3) สำหรับการตั้งค่าการบินให้ปรับไปที่โหมด Advanced (รูปที่ ข.10) ใช้ในการกำหนดค่ามุมของกล้องขณะถ่าย (Angle of camera) อัตราส่วนส่วนซ้อน และส่วนเกย (Front overlap & Side overlap) ความเร็วในการบิน (Drone Speed) การปรับรูรับแสง (White balance) โดยการกำหนดค่าแสดงดังตารางที่ ข.1

มหาวิทยาลัยเทคโนโลยีสุรนารี




รูปที่ ข.10 หน้าต่างการตั้งค่าการบินแบบ Advanced

ตารางที่ ข.1 การตั้งค่าการบินในการศึกษาวิจัย

ตัวแปรในการวางแผนการบินถ่ายภาพ	ค่าที่กำหนด
Angle of the camera	90
Front overlap	80%
Side overlap	70%
Look at grid's center	NO
Picture trigger mode	Safe mode
Drone speed	Slow+
White Balance	Auto
ความสูงในการบิน (ในหน้าเริ่มต้น)	30 m

(4) เมื่อตั้งค่าแผนการบินสำเร็จให้กดที่ปุ่ม “START” เพื่อเริ่มทำการบิน โดยจะมีการเช็คสถานะก่อนทำการบิน เมื่อเช็คสถานะได้ครบทุกรายการแล้ว จะสามารถกดปุ่ม “Start” ได้ เพื่อให้อากาศยานเริ่มทำการบินตามภารกิจในแผนที่วางไว้ได้โดยอัตโนมัติ



รูปที่ ข.11 การเช็คสถานะก่อนทำการบิน




รูปที่ ข.12 อากาศยานขณะบินตามภารกิจในแผนที่วางไว้

ข.2 การใช้งานซอฟต์แวร์ Pix4D Mapper


ในหัวข้อก่อนหน้าเป็นการบินเพื่อทำภารกิจในการเก็บภาพด้วยแอปพลิเคชัน Pix4D Capture ในหัวข้อนี้จะนำภาพถ่ายที่มีการระบุตำแหน่งของภาพ (Image Geolocation) ไว้ในระบบพิกัดฉากแบบ WGS 84 โดยจะเป็นไฟล์รูปภาพในนามสกุล .JPG เก็บใน Micro SD card ให้ถ่ายโอนข้อมูลลงบนคอมพิวเตอร์ที่จะใช้งาน

การเริ่มใช้งาน Pix4D Mapper เริ่มจากการสมัครใช้งาน และเลือกแพ็คเกจการสมัครสมาชิก หรือทดลองใช้ 15 วัน และ download ซอฟต์แวร์ Pix4D Mapper ผ่านทาง www.pix4d.com/product/pix4dmapper-photogrammetry-software/ แล้วทำการเข้าสู่ระบบ เพื่อทำการสร้างแผนที่ด้วยภาพถ่ายจากอากาศยานไร้คนขับมีขั้นตอนดังนี้




รูปที่ ข.13 หน้าเริ่มต้น Pix4D Mapper

(1) กดที่ปุ่ม “New Project” ทำการระบุชื่อ และตำแหน่งที่ต้องการเก็บไฟล์ และเลือก Project type เป็น New Project สำหรับการทำแผนที่ใหม่ หากต้องการเพิ่มข้อมูลภาพสำหรับทำแผนที่ที่เคยทำมาก่อนให้เลือกเป็น Project Merged from Existing Projects (รูปที่ ข.14) เมื่อดำเนินการเสร็จเรียบร้อยแล้วให้คลิก “Next”




รูปที่ ข.14 การสร้าง Project ใหม่

(2) ให้ทำการเพิ่มรูปภาพที่ถ่ายด้วย Pix4D Capture จะใช้ในการทำแผนที่โดยสามารถเลือกได้แบบ Add image สำหรับการเลือกรูปจากการดึงรูปมาโดยตรงเป็นรายรูปหรือ Add Directories สำหรับการเลือกรูปจากตำแหน่งที่เก็บไฟล์ กำหนดขั้นต่ำที่ 3 รูปและต้องเป็นไฟล์นามสกุล .JPG หรือ .TIFF จากนั้นคลิก Next




รูปที่ ข.15 การนำเข้ารูปภาพ

(3) ขั้นตอนถัดไปจะแสดงหน้าต่าง Image properties เพื่อแสดงข้อมูลเบื้องต้นเกี่ยวกับภาพที่นำเข้ามา (รูปที่ ข.16) ให้ใช้ค่าเริ่มต้น จากนั้นกด Next เพื่อดำเนินการต่อจะเข้าสู่หน้าต่าง Select Output Coordinate System ให้ใช้ค่าเริ่มต้น (รูปที่ ข.17) จากนั้นกด Next เพื่อดำเนินการต่อเช่นกัน




รูปที่ ข.16 Image properties




รูปที่ ข.17 Select Output Coordinate System

(4) ในหน้าต่างต่อมา Processing Option Template ให้เลือก Template การประมวลผลเป็น 3D Maps โดยที่ไม่ต้องเลือก Start Processing Now แล้วจึงกด Finish



รูปที่ ข.18 Processing Option Template

(5) เมื่อเข้าสู่หน้าต่าง Processing (รูปที่ ข.19) จะแสดงตำแหน่งของรูปที่นำเข้าสู่ซอฟต์แวร์ตามตำแหน่งในแผนที่ ให้ทำการคลิกที่ Processing Option (มุมขวาล่างเพื่อตั้งค่าการประมวลผล)




รูปที่ ข.19 หน้าต่าง Processing


(6) หน้าต่าง Processing Option แบ่งออกเป็น 3 ส่วนคือ 1. Initial processing, 2. Point Cloud and Mesh และ 3. DSM Orthomosaic and Index ดังรูปที่ ข.19, ข.20 และ ข.21 สำหรับการตั้งค่าจะแสดงในตารางที่ ข.1 จากนั้นกด Start เพื่อเริ่มการประมวลผล เมื่อประมวลผลเสร็จในแต่ละขั้นตอนจะได้รายงานการประมวลผล (Quality report) และเมื่อประมวลผลเสร็จสิ้นทั้ง 3 ขั้นตอนจะได้ไฟล์แผนที่ความละเอียดสูง และ DSM อยู่ในตำแหน่งที่เก็บไว้ที่ระบุไว้ในตอนแรก (รูปที่ ข.22) ตัวอย่างรายงานการประมวลผลแสดงในภาคผนวก ค.

ตารางที่ ข.1 การตั้งค่าก่อนการประมวลผลในซอฟต์แวร์ Pix4D Mapper


ตัวแปร	การตั้งค่า
Coordinate System	World Geodetic System 1984 (WGS 84)
Unit	Meter (m)
Keypoints image scale	Full
Image Scale	1/2 (Half image size)
Point Density	Optimal
Minimum Number of Matches	3
Export	LAS
Resolution	Automatic
DSM Filters	Use Noise Filtering และ Use Surface Smoothing
Raster DSM	Geo TIFF
Orthomosaic	Merge Tiles



รูปที่ ข.20 Initial processing



รูปที่ ข.21 Point Cloud and Mesh



รูปที่ ข.22 DSM Orthomosaic and Index




รูปที่ ข.23 ไฟล์ที่ได้ภายหลังการประมวลผล


ข.3 การใช้งานกล้องถ่ายภาพแบบหลายช่วงคลื่นรุ่น Parrot SEQUOIA

กล้องถ่ายภาพหลายช่วงคลื่นรุ่น Parrot SEQUOIA พร้อมด้วย Sunshine sensor จะถูกใช้ในการถ่ายภาพ 4 ช่วงคลื่นได้แก่ Green, Red, Red Edge และ NIR โดยเป็นกล้องที่ไว้สำหรับติดตั้งภายนอกอากาศยานไร้คนขับ สำหรับอากาศยานไร้คนขับรุ่น DJI Phantom 4 Pro จะต้องมีการใช้


อุปกรณ์จับยึดที่พิมพ์จากเครื่องพิมพ์สามมิติ รุ่น PrusaSlicer-2.3.1 ในการติดตั้งกล่อง ดังรูปที่ ข.23, ข.24 และ ข.25 โดยวัสดุที่ใช้เป็น Polyethylene Terephthalate Glycol-modified (PETG)



รูปที่ ข.24 การพิมพ์ชิ้นส่วนฐานกล่องถ่ายภาพหลายช่วงคลื่น



รูปที่ ข.25 การพิมพ์ชิ้นส่วนฐานกล่อง Sunshine sensor และอุปกรณ์จับยึด



รูปที่ ข.26 การพิมพ์ชิ้นส่วนขาตั้งอากาศยาน




รูปที่ ข.27 การติดตั้งอุปกรณ์จับยึดกับ UAV และชุดกล้อง Parrot SEQUOIA และแบตเตอรี่


(1) สำหรับการตั้งค่าในการถ่ายภาพจะดำเนินการก่อนที่จะปล่อยอากาศยานขึ้นเพื่อทำการกิจด้วยซอฟต์แวร์ Pix4D Capture โดยจะสามารถตั้งค่าได้ที่ URL ที่ระบุไว้ในคู่มือ โดยจำเป็นจะต้องเชื่อมต่อกับ WI-FI ของชุดกล้องด้วย สำหรับการตั้งค่าในการถ่ายภาพบน Parrot SEQUOIA HTML Interface แสดงได้ดังรูปที่ ข.28 และตัวแปรการตั้งค่าแสดงในตารางที่ 3.5

(2) ในการตั้งค่าการถ่ายภาพจะกำหนดรูปแบบในการถ่ายภาพเป็นแบบ Capture โดยสามารถคำนวณค่าในการถ่ายภาพได้จากสัญลักษณ์เครื่องคิดเลขในช่อง Timelapse interval ดังรูปที่ ข.28 (a) โดยกำหนดได้ที่ค่าความสูง และความเร็วในการบินดังรูปที่ ข.29

(3) ในการเก็บข้อมูลภาพถ่ายสามารถเลือกเก็บได้ที่ External SD card บน Sunshine Sensor หรือเก็บภาพใน Internal memory ของกล้องฯ แสดงในรูปที่ ข.28 (b)



รูปที่ ข.28 การตั้งค่าในการถ่ายภาพบน Parrot SEQUOIA HTML Interface



รูปที่ ข.29 การคำนวณ Timelapse interval

(4) เมื่อตั้งค่าเสร็จเรียบร้อยแล้วจะทำการเริ่มกดปุ่มถ่ายภาพ (วงกลมขอบสีเขียว) ที่เมนู My Sequoia ดังรูปที่ ข.28 (c) โดยขณะที่ทำการถ่ายภาพจะแสดงข้อความว่า TIMELAPSE RUNNING และเมื่อทำการกิจเสร็จสิ้น หรือต้องการหยุดถ่ายให้กดปุ่มเดิมอีกครั้งเพื่อหยุดการถ่ายภาพ

(5) ในการสอบเทียบค่าแสงจะใช้แผ่นสอบเทียบ โดยจะทำก่อนหรือภายหลังการทำการกิจก็ได้ วิธีการสอบเทียบทำได้โดยการวางแผ่นสอบเทียบในทิศทางที่ถูกต้องและระดับน้ำอยู่ตรงจุดกึ่งกลางดังรูปที่ ข.30 จากนั้นให้กดที่ปุ่ม Launch ของ Radiometric calibration (รูปที่ ข.27 (a)) จะแสดงคำแนะนำในการใช้งานดังรูปที่ ข.31 ให้กดปุ่ม Start เพื่อเริ่มการถ่ายภาพสำหรับสอบเทียบ โดยจะใช้เวลาในการถ่ายภาพ 10 วินาที




รูปที่ ข.30 การวางแผ่นสอบเทียบ

Radiometric calibration

For accurate reflectance data, pictures of a calibrated reflectance panel should be captured from directly overhead the panel immediately before and immediately after each flight.


When imaging the reflectance panel, place the panel flat on the ground and ensure that it is not shadowed by anything, that it is receiving direct light from the sun or sky, and that the angle of view from the camera to the panel is as perpendicular as possible (without shadowing). Avoid having the sun reflect off any surface and hit the panel. It's best to place your shadow just to the left or right of the panel (See picture below).






รูปที่ ข.31 การทำ Radiometric calibration

(6) สำหรับการสอบเทียบค่าใน Pix4D Mapper จะตั้งค่านในขั้นตอน 3. DSM Orthomosaic and Index โดยไปที่ Index Calculator เลือก Correction Type เป็น Camera and Sun Irradiance ในทุกช่วงคลื่นดังรูปที่ ข.32



รูปที่ ข.32 หน้าเริ่มต้นการสอบเทียบค่าใน Pix4D

(7) นำเข้าข้อมูลภาพโดยกดที่ Calibrate จะเข้าสู่หน้าการกำหนดพื้นที่สอบเทียบ (รูปที่ ข.33) เลือกรูปให้ตรงกับช่วงคลื่นที่จะสอบเทียบ วาดขอบเขตของแผ่นสอบเทียบ แล้วกด Ok จากนั้นทำการสอบเทียบให้ครบทุกช่วงคลื่นจะได้ผลลัพธ์ดังรูปที่ ข.34




รูปที่ ข.33 การกำหนดพื้นที่สอบเทียบ



รูปที่ ข.34 การกำหนดการสอบเทียบสำเร็จ

(8) ก่อนที่จะทำการเริ่มการประมวลผลให้เลือกค่าดัชนีพืชพรรณที่ต้องการ (เฉพาะกรณีดัชนีพืชพรรณจากกล้องถ่ายภาพหลายช่วงคลื่น) ในช่อง Indices โดยเลือกค่าดัชนี ndvi ดังรูปที่ ข.35 จากนั้นจึงเริ่มการประมวลผลเพื่อสร้างแผนที่ภาพถ่ายความละเอียดสูงของดัชนีพืชพรรณ NDVI



รูปที่ ข.35 การตั้งค่าการคำนวณดัชนี NDVI บน Pix4D



ภาคผนวก ค

ตัวอย่างรายงานการประเมินผล

Quality Report



Generated with Pix4Dmapper Pro version 3.0.18



Important: Click on the different icons for:



Help to analyze the results in the Quality Report



Additional information about the sections



Click [here](#) for additional tips to analyze the Quality Report

Summary



Project	28-12-64-rgb
Processed	2022-09-28 22:09:12
Camera Model Name(s)	FC6310_8.8_5472x3648 (RGB)
Average Ground Sampling Distance (GSD)	0.81 cm / 0.32 in
Area Covered	0.0381 km ² / 3.8148 ha / 0.0147 sq. mi. / 9.4314 acres
Time for Initial Processing (without report)	04h:25m:35s

Quality Check



Images	median of 79005 keypoints per image	
Dataset	507 out of 531 images calibrated (95%), all images enabled, 4 blocks	
Camera Optimization	2.99% relative difference between initial and optimized internal camera parameters	
Matching	median of 3955.9 matches per calibrated image	
Georeferencing	yes, no 3D GCP	

Preview




Figure 1: Orthomosaic and the corresponding sparse Digital Surface Model (DSM) before densification.

Calibration Details



Number of Calibrated Images	507 out of 531
Number of Geolocated Images	531 out of 531

? Initial Image Positions





Figure 2: Top view of the initial image position. The green line follows the position of the images in time starting from the large blue dot.

? Computed Image/GCPs/Manual Tie Points Positions




Uncertainty ellipses 1x magnified

Figure 3: Offset between initial (blue dots) and computed (green dots) image positions as well as the offset between the GCPs initial positions (blue crosses) and their computed positions (green crosses) in the top-view (XY plane), front-view (XZ plane), and side-view (YZ plane). Red dots indicate disabled or uncalibrated images. Dark green ellipses indicate the absolute position uncertainty of the bundle block adjustment result.

? Absolute camera position and orientation uncertainties

	X [m]	Y [m]	Z [m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	1.164	1.164	0.095	0.081	0.177	0.641
Sigma	0.340	0.340	0.055	0.040	0.090	0.098

Overlap



Number of overlapping images: 1 2 3 4 5+

Figure 4: Number of overlapping images computed for each pixel of the orthomosaic. Red and yellow areas indicate low overlap for which poor results may be generated. Green areas indicate an overlap of over 5 images for every pixel. Good quality results will be generated as long as the number of keypoint matches is also sufficient for these areas (see Figure 5 for keypoint matches).

Bundle Block Adjustment Details

Number of 2D Keypoint Observations for Bundle Block Adjustment	2148362
Number of 3D Points for Bundle Block Adjustment	874207
Mean Reprojection Error [pixels]	0.118

Internal Camera Parameters

FC6310_8.8_5472x3648 (RGB). Sensor Dimensions: 12.833 [mm] x 8.556 [mm]

EXIF ID: FC6310_8.8_5472x3648

	Focal Length	Principal Point x	Principal Point y	R1	R2	R3	T1	T2
Initial Values	3668.759 [pixel] 8.604 [mm]	2736.001 [pixel] 6.417 [mm]	1823.999 [pixel] 4.278 [mm]	0.003	-0.008	0.008	-0.000	0.000
Optimized Values	3778.478 [pixel] 8.862 [mm]	2743.311 [pixel] 6.434 [mm]	1821.359 [pixel] 4.272 [mm]	0.004	-0.010	0.010	-0.001	0.001
Uncertainties (Sigma)	0.025 [pixel] 0.000 [mm]	0.625 [pixel] 0.001 [mm]	0.569 [pixel] 0.001 [mm]	0.001	0.002	0.002	0.000	0.000



The number of Automatic Tie Points (ATPs) per pixel averaged over all images of the camera model is color coded between black and white. White indicates that, in average, more than 16 ATPs are extracted at this pixel location. Black indicates that, in average, 0 ATP has been extracted at this pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization.

2D Keypoints Table


	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	79005	3956

Min	72630	33
Max	96637	17039
Mean	81823	4237

? 3D Points from 2D Keypoint Matches

	Number of 3D Points Observed
In 2 Images	658465
In 3 Images	130486
In 4 Images	44391
In 5 Images	19098
In 6 Images	8546
In 7 Images	4904
In 8 Images	3007
In 9 Images	1909
In 10 Images	1254
In 11 Images	697
In 12 Images	534
In 13 Images	300
In 14 Images	228
In 15 Images	156
In 16 Images	85
In 17 Images	59
In 18 Images	43
In 19 Images	22
In 20 Images	11
In 21 Images	7
In 22 Images	5

? 2D Keypoint Matches






Figure 5: Computed image positions with links between matched images. The darkness of the links indicates the number of matched 2D keypoints between the images. Bright links indicate weak links and require manual tie points or more images. Dark green ellipses indicate the relative camera position uncertainty of the bundle block adjustment result.

? Relative camera position and orientation uncertainties

	X [m]	Y [m]	Z [m]	Omega [degree]	Phi [degree]	Kappa [degree]
Mean	0.040	0.031	0.095	0.080	0.177	0.032
Sigma	0.020	0.019	0.056	0.040	0.090	0.024

Geolocation Details

? Absolute Geolocation Variance

Min Error [m]	Max Error [m]	Geolocation Error X [%]	Geolocation Error Y [%]	Geolocation Error Z [%]
-	-15.00	0.00	0.00	0.00
-15.00	-12.00	0.00	0.00	0.00
-12.00	-9.00	0.00	0.00	0.00
-9.00	-6.00	0.00	0.00	0.00
-6.00	-3.00	0.20	0.00	0.00
-3.00	0.00	44.97	52.47	49.11
0.00	3.00	54.44	46.35	50.89
3.00	6.00	0.39	0.39	0.00
6.00	9.00	0.00	0.39	0.00
9.00	12.00	0.00	0.00	0.00
12.00	15.00	0.00	0.00	0.00
15.00	-	0.00	0.39	0.00
Mean [m]		0.000347	0.002470	-0.000305
Sigma [m]		1.272819	1.346943	0.449344
RMS Error [m]		1.272819	1.346945	0.449344

Min Error and Max Error represent geolocation error intervals between -1.5 and 1.5 times the maximum accuracy of all the images. Columns X, Y, Z show the percentage of images with geolocation errors within the predefined error intervals. The geolocation error is the difference between the initial and computed image positions. Note that the image geolocation errors do not correspond to the accuracy of the observed 3D points.

? Relative Geolocation Variance

Relative Geolocation Error	Images X [%]	Images Y [%]	Images Z [%]
[-1.00, 1.00]	100.00	99.01	100.00
[-2.00, 2.00]	100.00	99.61	100.00
[-3.00, 3.00]	100.00	99.61	100.00
Mean of Geolocation Accuracy [m]	5.000000	5.000000	10.000000
Sigma of Geolocation Accuracy [m]	0.000000	0.000000	0.000000

Images X, Y, Z represent the percentage of images with a relative geolocation error in X, Y, Z.

Quality Report



Generated with Pix4Dmapper Pro version 3.0.18



Important: Click on the different icons for:



Help to analyze the results in the Quality Report



Additional information about the sections



Click [here](#) for additional tips to analyze the Quality Report

Summary



Project	28-12-64
Processed	2022-01-14 18:11:08
Camera Model Name(s)	Sequoia_4.0_1280x960 (Green), Sequoia_4.0_1280x960 (Red), Sequoia_4.0_1280x960 (Red edge), Sequoia_4.0_1280x960 (NIR)
Rig name(s)	«Sequoia»
Average Ground Sampling Distance (GSD)	3.08 cm / 1.21 in
Area Covered	0.0438 km ² / 4.3772 ha / 0.0169 sq. mi. / 10.822 acres
Time for Initial Processing (without report)	53m:11s

Quality Check



Images	median of 9386 keypoints per image	
Dataset	3044 out of 3044 images calibrated (100%), all images enabled	
Camera Optimization	0.1% relative difference between initial and optimized internal camera parameters	
Matching	median of 4632.52 matches per calibrated image	
Georeferencing	yes, no 3D GCP	

Preview



มหาวิทยาลัยเทคโนโลยีสุรนารี




Figure 1: Orthomosaic and the corresponding sparse Digital Surface Model (DSM) before densification.

Calibration Details

Number of Calibrated Images	3044 out of 3044
Number of Geolocated Images	3044 out of 3044

? Initial Image Positions




Figure 2: Top view of the initial image position. The green line follows the position of the images in time starting from the large blue dot.

? Computed Image/GCPs/Manual Tie Points Positions




Figure 3: Offset between initial (blue dots) and computed (green dots) image positions as well as the offset between the GCPs initial positions (blue crosses) and their computed positions (green crosses) in the top-view (XY plane), front-view (XZ plane), and side-view (YZ plane).

Overlap




Figure 4: Number of overlapping images computed for each pixel of the orthomosaic. Red and yellow areas indicate low overlap for which poor results may be generated. Green areas indicate an overlap of over 5 images for every pixel. Good quality results will be generated as long as the number of keypoint matches is also sufficient for these areas (see Figure 5 for keypoint matches).

Bundle Block Adjustment Details


Number of 2D Keypoint Observations for Bundle Block Adjustment	4537600
Number of 3D Points for Bundle Block Adjustment	1527644
Mean Reprojection Error [pixels]	0.236

? Internal Camera Parameters

Sequoia_4.0_1280x960 (Green). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]

EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.006663	-0.134893	0.000000	1661.46	0.00	0.00	1661.46	653.82	512.64
Optimized Values	0.000000	1.000000	0.006929	-0.173697	0.000000	1694.96	0.00	0.00	1694.96	650.22	512.61



The number of Automatic Tie Points (ATPs) per pixel averaged over all images of the camera model is color coded between black and white. White indicates that, in average, more than 16 ATPs are extracted at this pixel location. Black indicates that, in average, 0 ATP has been extracted at this pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization.

? Internal Camera Parameters

Sequoia_4.0_1280x960 (Red). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]

EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.007344	-0.142578	0.000000	1662.44	0.00	0.00	1662.44	633.39	514.40
Optimized Values	0.000000	1.000000	0.006825	-0.180556	0.000000	1694.53	0.00	0.00	1694.53	632.82	517.54




The number of Automatic Tie Points (ATPs) per pixel averaged over all images of the camera model is color coded between black and white. White indicates that, in average, more than 16 ATPs are extracted at this pixel location. Black indicates that, in average, 0 ATP has been extracted at this pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization.

? Internal Camera Parameters

Sequoia_4.0_1280x960 (Red edge). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]

EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.002736	-0.131955	0.000000	1661.90	0.00	0.00	1661.90	647.50	515.21
Optimized Values	0.000000	1.000000	0.006456	-0.176784	0.000000	1692.65	0.00	0.00	1692.65	646.34	516.88



The number of Automatic Tie Points (ATPs) per pixel averaged over all images of the camera model is color coded between black and white. White indicates that, in average, more than 16 ATPs are extracted at this pixel location. Black indicates that, in average, 0 ATP has been extracted at this pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization.

Internal Camera Parameters

Sequoia_4.0_1280x960 (NIR). Sensor Dimensions: 4.800 [mm] x 3.600 [mm]

EXIF ID: Sequoia_4.0_1280x960

	Poly[0]	Poly[1]	Poly[2]	Poly[3]	Poly[4]	c	d	e	f	Principal Point x	Principal Point y
Initial Values	0.000000	1.000000	0.006322	-0.140429	0.000000	1664.14	0.00	0.00	1664.14	646.67	516.20
Optimized Values	0.000000	1.000000	0.004251	-0.174749	0.000000	1695.33	0.00	0.00	1695.33	646.90	519.26



The number of Automatic Tie Points (ATPs) per pixel averaged over all images of the camera model is color coded between black and white. White indicates that, in average, more than 16 ATPs are extracted at this pixel location. Black indicates that, in average, 0 ATP has been extracted at this pixel location. Click on the image to see the average direction and magnitude of the reprojection error for each pixel. Note that the vectors are scaled for better visualization.

Camera Rig «Sequoia» Relatives. Images: 3044

	Transl X [m]	Transl Y [m]	Transl Z [m]	Rot X [degree]	Rot Y [degree]	Rot Z [degree]
Sequoia_4.0_1280x960 (Green)	Reference Camera					
Sequoia_4.0_1280x960 (Red)						
Initial Values	0.000	-0.015	0.000	-0.702	-0.234	0.020
Optimized values	0.000	-0.015	0.000	-0.690	-0.081	0.028
Sequoia_4.0_1280x960 (Red edge)						
Initial Values	0.015	0.000	0.000	-0.029	-0.227	-0.084
Optimized values	0.015	0.000	0.000	-0.023	0.038	-0.083
Sequoia_4.0_1280x960 (NIR)						
Initial Values	0.015	-0.015	0.000	-0.519	-0.304	-0.067
Optimized values	0.015	-0.015	0.000	-0.534	-0.142	-0.060

2D Keypoints Table

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	9386	4633
Min	7379	178
Max	10000	7468
Mean	9353	4574

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Green)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	9478	4789
Min	7889	1262
Max	10000	7468
Mean	9456	4848

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	8662	2600
Min	7573	178

Max	9549	5590
Mean	8661	2614

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (Red edge)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	9029	4074
Min	7379	1822
Max	9995	7282
Mean	9041	4188

2D Keypoints Table for Camera Sequoia_4.0_1280x960 (NIR)

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	9277	4224
Min	8345	763
Max	10000	6583
Mean	9341	4214

Median / 75% / Maximal Number of Matches Between Camera Models

	Sequoia_4.0_1...(Green)	Sequoia_4.0_128...(Red)	Sequoia_4....(Red edge)	Sequoia_4.0_128...(NIR)
Sequoia_4.0_1280x960 (Green)	34 / 182 / 5554	8 / 25 / 1287	35 / 144 / 2566	31 / 124 / 3049
Sequoia_4.0_1280x960 (Red)		65 / 532 / 4630	14 / 33 / 646	11 / 28 / 234
Sequoia_4.0_1280x960 (Red edge)			101 / 654 / 5539	114 / 463 / 3482
Sequoia_4.0_1280x960 (NIR)				96 / 505 / 5126

3D Points from 2D Keypoint Matches

	Number of 3D Points Observed
In 2 Images	960410
In 3 Images	270908
In 4 Images	123117
In 5 Images	59923
In 6 Images	35466
In 7 Images	22302
In 8 Images	14473
In 9 Images	9636
In 10 Images	6958
In 11 Images	5110
In 12 Images	3947
In 13 Images	2920
In 14 Images	2286
In 15 Images	1905
In 16 Images	1542
In 17 Images	1252
In 18 Images	1009
In 19 Images	778
In 20 Images	654
In 21 Images	563
In 22 Images	405
In 23 Images	375
In 24 Images	311
In 25 Images	267
In 26 Images	214

In 27 Images	198
In 28 Images	145
In 29 Images	118
In 30 Images	96
In 31 Images	80
In 32 Images	69
In 33 Images	40
In 34 Images	44
In 35 Images	29
In 36 Images	28
In 37 Images	23
In 38 Images	8
In 39 Images	14
In 40 Images	7
In 41 Images	3
In 42 Images	2
In 43 Images	5
In 44 Images	2
In 47 Images	1
In 48 Images	1

? 2D Keypoint Matches




Figure 5: Computed image positions with links between matched images. The darkness of the links indicates the number of matched 2D keypoints between the images. Bright links indicate weak links and require manual tie points or more images.

Geolocation Details

? Absolute Geolocation Variance

Min Error [m]	Max Error [m]	Geolocation Error X [%]	Geolocation Error Y [%]	Geolocation Error Z [%]
-	-2.38	0.00	0.00	0.00
-2.38	-1.91	0.00	1.28	0.13
-1.91	-1.43	0.85	4.60	1.58
-1.43	-0.95	8.38	9.89	8.80
-0.95	-0.48	12.68	12.35	14.98
-0.48	0.00	28.35	6.41	18.56
0.00	0.48	21.39	30.55	27.92
0.48	0.95	18.63	28.55	20.11
0.95	1.43	9.59	6.37	5.81
1.43	1.91	0.13	0.00	2.10
1.91	2.38	0.00	0.00	0.00
2.38	-	0.00	0.00	0.00
Mean [m]		0.024985	0.034984	0.024181
Sigma [m]		0.668670	0.794242	0.712037
RMS Error [m]		0.669137	0.795012	0.712447

Min Error and Max Error represent geolocation error intervals between -1.5 and 1.5 times the maximum accuracy of all the images. Columns X, Y, Z show the percentage of images with geolocation errors within the predefined error intervals. The geolocation error is the difference between the initial and computed image positions. Note that the image geolocation errors do not correspond to the accuracy of the observed 3D points.

? Relative Geolocation Variance

Relative Geolocation Error	Images X [%]	Images Y [%]	Images Z [%]
[-1.00, 1.00]	73.32	74.51	93.69
[-2.00, 2.00]	100.00	97.63	100.00
[-3.00, 3.00]	100.00	100.00	100.00
Mean of Geolocation Accuracy [m]	0.891343	0.891343	1.359507
Sigma of Geolocation Accuracy [m]	0.068042	0.068042	0.116941

Images X, Y, Z represent the percentage of images with a relative geolocation error in X, Y, Z.

Geolocation Orientational Variance	RMS [degree]
Omega	21.592
Phi	13.393
Kappa	22.186

Geolocation RMS error of the orientation angles given by the difference between the initial and computed image orientation angles.

Initial Processing Details

System Information

Hardware	CPU: Intel(R) Core(TM) i7-9750H CPU @ 2.60GHz RAM: 16GB GPU: no info (Driver: unknown)
Operating System	Darwin 21.1.0 x86_64

Coordinate Systems

Image Coordinate System	WGS84 (egm96)
Output Coordinate System	WGS84 / UTM zone 48N (egm96)

Processing Options

Detected Template	No Template Available
Keypoints Image Scale	Rapid, Image Scale: 1
Advanced: Matching Image Pairs	Aerial Grid or Corridor
Advanced: Matching Strategy	Use Geometrically Verified Matching: yes
Advanced: Keypoint Extraction	Targeted Number of Keypoints: Custom, Number of Keypoints: 10000
Advanced: Calibration	Calibration Method: Alternative Internal Parameters Optimization: All External Parameters Optimization: All Rematch: Custom, yes Bundle Adjustment: Classic
Rig «Sequoia» processing	optimize relative rotation using a subset of secondary cameras

Point Cloud Densification details

Processing Options

Image Scale	multiscale, 1/4 (Quarter image size, Fast)
Point Density	Low (Fast)
Minimum Number of Matches	3
3D Textured Mesh Generation	no
Advanced: Matching Window Size	7x7 pixels
Advanced: Image Groups	Green, NIR, Red, Red edge
Advanced: Use Processing Area	yes
Advanced: Use Annotations	yes
Advanced: Limit Camera Depth Automatically	no
Time for Point Cloud Densification	02m:20s

Results

Number of Generated Tiles	1
Number of 3D Densified Points	363553
Average Density (per m ³)	15.9

DSM, Orthomosaic and Index Details

Processing Options

DSM and Orthomosaic Resolution	1 x GSD (3.09 [cm/pixel])
DSM Filters	Noise Filtering: yes Surface Smoothing: yes, Type: Sharp
Index Calculator: Reflectance Map	Generated: yes Resolution: 1 x GSD (3.09 [cm/pixel]) Merge Tiles: no
Index Calculator: Indices	ndvi

Index Calculator: Index Values	Polygon Shapefile [cm/grid]: 400
Time for Reflectance Map Generation	35m:02s
Time for Index Map Generation	02m:17s

Camera Radiometric Correction



Camera Name	Band	Radiometric Correction Type
Sequoia_4.0_1280x960	Green	Camera and Sun Irradiance
Sequoia_4.0_1280x960	Red	Camera and Sun Irradiance
Sequoia_4.0_1280x960	Red edge	Camera and Sun Irradiance
Sequoia_4.0_1280x960	NIR	Camera and Sun Irradiance



The logo of Sakon Nakhon Rajabhat University is a large, faint watermark in the background. It features a golden-yellow bell-shaped structure with a central figure of a person sitting on a throne. Below the figure is a circular emblem with a book and a torch. The entire logo is encircled by a red and white decorative border.


ภาคผนวก ง

การคำนวณดัชนีพืชพรรณด้วยซอฟต์แวร์ QGIS

มหาวิทยาลัยเทคโนโลยีสุรนารี


ในการคำนวณค่าดัชนีพืชพรรณด้วยภาพถ่ายจากกล้อง RGB นั้นสามารถทำได้โดยใช้ซอฟต์แวร์ช่วยในการคำนวณ สำหรับการศึกษานี้จะคำนวณดัชนีพืชพรรณ GRVI และ ExG โดยตัวอย่างการคำนวณดัชนีพืชพรรณ ExG โดยใช้ซอฟต์แวร์ QGIS มีขั้นตอน ดังต่อไปนี้

(1) เปิดซอฟต์แวร์ QGIS




รูปที่ ง.1 หน้าต่างเริ่มต้นของซอฟต์แวร์ QGIS

(2) นำเข้าข้อมูลไฟล์ภาพถ่ายแผนที่ความละเอียดสูงนามสกุล .tiff ในที่นี้คือไฟล์ M1-clip-cassava.tiff โดยการลากจากที่เก็บไฟล์แล้ววางบนหน้าต่างของ QGIS หรือไปที่ Layer > Add Layer > Add Raster Layer...



รูปที่ ง.2 การนำเข้าไฟล์ .tiff

(3) ไปที่เมนู Raster > Raster Calculator ...




รูปที่ ง.3 คำสั่ง Raster Calculator

(4) ทำการระบุสูตรคำนวณหาค่า ExG จากสมการในรูป โดยที่จะปรากฏในหน้าต่าง 4 ช่วงคลื่น (Band) ได้แก่ สีแดง (Red), สีเขียว (Green), สีน้ำเงิน (Blue) และค่าเฉดสีเทา (Gray scale) โดยที่ M1-clip-cassava คือชื่อไฟล์ และ ตัวเลขหลัง @ คือหมายเลขช่วงคลื่น สูตรการคำนวณมีดังนี้


$$2 * ("M1-clip-cassava@2" / ("M1-clip-cassava@1" + "M1-clip-cassava@2" + "M1-clip-cassava@3")) - ("M1-clip-cassava@1" / ("M1-clip-cassava@1" + "M1-clip-cassava@2" + "M1-clip-cassava@3")) - ("M1-clip-cassava@3" / ("M1-clip-cassava@1" + "M1-clip-cassava@2" + "M1-clip-cassava@3"))$$

(5) ตั้งชื่อไฟล์ที่ Output layer “M1-ExG” เลือกตำแหน่งที่เก็บไฟล์ และเลือก Output format เป็น GeoTIFF แล้วคลิก OK




รูปที่ ง.4 การคำนวณค่าดัชนีพืชพรรณ ExG

(6) รวบรวมผลการประมวลผลจนสำเร็จ ผลที่ได้จะได้ไฟล์ราสเตอร์ของดัชนีพืชพรรณ ExG




รูปที่ ง.5 แผนที่ความละเอียดสูงของดัชนีพืชพรรณ ExG

(7) ทำการปรับแต่งสีของข้อมูลเพื่อทำการวิเคราะห์ โดยคลิกขวาที่ชั้นข้อมูล เลือก Properties...




รูปที่ ง.6 เลือกชุดคำสั่ง Properties

(8) เลือกแถบเมนู Symbology > เลือกรูปแบบ Render type เป็น Singleband pseudocolor จากนั้นกำหนด Min/Max Value setting ที่ Mean $\pm$ standard deviation X กรอกค่า 2.00 สามารถแบ่งคลาสได้โดยการเปลี่ยนการประมาณค่าเชิงพื้นที่ (Interpolation) จาก Linear เป็น Discrete และยังสามารถกำหนดช่วงของสีเพื่อแบ่งคลาสตามต้องการได้




รูปที่ ง.7 การผสมสีแบบ Singleband pseudocolor

(8.1) เลือก Interpolation แบบ Linear โดยแสดงค่าแถบสีตามค่าของดัชนีพืชพรรณ




รูปที่ ๓.๘ การประมาณค่าเชิงพื้นที่แบบ Linear

(๘.๒) การแบ่งคลาสโดยใช้ค่าของดัชนีออกเป็น 5 คลาส โดยการเปลี่ยน Interpolation เป็น Discrete



รูปที่ ๓.๙ การประมาณค่าเชิงพื้นที่แบบ Discrete



รูปที่ ง.10 การประมาณค่าเชิงพื้นที่แบบ Linear




รูปที่ ง.11 การประมาณค่าเชิงพื้นที่แบบ Discrete

(9) ทำการตัดค่าส่วนที่เป็นพืช โดยจะเลือกค่าขีดแบ่ง (Threshold) เท่ากับ 0.1 เพื่อจำแนกเฉพาะส่วนที่เป็นพืชพรรณ ดัชนีพืชพรรณแต่ละชนิดจะกำหนดค่าขีดแบ่งที่ต่างกันแสดงดังตารางที่ ง. 1 โดยไปที่เมนู Raster > Raster Calculator... ทำการระบุสูตร เลือกที่เก็บผลลัพธ์ และตั้งชื่อไฟล์ จากนั้นคลิก OK

สูตรที่ใช้คือ

"M1-ExG@1" > 0.1




รูปที่ ง.12 การกำหนดค่าขีดแบ่ง

ตารางที่ ง.1 การกำหนดค่าขีดแบ่งของดัชนีพืชพรรณ

ดัชนีพืชพรรณ	ค่าขีดแบ่ง	อ้างอิง
NDVI	0.4	Hashim, Latif and Adnam (2019) Motohka, Nasahara and Hiroyuki (2010)
ExG	0.1	ชิงชัย ทุมห้อง (2563) Kim, Yun, Jeong et al. (2018)
GRVI	-0.1	Motohka, Nasahara and Hiroyuki (2010)

(10) ผลลัพธ์ที่ได้จะตัดเอาไว้เฉพาะส่วนที่เป็นพืช จะได้ไฟล์ M1-ExG-vegetation.tiff




รูปที่ ง.13 แผนที่ภายหลังจากกำหนดค่าขีดแบ่ง




รูปที่ ง.14 รายละเอียดแผนที่ภายหลังจากกำหนดค่าขีดแบ่ง

(11) ต้องการตัดเอาเฉพาะพืช ให้คลิกขวาที่ layer: M1-ExG-vegetation.tiff เลือก Properties > Symbology เลือก Render type เป็น Paletted/Unique values แล้วกด Classify




รูปที่ ง.15 การตัดเอาเฉพาะส่วนที่เป็นพืช

(12) ผลลัพธ์จากการ Classify จะได้ 2 คลาส ให้ลบ Class 0 ออก




รูปที่ ง.16 ผลลัพธ์การตัดเอาเฉพาะพืช

(13) จะได้ผลลัพธ์ที่ผ่านการผสมสีและนำไปรวมกับราสเตอร์ M1-ExG.tiff ดังรูป




รูปที่ ง.17 แผนที่ความละเอียดสูงของพืชพรรณ

(14) หากต้องการดูค่าดัชนีในแต่ละจุดที่ทำการเก็บข้อมูล สามารถดูได้โดยการใช้ปุ่ม Identify Feature ที่แถบเมนูด้านบน



รูปที่ ง.18 คำสั่งเลือกดูค่าดัชนีพืชพรรณรายจุด

(15) คลิกในบริเวณที่ต้องการจะได้ค่าดัชนีพืชพรรณในแต่ละจุด



รูปที่ ง.19 ค่าดัชนีพืชพรรณรายจุด



ภาคผนวก จ

ตารางชุดข้อมูลในงานวิจัย

ตารางที่ จ.1 ชุดข้อมูลในงานวิจัย

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
1	1	1	0.2613	0.1410	0.4587	3.26	25.5
1	1	2	0.2552	0.1609	0.4511	3.42	25.5
1	1	3	0.2507	0.1663	0.4805	3.44	26.7
1	1	4	0.2507	0.1594	0.4887	3.43	26.3
1	1	5	0.2574	0.1613	0.4993	3.58	25.7
1	1	6	0.2554	0.1688	0.4608	3.64	26.5
1	1	7	0.2576	0.1585	0.4533	3.63	25.5
1	1	8	0.2506	0.1558	0.4799	3.59	26.0
1	1	9	0.2563	0.1615	0.4969	3.43	26.9
1	1	10	0.2537	0.1621	0.4993	3.57	26.0
1	2	1	0.2568	0.1380	0.5032	3.98	27.5
1	2	2	0.2587	0.1429	0.5258	3.75	27.7
1	2	3	0.2578	0.1443	0.5263	3.36	27.9
1	2	4	0.2546	0.1592	0.5049	3.39	27.6
1	2	5	0.2516	0.1445	0.5366	3.31	28.6
1	2	6	0.2541	0.1583	0.5078	3.73	28.9
1	2	7	0.2548	0.1413	0.5316	3.96	27.7
1	2	8	0.2520	0.1579	0.5019	3.99	28.4
1	2	9	0.2550	0.1582	0.5444	3.24	28.6
1	2	10	0.2596	0.1527	0.5443	3.63	27.6
1	3	1	0.3038	0.1423	0.6225	4.22	29.0
1	3	2	0.2883	0.1453	0.6035	3.88	26.1
1	3	3	0.2889	0.1499	0.6136	4.10	28.8
1	3	4	0.2970	0.1433	0.6079	3.85	28.7
1	3	5	0.2788	0.1477	0.6184	3.82	28.5
1	3	6	0.2856	0.1439	0.6019	3.78	28.1
1	3	7	0.2930	0.1446	0.6069	3.82	28.7

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
1	3	8	0.2990	0.1431	0.6010	4.18	28.8
1	3	9	0.2712	0.1464	0.6064	3.59	29.0
1	3	10	0.2717	0.1429	0.6120	3.69	28.2
1	4	1	0.2712	0.1508	0.6174	4.13	28.6
1	4	2	0.2758	0.1357	0.6124	3.86	27.0
1	4	3	0.2779	0.1417	0.6150	4.13	25.1
1	4	4	0.2894	0.1368	0.6046	3.92	27.5
1	4	5	0.2942	0.1401	0.6123	4.13	27.2
1	4	6	0.2902	0.1356	0.6044	4.19	26.4
1	4	7	0.2907	0.1370	0.6139	4.19	26.4
1	4	8	0.2932	0.1453	0.6080	3.94	26.8
1	4	9	0.2819	0.1426	0.6247	3.89	25.6
1	4	10	0.2927	0.1457	0.6097	4.02	26.8
1	5	1	0.2906	0.1326	0.5072	2.87	24.7
1	5	2	0.2771	0.1442	0.5092	3.27	27.8
1	5	3	0.2778	0.1486	0.5171	3.64	25.0
1	5	4	0.2763	0.1302	0.5112	3.41	27.3
1	5	5	0.2830	0.1344	0.5263	2.90	24.2
1	5	6	0.2840	0.1383	0.5098	3.42	26.2
1	5	7	0.2834	0.1473	0.5453	2.91	24.2
1	5	8	0.2767	0.1485	0.5478	3.49	25.6
1	5	9	0.2960	0.1466	0.5288	3.46	26.0
1	5	10	0.2954	0.1449	0.5206	2.87	26.4
1	6	1	0.3170	0.1449	0.6100	4.45	28.6
1	6	2	0.3062	0.1339	0.6084	4.41	26.2
1	6	3	0.3148	0.1365	0.6060	4.47	27.3
1	6	4	0.3165	0.1403	0.6183	4.45	26.0
1	6	5	0.3016	0.1580	0.6234	4.44	27.7

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
1	6	6	0.2839	0.1520	0.6104	4.35	26.5
1	6	7	0.2905	0.1393	0.6102	4.34	26.3
1	6	8	0.3003	0.1505	0.6080	4.31	26.7
1	6	9	0.3086	0.1575	0.6212	4.48	27.5
1	6	10	0.2920	0.1424	0.6234	4.44	27.3
1	7	1	0.2029	0.1467	0.6076	4.48	27.4
1	7	2	0.2452	0.1441	0.6172	4.40	26.9
1	7	3	0.2213	0.1539	0.6200	4.32	26.2
1	7	4	0.2064	0.1463	0.6027	4.32	27.4
1	7	5	0.2228	0.1349	0.6246	4.33	27.0
1	7	6	0.2097	0.1470	0.6093	4.33	26.7
1	7	7	0.2120	0.1505	0.6239	4.35	26.7
1	7	8	0.2475	0.1597	0.6021	4.32	26.7
1	7	9	0.2316	0.1327	0.6159	4.33	26.1
1	7	10	0.2303	0.1384	0.6246	4.39	27.0
1	8	1	0.2742	0.1288	0.5031	3.46	27
1	8	2	0.2689	0.1409	0.5230	3.34	27.2
1	8	3	0.2506	0.1239	0.5083	3.48	27.5
1	8	4	0.2764	0.1540	0.5137	3.45	27.9
1	8	5	0.2613	0.1510	0.5088	3.31	27.9
1	8	6	0.2660	0.1238	0.5484	3.34	27.7
1	8	7	0.2543	0.1397	0.5005	3.45	27.9
1	8	8	0.2614	0.1473	0.5271	3.46	27.5
1	8	9	0.2700	0.1577	0.5237	3.37	27.2
1	8	10	0.2612	0.1538	0.5453	3.36	27.5
1	9	1	0.2625	0.1411	0.4119	2.08	28.1
1	9	2	0.2521	0.1368	0.4087	2.48	29.0
1	9	3	0.2587	0.1492	0.4125	2.56	28.1

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
1	9	4	0.2549	0.1286	0.4366	2.51	28.3
1	9	5	0.2702	0.1289	0.4374	2.56	29.8
1	9	6	0.2773	0.1468	0.4195	2.46	28.1
1	9	7	0.2766	0.1510	0.4407	2.12	28.3
1	9	8	0.2769	0.1469	0.4201	2.76	29.1
1	9	9	0.2742	0.1256	0.4282	2.75	28.8
1	9	10	0.2652	0.1262	0.4127	2.29	28.1
1	10	1	0.1730	0.1191	0.4093	2.18	29.5
1	10	2	0.1786	0.1193	0.4382	2.02	28.5
1	10	3	0.1529	0.1116	0.4362	2.78	28.1
1	10	4	0.1737	0.1141	0.4032	2.38	29.2
1	10	5	0.1546	0.1136	0.4497	2.79	28.7
1	10	6	0.1625	0.1192	0.4027	2.33	28.4
1	10	7	0.1792	0.1054	0.4450	2.36	29.9
1	10	8	0.1748	0.1134	0.4154	2.38	29.9
1	10	9	0.1678	0.1118	0.4062	2.13	28.2
1	10	10	0.1538	0.1143	0.4472	2.38	28.9
1	11	1	0.1632	0.1070	0.4499	2.32	29.5
1	11	2	0.1667	0.1200	0.4060	2.16	28.7
1	11	3	0.1637	0.1156	0.4004	2.56	29.0
1	11	4	0.1527	0.1133	0.4298	2.14	28.9
1	11	5	0.1784	0.1036	0.4272	2.32	29.6
1	11	6	0.1597	0.1135	0.4248	2.24	28.9
1	11	7	0.1559	0.1016	0.4132	2.23	28.8
1	11	8	0.1750	0.1079	0.4229	2.52	28.0
1	11	9	0.1596	0.1031	0.4458	2.38	29.3
1	11	10	0.1525	0.1051	0.4481	2.56	29.5
1	12	1	0.1569	0.1189	0.4680	2.9	28.9

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
1	12	2	0.1694	0.1169	0.4652	2.71	29.6
1	12	3	0.1528	0.1001	0.4897	2.82	29.8
1	12	4	0.1505	0.1069	0.4873	2.75	29.0
1	12	5	0.1756	0.1148	0.4871	2.79	29.8
1	12	6	0.1711	0.1032	0.4920	3.00	28.2
1	12	7	0.1550	0.1049	0.4607	2.93	29.1
1	12	8	0.1670	0.1163	0.4946	2.73	29.0
1	12	9	0.1799	0.1110	0.4767	2.86	29.6
1	12	10	0.1686	0.1129	0.4633	2.71	28.1
2	1	1	0.0592	0.0213	0.3050	1.03	32
2	1	2	0.0869	0.0578	0.3305	1.34	32.4
2	1	3	0.0730	0.0437	0.3009	1.41	31.8
2	1	4	0.0875	0.0293	0.3044	1.37	31.4
2	1	5	0.0626	0.0582	0.3412	1.25	31.2
2	1	6	0.0763	0.0395	0.3042	1.20	31.2
2	1	7	0.0581	0.0539	0.3393	1.28	31.8
2	1	8	0.0646	0.0266	0.3389	1.28	31.5
2	1	9	0.0882	0.0361	0.3014	1.48	32.0
2	1	10	0.0845	0.0625	0.3497	1.17	32.3
2	2	1	0.0501	0.0562	0.3124	1.16	32.3
2	2	2	0.0544	0.0280	0.3074	1.48	32.0
2	2	3	0.0786	0.0423	0.3092	1.20	32.4
2	2	4	0.0517	0.0461	0.3307	1.31	31.9
2	2	5	0.0557	0.0433	0.3326	1.42	31.5
2	2	6	0.0683	0.0451	0.3189	1.44	31.8
2	2	7	0.0539	0.0321	0.3184	1.48	31.2
2	2	8	0.0547	0.0467	0.3319	1.33	32.4
2	2	9	0.0556	0.0207	0.3083	1.40	32.1

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
2	2	10	0.0727	0.0346	0.3269	1.15	31.2
2	3	1	0.0531	0.0307	0.3897	1.20	32.5
2	3	2	0.0640	0.0359	0.3787	1.29	31.1
2	3	3	0.0731	0.0300	0.3731	1.15	31.7
2	3	4	0.0772	0.0397	0.3623	1.10	32.0
2	3	5	0.0516	0.0638	0.3976	1.39	32.1
2	3	6	0.0600	0.0268	0.3896	1.47	31.7
2	3	7	0.0659	0.0387	0.3986	1.22	31.8
2	3	8	0.0648	0.0448	0.3892	1.12	31.5
2	3	9	0.0891	0.0302	0.3871	1.39	31.6
2	3	10	0.0862	0.0649	0.3651	1.39	31.6
2	4	1	0.0713	0.0590	0.3945	1.86	31.6
2	4	2	0.0679	0.0646	0.3857	1.61	31.8
2	4	3	0.0551	0.0329	0.3735	1.38	31.2
2	4	4	0.0756	0.0561	0.3810	1.76	31.2
2	4	5	0.0776	0.0368	0.3682	1.72	32.0
2	4	6	0.0710	0.0412	0.3634	1.88	32.3
2	4	7	0.0663	0.0571	0.3511	1.39	31.9
2	4	8	0.0782	0.0224	0.3802	1.71	32.3
2	4	9	0.0659	0.0377	0.3792	1.79	31.6
2	4	10	0.0871	0.0609	0.3994	1.70	31.8
2	5	1	0.0855	0.0546	0.3931	1.27	31.8
2	5	2	0.0819	0.0494	0.3617	1.75	31.1
2	5	3	0.0846	0.0648	0.3876	1.39	31.4
2	5	4	0.0855	0.0583	0.3794	1.63	31.8
2	5	5	0.0645	0.0255	0.3630	1.46	32.2
2	5	6	0.0805	0.0239	0.3744	1.42	31.6
2	5	7	0.0707	0.0598	0.3934	1.34	31.9

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
2	5	8	0.0820	0.0413	0.3873	1.81	32.2
2	5	9	0.0587	0.0595	0.3612	1.74	31.1
2	5	10	0.0639	0.0228	0.3938	1.67	32.4
2	6	1	0.0793	0.0500	0.3884	1.38	31.1
2	6	2	0.0854	0.0577	0.3517	1.87	32.2
2	6	3	0.0730	0.0338	0.3721	1.69	31.1
2	6	4	0.0872	0.0647	0.3785	1.48	32.4
2	6	5	0.0877	0.0364	0.3686	1.49	31.9
2	6	6	0.0598	0.0302	0.3823	1.84	32.2
2	6	7	0.0611	0.0268	0.3870	1.60	31.2
2	6	8	0.0813	0.0503	0.3691	1.49	31.3
2	6	9	0.0729	0.0275	0.3986	1.37	31.3
2	6	10	0.0843	0.0262	0.3669	1.65	32.1
2	7	1	0.0573	0.0537	0.3913	1.26	31.0
2	7	2	0.0786	0.0577	0.3757	1.45	31.4
2	7	3	0.0746	0.0542	0.3554	1.73	31.1
2	7	4	0.0553	0.0428	0.3905	1.30	31.9
2	7	5	0.0626	0.0470	0.3729	1.79	31.4
2	7	6	0.0531	0.0504	0.3827	1.48	32.4
2	7	7	0.0721	0.0433	0.3946	1.77	31.9
2	7	8	0.0549	0.0238	0.3957	1.77	32.3
2	7	9	0.0667	0.0349	0.3921	1.69	31.3
2	7	10	0.0783	0.0598	0.3611	1.22	31.6
2	8	1	0.1454	0.0515	0.4795	2.72	31
2	8	2	0.1423	0.0540	0.4907	2.46	31.1
2	8	3	0.1377	0.0549	0.4846	2.68	30.9
2	8	4	0.0904	0.0489	0.4793	2.18	29.0
2	8	5	0.1763	0.0508	0.4873	2.54	29.4

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
2	8	6	0.0822	0.0278	0.4889	2.19	29.8
2	8	7	0.1697	0.0280	0.4861	2.31	29.4
2	8	8	0.1775	0.0330	0.4751	2.58	30.6
2	8	9	0.1566	0.0256	0.4630	2.65	30.3
2	8	10	0.1753	0.0592	0.4804	2.19	29.1
2	9	1	0.1108	0.0421	0.4997	2.30	31.2
2	9	2	0.1507	0.0562	0.4822	2.69	31.1
2	9	3	0.1343	0.0498	0.4661	2.08	30.2
2	9	4	0.1231	0.0317	0.4971	2.46	31.7
2	9	5	0.1709	0.0432	0.4540	2.63	31.3
2	9	6	0.0885	0.0223	0.4805	2.32	30.0
2	9	7	0.1197	0.0392	0.4614	2.11	29.7
2	9	8	0.0983	0.0324	0.4682	2.16	31.6
2	9	9	0.0938	0.0237	0.4580	2.43	31.9
2	9	10	0.0846	0.0528	0.4574	2.49	30.7
2	10	1	0.0936	0.0546	0.4961	2.29	30.0
2	10	2	0.1764	0.0273	0.4915	2.25	30.9
2	10	3	0.1657	0.0469	0.4604	2.62	30.5
2	10	4	0.0983	0.0399	0.4787	2.63	31.8
2	10	5	0.1378	0.0313	0.4926	2.08	30.9
2	10	6	0.1162	0.0301	0.4830	2.15	31.3
2	10	7	0.1700	0.0622	0.4705	2.40	29.1
2	10	8	0.0932	0.0458	0.4765	2.30	29.1
2	10	9	0.1690	0.0249	0.4769	2.48	31.7
2	10	10	0.1708	0.0238	0.4713	2.12	30.3
2	11	1	0.1693	0.0629	0.4561	2.50	29.3
2	11	2	0.1390	0.0296	0.4871	2.09	31.9
2	11	3	0.1006	0.0592	0.4675	2.27	31.9

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
2	11	4	0.1747	0.0473	0.4535	2.38	31.2
2	11	5	0.1306	0.0299	0.4605	2.07	29.3
2	11	6	0.1147	0.0311	0.4694	2.51	31.4
2	11	7	0.1339	0.0356	0.4933	2.32	30.4
2	11	8	0.1059	0.0606	0.4504	2.66	29.3
2	11	9	0.1580	0.0603	0.4750	2.54	31.2
2	11	10	0.0820	0.0213	0.4848	2.28	31.2
2	12	1	0.1357	0.0594	0.4783	2.31	31.7
2	12	2	0.1280	0.0341	0.4640	2.66	29.1
2	12	3	0.0956	0.0546	0.4767	2.62	30.9
2	12	4	0.1773	0.0594	0.4797	2.21	31.4
2	12	5	0.1293	0.0486	0.4721	2.29	30.4
2	12	6	0.0943	0.0553	0.4641	2.32	31.2
2	12	7	0.0974	0.0604	0.4830	2.44	29.2
2	12	8	0.1751	0.0260	0.4821	2.28	31.7
2	12	9	0.0819	0.0240	0.4640	2.38	30.3
2	12	10	0.0927	0.0647	0.4807	2.54	31.9
3	1	1	0.1731	0.0586	0.4582	2.72	31.9
3	1	2	0.1233	0.0598	0.4571	2.74	30.5
3	1	3	0.1461	0.0558	0.4685	2.65	30.2
3	1	4	0.1143	0.0564	0.4637	2.82	29.4
3	1	5	0.1707	0.0597	0.4808	2.83	29.6
3	1	6	0.1020	0.0551	0.4715	2.70	29.7
3	1	7	0.1115	0.0553	0.4502	2.80	29.9
3	1	8	0.1585	0.0566	0.4659	2.74	30.9
3	1	9	0.0970	0.0569	0.4641	2.75	31.6
3	1	10	0.1258	0.0600	0.4691	2.68	29.0
3	2	1	0.1206	0.0555	0.4743	2.71	29.4

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
3	2	2	0.1287	0.0562	0.5000	2.75	29.6
3	2	3	0.1139	0.0599	0.4544	2.68	30.8
3	2	4	0.0846	0.0551	0.4646	2.83	29.3
3	2	5	0.0885	0.0579	0.4972	2.75	31.8
3	2	6	0.1288	0.0586	0.4663	2.83	31.8
3	2	7	0.1677	0.0595	0.4602	2.69	30.1
3	2	8	0.1293	0.0566	0.4948	2.67	30.2
3	2	9	0.1690	0.0572	0.4611	2.66	29.8
3	2	10	0.1525	0.0592	0.4906	2.74	29.1
3	3	1	0.1309	0.0555	0.4937	2.73	30.6
3	3	2	0.1591	0.0586	0.4780	2.75	29.6
3	3	3	0.1214	0.0550	0.4746	2.76	29.5
3	3	4	0.0912	0.0556	0.4898	2.77	30.3
3	3	5	0.1085	0.0567	0.4842	2.71	29.5
3	3	6	0.1673	0.0567	0.4557	2.68	29.3
3	3	7	0.1393	0.0575	0.4858	2.76	31.0
3	3	8	0.1093	0.0553	0.4968	2.75	31.1
3	3	9	0.1653	0.0598	0.4641	2.70	29.6
3	3	10	0.1644	0.0573	0.4565	2.66	31.4
3	4	1	0.1227	0.0599	0.4880	2.65	30.7
3	4	2	0.1081	0.0595	0.4627	2.77	29.3
3	4	3	0.1123	0.0594	0.4689	2.71	31.9
3	4	4	0.1074	0.0587	0.4592	2.81	31.1
3	4	5	0.1081	0.0551	0.4929	2.80	31.3
3	4	6	0.1198	0.0595	0.4539	2.81	30.2
3	4	7	0.1401	0.0567	0.4700	2.78	30.7
3	4	8	0.1776	0.0597	0.4916	2.81	30.6
3	4	9	0.1071	0.0554	0.4536	2.66	30.8

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
3	4	10	0.0997	0.0563	0.4828	2.76	31.5
3	5	1	0.2034	0.1349	0.4953	3	32
3	5	2	0.1350	0.0853	0.5020	3.06	31.9
3	5	3	0.1383	0.1098	0.5195	3.04	30.5
3	5	4	0.0898	0.0898	0.4938	3.14	32.4
3	5	5	0.1892	0.0775	0.4865	3.12	31.5
3	5	6	0.1328	0.1028	0.5222	3.23	32.5
3	5	7	0.1479	0.0755	0.4865	2.95	31.2
3	5	8	0.0900	0.0811	0.5091	3.20	30.1
3	5	9	0.1352	0.0976	0.5108	3.23	32.4
3	5	10	0.1148	0.1168	0.5130	3.29	31.1
3	6	1	0.2181	0.1314	0.5039	2.94	31.3
3	6	2	0.2981	0.1430	0.5226	3.13	30.4
3	6	3	0.2828	0.1431	0.4944	3.07	32.3
3	6	4	0.2927	0.1442	0.4882	3.17	31.9
3	6	5	0.2892	0.1375	0.4993	3.29	31.2
3	6	6	0.2855	0.1364	0.5222	3.23	30.1
3	6	7	0.2908	0.1495	0.5012	2.99	30.0
3	6	8	0.2906	0.1360	0.5220	2.95	31.9
3	6	9	0.2848	0.1351	0.4861	2.99	31.9
3	6	10	0.2843	0.1485	0.5164	2.96	31.6
3	7	1	0.2905	0.1462	0.4796	3.08	30.4
3	7	2	0.2939	0.1482	0.4722	2.94	31.2
3	7	3	0.2816	0.1467	0.4768	3.16	32.5
3	7	4	0.2896	0.1475	0.4960	3.12	31.9
3	7	5	0.2835	0.1405	0.4160	3.19	32.5
3	7	6	0.2916	0.1337	0.4988	3.27	31.3
3	7	7	0.2865	0.1488	0.4770	3.04	30.9

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
3	7	8	0.2941	0.1399	0.4000	3.02	31.2
3	7	9	0.2805	0.1314	0.4143	3.07	30.6
3	7	10	0.2934	0.1338	0.4651	3.30	30.4
3	8	1	0.2681	0.1315	0.4054	2.99	33
3	8	2	0.2780	0.1362	0.4658	2.95	32.6
3	8	3	0.2621	0.1420	0.4114	3.22	32.9
3	8	4	0.2649	0.1481	0.4580	3.12	30.2
3	8	5	0.2741	0.1457	0.4952	3.16	32.2
3	8	6	0.2698	0.1436	0.4277	3.28	32.4
3	8	7	0.2615	0.1473	0.4609	2.90	32.4
3	8	8	0.2668	0.1364	0.4460	3.15	30.2
3	8	9	0.2682	0.1434	0.4862	2.98	30.3
3	8	10	0.2640	0.1357	0.4508	3.19	30.1
3	9	1	0.0471	0.0639	0.4440	2	31.0
3	9	2	0.0546	0.0600	0.4038	2.33	31.6
3	9	3	0.0830	0.0509	0.4479	2.30	30.6
3	9	4	0.0698	0.0520	0.4410	2.01	32.4
3	9	5	0.0606	0.0608	0.4323	2.38	30.0
3	9	6	0.0814	0.0544	0.4447	2.39	30.8
3	9	7	0.0758	0.0575	0.4180	2.18	30.1
3	9	8	0.0512	0.0631	0.4393	2.37	33.0
3	9	9	0.0859	0.0548	0.4015	2.30	31.1
3	9	10	0.0656	0.0511	0.4298	2.01	32.7
3	10	1	0.0568	0.0505	0.4074	2.02	31.0
3	10	2	0.0647	0.0564	0.4044	2.48	30.5
3	10	3	0.0551	0.0505	0.4442	2.11	32.3
3	10	4	0.0701	0.0586	0.4041	2.38	31.2
3	10	5	0.0646	0.0592	0.4495	2.15	31.5

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
3	10	6	0.0504	0.0541	0.4273	2.01	30.6
3	10	7	0.0716	0.0550	0.4499	2.21	30.5
3	10	8	0.0672	0.0582	0.4326	2.22	30.8
3	10	9	0.0870	0.0554	0.4181	2.42	31.5
3	10	10	0.0801	0.0505	0.4083	2.32	30.9
3	11	1	0.0276	0.0252	0.3310	1.5	32.7
3	11	2	0.0249	0.0381	0.3470	1.55	31.6
3	11	3	0.0276	0.0200	0.3327	1.51	31.1
3	11	4	0.0439	0.0374	0.3272	1.53	32.6
3	11	5	0.0382	0.0367	0.3304	1.58	31.8
3	11	6	0.0334	0.0277	0.3278	1.79	31.7
3	11	7	0.0473	0.0392	0.3017	1.55	31.9
3	11	8	0.0479	0.0320	0.3040	1.55	32.0
3	11	9	0.0337	0.0379	0.3275	1.74	31.5
3	11	10	0.0249	0.0328	0.3061	1.76	32.3
3	12	1	0.0330	0.0341	0.3279	1.78	32.5
3	12	2	0.0490	0.0393	0.3137	1.65	32.2
3	12	3	0.0442	0.0390	0.3489	1.87	32.1
3	12	4	0.0248	0.0341	0.3477	1.72	33.0
3	12	5	0.0491	0.0228	0.3080	1.69	32.9
3	12	6	0.0252	0.0368	0.3423	1.82	31.7
3	12	7	0.0372	0.0215	0.3013	1.74	31.2
3	12	8	0.0313	0.0281	0.3331	1.54	32.1
3	12	9	0.0202	0.0246	0.3485	1.61	32.0
3	12	10	0.0481	0.0395	0.3250	1.57	32.0
4	1	1	0.0615	0.0053	0.4134	2.54	30.2
4	1	2	0.0876	0.0586	0.4131	2.39	30.3
4	1	3	0.0712	0.0554	0.4251	2.33	29.9

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
4	1	4	0.0792	0.0451	0.4069	2.49	30.2
4	1	5	0.0740	0.0647	0.4099	2.31	30.5
4	1	6	0.0572	0.0477	0.4301	2.42	30.7
4	1	7	0.0776	0.0568	0.4110	2.40	30.6
4	1	8	0.0541	0.0535	0.4280	2.34	30.4
4	1	9	0.0489	0.0571	0.4143	2.33	30.5
4	1	10	0.0807	0.0488	0.4040	2.37	30.1
4	2	1	0.0831	0.0641	0.4487	2.37	30.1
4	2	2	0.0725	0.0632	0.4328	2.50	29.6
4	2	3	0.0509	0.0483	0.4133	2.37	30.0
4	2	4	0.0405	0.0595	0.4126	2.49	29.5
4	2	5	0.0778	0.0600	0.4445	2.31	30.3
4	2	6	0.0495	0.0612	0.4431	2.38	31.2
4	2	7	0.0516	0.0518	0.4482	2.41	31.5
4	2	8	0.0842	0.0501	0.4214	2.40	30.9
4	2	9	0.0813	0.0638	0.4338	2.36	29.5
4	2	10	0.0410	0.0622	0.4211	2.30	30.8
4	3	1	0.0479	0.0456	0.4222	2.39	30.4
4	3	2	0.0452	0.0646	0.4058	2.40	30.9
4	3	3	0.0672	0.0497	0.4122	2.38	30.1
4	3	4	0.0798	0.0638	0.4073	2.33	31.5
4	3	5	0.0450	0.0475	0.4440	2.38	31.3
4	3	6	0.0482	0.0641	0.4155	2.36	29.7
4	3	7	0.0550	0.0454	0.4046	2.38	29.5
4	3	8	0.0831	0.0550	0.4011	2.46	30.7
4	3	9	0.0661	0.0504	0.4054	2.44	29.7
4	3	10	0.0794	0.0551	0.4141	2.37	29.5
4	4	1	0.0715	0.0603	0.4110	2.35	29.7

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
4	4	2	0.0525	0.0622	0.4458	2.35	30.9
4	4	3	0.0608	0.0561	0.4080	2.50	30.3
4	4	4	0.0798	0.0510	0.4185	2.46	30.8
4	4	5	0.0606	0.0544	0.4237	2.39	31.3
4	4	6	0.0756	0.0498	0.4051	2.30	30.0
4	4	7	0.0608	0.0533	0.4237	2.50	29.5
4	4	8	0.0593	0.0639	0.4257	2.39	31.2
4	4	9	0.0404	0.0647	0.4263	2.45	29.6
4	4	10	0.0704	0.0519	0.4491	2.37	30.8
4	5	1	0.0841	0.0570	0.4319	2.3	31.2
4	5	2	0.0632	0.0547	0.4195	2.36	30.6
4	5	3	0.0525	0.0631	0.4333	2.34	30.7
4	5	4	0.0532	0.0488	0.4179	2.31	30.1
4	5	5	0.0825	0.0510	0.4003	2.32	30.2
4	5	6	0.0801	0.0625	0.4460	2.31	29.7
4	5	7	0.0639	0.0548	0.4119	2.31	31.3
4	5	8	0.0496	0.0625	0.4306	2.39	30.2
4	5	9	0.0570	0.0488	0.4410	2.35	30.9
4	5	10	0.0759	0.0633	0.4472	2.33	30.2
4	6	1	0.0594	0.0648	0.4039	2.38	29.5
4	6	2	0.0659	0.0594	0.4421	2.32	31.1
4	6	3	0.0708	0.0642	0.4106	2.38	29.6
4	6	4	0.0850	0.0569	0.4083	2.31	29.7
4	6	5	0.0428	0.0580	0.4161	2.31	30.8
4	6	6	0.0840	0.0590	0.4232	2.38	30.8
4	6	7	0.0568	0.0559	0.4236	2.38	30.7
4	6	8	0.0519	0.0472	0.4230	2.38	29.6
4	6	9	0.0450	0.0646	0.4063	2.35	31.4

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
4	6	10	0.0575	0.0515	0.4415	2.36	30.4
4	7	1	0.0702	0.0599	0.4282	2.38	30.8
4	7	2	0.0465	0.0597	0.4463	2.39	30.9
4	7	3	0.0629	0.0474	0.4241	2.32	29.6
4	7	4	0.0606	0.0631	0.4249	2.38	29.6
4	7	5	0.0540	0.0642	0.4423	2.33	31.1
4	7	6	0.0652	0.0611	0.4001	2.38	30.2
4	7	7	0.0553	0.0594	0.4159	2.33	30.0
4	7	8	0.0662	0.0515	0.4115	2.39	30.5
4	7	9	0.0755	0.0595	0.4129	2.33	30.5
4	7	10	0.0513	0.0489	0.4228	2.31	30.7
4	8	1	0.0787	0.0610	0.4264	2.37	30.8
4	8	2	0.0862	0.0625	0.4366	2.33	30.5
4	8	3	0.0567	0.0500	0.4077	2.39	31.2
4	8	4	0.0742	0.0489	0.4384	2.37	31.5
4	8	5	0.0564	0.0597	0.4238	2.30	31.4
4	8	6	0.0659	0.0526	0.4192	2.35	31.3
4	8	7	0.0663	0.0545	0.4158	2.38	30.2
4	8	8	0.0654	0.0587	0.4039	2.38	30.5
4	8	9	0.0772	0.0467	0.4270	2.34	30.5
4	8	10	0.0698	0.0481	0.4478	2.38	29.7
4	9	1	0.2234	0.1026	0.5087	3.17	28.9
4	9	2	0.1964	0.1098	0.5116	3.12	29.3
4	9	3	0.1723	0.1050	0.5214	3.01	29.3
4	9	4	0.2422	0.1151	0.5073	3.08	28.7
4	9	5	0.2201	0.1024	0.5076	3.11	28.6
4	9	6	0.1916	0.1273	0.5218	3.11	29.3
4	9	7	0.2456	0.1021	0.5005	3.10	29.0

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
4	9	8	0.1896	0.1273	0.5129	3.02	29.3
4	9	9	0.2190	0.0970	0.5216	3.05	28.6
4	9	10	0.1888	0.1059	0.5056	3.13	29.3
4	10	1	0.1633	0.1271	0.5171	3.02	28.7
4	10	2	0.1659	0.1226	0.5238	3.12	29.2
4	10	3	0.1821	0.1163	0.5017	3.19	28.7
4	10	4	0.2069	0.1007	0.5219	3.04	28.6
4	10	5	0.1576	0.1231	0.5176	3.17	29.4
4	10	6	0.2272	0.0962	0.5243	3.02	28.9
4	10	7	0.2356	0.0913	0.5232	3.13	29.2
4	10	8	0.2334	0.0909	0.5094	3.17	28.9
4	10	9	0.2320	0.1009	0.5061	3.02	28.6
4	10	10	0.1817	0.1261	0.5138	3.07	28.8
4	11	1	0.1655	0.1252	0.5229	3.15	29.0
4	11	2	0.2001	0.1153	0.5147	3.20	28.7
4	11	3	0.1927	0.1193	0.5032	3.19	29.2
4	11	4	0.2415	0.1209	0.5088	3.05	28.7
4	11	5	0.1700	0.1214	0.5150	3.13	29.2
4	11	6	0.2139	0.1073	0.5145	3.10	28.7
4	11	7	0.2402	0.1068	0.5130	3.08	28.9
4	11	8	0.2110	0.0919	0.5194	3.14	28.6
4	11	9	0.1723	0.1143	0.5228	3.11	28.9
4	11	10	0.1704	0.1247	0.5103	3.17	29.0
4	12	1	0.2283	0.1136	0.5193	3.17	29.4
4	12	2	0.1943	0.1227	0.5101	3.17	29.4
4	12	3	0.2442	0.1092	0.5223	3.12	28.5
4	12	4	0.2122	0.1209	0.5239	3.11	29.4
4	12	5	0.2135	0.1030	0.5122	3.16	29.0

เดือน ที่	หมายเลข แปลงย่อย	ตัวอย่าง	ExG	GRVI	NDVI	น้ำหนัก (กก./ตร. ม.)	ปริมาณแบ่ง (%)
4	12	6	0.2081	0.1289	0.5219	3.02	29.1
4	12	7	0.2055	0.1050	0.5162	3.02	29.0
4	12	8	0.2380	0.1159	0.5151	3.15	29.1
4	12	9	0.1556	0.0974	0.5055	3.14	28.8
4	12	10	0.1980	0.0914	0.5192	3.17	29.4



ภาคผนวก ฉ

การเขียนโปรแกรมภาษาไพธอนในงานวิจัย



โปรแกรม คือ ชุดคำสั่งที่กำหนดขึ้นมาเพื่อให้คอมพิวเตอร์ทำงานอย่างใดอย่างหนึ่ง การนำคำสั่งมาเรียงต่อกันเป็นขั้นตอนเพื่อให้บรรลุวัตถุประสงค์บางอย่าง เรียกว่า ชุดคำสั่ง

ภาษาคอมพิวเตอร์ คือ ภาษาที่ใช้ในการสื่อสารให้คอมพิวเตอร์เข้าใจได้

ภาษาไพธอน (Python) ถูกพัฒนาขึ้นในปี ค.ศ. 1991 โดย Guido van Rossum โดยนำชื่อ Python มาจากคณะตลกที่มีชื่อว่า Monty Python ภาษาไพธอนเป็นที่นิยมมากในปัจจุบัน เนื่องจากสามารถทำงานได้บนระบบปฏิบัติการที่หลากหลาย เป็นซอฟต์แวร์รหัสเปิด (Open source) โครงสร้างของภาษาเรียบง่าย มีชุดคำสั่ง หรือไลบรารี (Library) จำนวนมากให้เรียกใช้ และใช้งานได้กับฐานข้อมูลจำนวนมาก

เครื่องมือในการเขียนโปรแกรมภาษาไพธอนจะเขียนผ่าน Integrated Development Environment (IDE) โดยมีส่วนหน้าต่างในการเขียนโค้ด (Code) เรียกว่า Source Editor และส่วนที่สั่งให้โปรแกรมทำงาน หรือการรัน (Run) เพื่อแสดงผล นอกจากนี้ยังมี debugger สำหรับตรวจสอบความผิดพลาดของโปรแกรม IDE ที่นิยมใช้ในการเขียนโปรแกรมภาษาไพธอน ได้แก่ Python IDLE, PyCharm และ Jupyter Notebook

Jupyter Notebook เป็นเครื่องมือที่มีความโดดเด่นมากที่สุดชนิดหนึ่ง เนื่องจากมีการทำงานบนบล็อกบรรจุก๊ัด (Code block) และบล็อกบรรจุกข้อความ (Text block) โดยจะเริ่มการทำงานตามลำดับการรันในแต่ละบล็อก เพื่อความสะดวกในการแก้ไข และจัดรูปแบบ อีกทั้งแต่ละบล็อกบรรจุก๊ัดยังมีพื้นที่แสดงผลลัพธ์ (Output) ของแต่ละบล็อก อีกทั้งยังรองรับการใส่รูปภาพ และข้อความ

Jupyter Notebook เป็นที่นิยมอย่างมากในการคำนวณทางวิทยาศาสตร์ และการพัฒนาการเรียนรู้ของเครื่องสามารถใช้งาน Jupyter Notebook ได้ผ่านทางแพลตฟอร์ม เช่น Anaconda ซึ่งนิยมใช้กับงานวิทยาศาสตร์ข้อมูล หรือบนระบบ Cloud เช่น Google Colaboratory เป็นต้น

ไลบรารีที่สำคัญในการพัฒนาการเรียนรู้ของเครื่อง ได้แก่ TensorFlow และ Scikit-learn (Sklearn) เป็นไลบรารีแบบรหัสเปิด ที่บรรจุอัลกอริทึมทางการเรียนรู้ของเครื่องไว้มากมาย นอกจากนี้ยังมีไลบรารีพื้นฐานในการคำนวณและการจัดการข้อมูล เช่น Numpy, Scipy, pandas ไลบรารีสำหรับแสดงผล เช่น matplotlib และ seaborn เป็นต้น

ฉ.1 การสร้างแบบจำลองโครงข่ายประสาทเทียมด้วย Keras และ TensorFlow

Keras และ Tensor เป็นชุดเครื่องมือที่มีประโยชน์อย่างยิ่งต่อการพัฒนาแบบจำลองโครงข่ายประสาทเทียม ด้วยมีคุณสมบัติในการปรับค่าตัวแปรต่าง ๆ ภายในโครงสร้างของแบบจำลองได้อย่างอิสระ อีกทั้งยังมีไลบรารีที่มีการพัฒนาแล้วให้เลือกในการใช้งานได้เป็นจำนวนมาก ใน

การศึกษานี้ได้ใช้ชุดเครื่องมือ TensorFlow v.3 ร่วมกับ Keras ในการพัฒนาแบบจำลองสำหรับการทำนายปริมาณผลผลิต โดยตัวอย่างของโค้ดที่ใช้สำหรับสร้างแบบจำลองที่มี 4 ชั้นซ่อน 16 โหนด แสดงได้ดังนี้

```
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense, Dropout
from sklearn.metrics import mean_squared_error, r2_score

# Mount Drive and Load data
data = pd.read_excel('...file path...')
data.head()

#Normalization
feature_cols = ['ExG']
x = df[feature_cols]
y2 = df.Yield_weight #Percent_strach
sc = StandardScaler()
X2 = sc.fit_transform(X)

# Train-Test-Split
X_train, X_test, y_train, y_test = train_test_split(x2, y2, test_size = 0.2, random_state=1)

# Build Model
learning_rate = 0.001
node=16
model = Sequential()
model.add(Dense(node, activation='relu',input_shape=(1,))) #Input layer
model.add(Dense(node,activation='relu')) # Hidden layer 1
model.add(Dense(node,activation='relu')) # Hidden layer 2
model.add(Dense(node,activation='relu')) # Hidden layer 3
model.add(Dense(node,activation='relu')) # Hidden layer 4
model.add(Dense(1,activation='linear')) #Output layer

# model.summary()
model.compile(loss='mean_squared_error', optimizer='Adam', metrics=['Accuracy']) #with default LearningRate
history=model.fit(X_train,y_train, epochs=1500, verbose=0, batch_size=16)

#model evaluate Loss
score = model.evaluate(X_train, y_train, verbose=0)
score1 = model.evaluate(X_test, y_test, verbose=0)
RMSE_train = np.sqrt(score)
RMSE_test = np.sqrt(score1)
```



```
print("Train MSE:", score[0])
print("Train RMSE:", RMSE_train)
print("Test MSE:", score1[0])
print("Test RMSE:", RMSE_test)
```

```
#model evaluate Accuracy
y_pred_train = model.predict(X_train)
y_pred_test = model.predict(X_test)
R2_train = r2_score(y_train,y_pred_train)
R2_test = r2_score(y_test,y_pred_test)
print("Train R2 =", R2_train)
print("Test R2 =", R2_test)
def plot_history(history, key):
    plt.plot(history.history[key])
    plt.plot(history.history['val_'+key])
    plt.xlabel("Epochs")
    plt.ylabel(key)
    plt.legend([key, 'val_'+key])
    plt.show()
plot_history(history, 'mean_squared_error')
```

ฉ.2 การสร้างแบบจำลองสมการถดถอยเชิงเส้นด้วย Scikit-Learn

Scikit-Learn เป็นอีกเครื่องมือที่นิยมในการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง เป็นที่นิยมอย่างมากในการศึกษาและการทำงานในแขนงวิทยาศาสตร์ข้อมูล และปัญญาประดิษฐ์ โดยแบบจำลองสมการถดถอย และการหาสหสัมพันธ์ในการศึกษานี้จะใช้เครื่องมือ Scikit-Learn ด้วยการเขียนโปรแกรมภาษาไพธอนบน Google Colaboratory ตัวอย่างโค้ดของแบบจำลอง แสดงได้ด้านล่าง

ฉ.2.1 การหาค่า Correlation

```
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import seaborn as sns
```

```
# Mount Drive and Load data
data = pd.read_excel('...file path...')
data.head()
```

```
# Correlation heatmap
sns.set()
plt.figure(figsize=(6,4.5))
cor=data.corr()
g = sns.heatmap(cor, annot=True, cmap='YlGnBu', linewidths=0.8,
                 linecolor='b', fmt='.2f')
g.set_yticklabels(g.get_yticklabels(), rotation=0, fontsize=12)
plt.show()
```

จ.2.2 แบบจำลอง Linear Regression

การสร้างแบบจำลอง Linear Regression สามารถทำได้โดยการเรียกใช้ sklearn.

linear_model import LinearRegression แสดงได้ดังนี้

```
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score, mean_squared_error

# Mount Drive and Load data
data = pd.read_excel('...file path...')
data.head()

# Create Model
linear_model = LinearRegression()
x1 = data['NDVI'].values.reshape(-1,1) # ExG GRVI NDVI
y1 = data['Percent_strach'].values.reshape(-1,1) # Yield_weight

# Train-Test split
X1_train, X1_test, y1_train, y1_test = train_test_split(x1, y1, test_size = 0.2, random_state=1)
print('Train size X:',X1_train.shape,'Test size X:', X1_test.shape)
print('Train size Y:',y1_train.shape,'Test size Y:', y1_test.shape)

# Train model
linear_model.fit(X1_train,y1_train)

# Evaluate
Train_y1_predict = linear_model.coef_*X1_train + linear_model.intercept_
Train_r2_1 = r2_score(y1_train,Train_y1_predict)
Train_MSE_1 = mean_squared_error(y1_train,Train_y1_predict)
Train_RMSE_1 = np.sqrt(Train_MSE_1)
Test_y1_predict = linear_model.predict(X1_test)
Test_r2_1 = r2_score(y1_test,Test_y1_predict)
Test_MSE_1 = mean_squared_error(y1_test,Test_y1_predict)
Test_RMSE_1 = np.sqrt(Test_MSE_1)

# Show Result
print('Training model performance ')
print(' Train-R_2 :',Train_r2_1)
print(' Train-MSE :',Train_MSE_1)
print(' Train-RMSE :',Train_RMSE_1)
print('Test model performance ')
print(' Test-R_2 :',Test_r2_1)
print(' Test-MSE :',Test_MSE_1)
print(' Test-RMSE :',Test_RMSE_1)

# Statsmodels - all data
import statsmodels.formula.api as smf
dt_1 =smf.ols('ExG ~ Yield_weight', data = data).fit()
print(dt_1.summary())
```

ฉ.3 การสร้างแบบจำลองโครงข่ายประสาทเทียมด้วย Scikit-Learn

นอกจากนี้ Scikit-learn ยังสามารถสร้างแบบจำลองโครงข่ายประสาทเทียมได้โดยเรียกใช้จาก `sklearn.neural_network import MLPRegressor` แสดงได้ดังนี้

```
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.model_selection import train_test_split
from sklearn.neural_network import MLPRegressor
from sklearn.preprocessing import StandardScaler

# Mount Drive and Load data
data = pd.read_excel("ชื่อไฟล์.xlsx")
data.dropna(axis=0, inplace=True)
target_name = "Yield_weight"
feature_name = list(data.columns.drop(target_name))
X = data[feature_name]
y = data[target_name]

# Train-Test split
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.20, shuffle=True)

# Create Model
reg = MLPRegressor(
    hidden_layer_sizes=(8, 8, 8, 8),
    activation="relu",
    alpha=0,
    batch_size=X_train_scaled.shape[0],
    learning_rate_init=0.01,
    max_iter=1500,
    momentum=0,
)

# Train model
reg.fit(X_train_scaled, y_train)
plt.plot(reg.loss_curve_)

# Evaluate
print("r2_score =\t\t\t", r2_score(y_train, y_pred_train))
print("mean_squared_error =\t\t", mean_squared_error(y_train, y_pred_train))
print("r2_score =\t\t\t", r2_score(y_test, y_pred_test))
print("mean_squared_error =\t\t", mean_squared_error(y_test, y_pred_test))
```



ภาคผนวก ช


การใช้งานซอฟต์แวร์ MATLAB ในงานวิจัย

มหาวิทยาลัยเทคโนโลยีสุรนารี

ซอฟต์แวร์ MATLAB หรือ Matrix Laboratory เป็นซอฟต์แวร์ที่ได้รับความนิยมอย่างมากในการคำนวณและเขียนโปรแกรม มีความสามารถในการสร้างสมการทางคณิตศาสตร์ การออกแบบแบบจำลองของระบบ การสร้างระบบควบคุม เป็นต้น อีกทั้งยังรองรับการทำงานบนระบบปฏิบัติการ Windows, Linux และ MacOS


MATLAB ยังมีความสามารถในการสร้างแบบจำลองการเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก และโครงข่ายประสาทเทียม โดยมีชุดเครื่องมือ (Toolbox) ให้เลือกใช้งาน สำหรับการสร้างแบบจำลองโครงข่ายประสาทเทียมในการศึกษานี้จะใช้ Neural Network Toolbox โดยมีขั้นตอนดังนี้

(1) เปิดใช้งานซอฟต์แวร์ MATLAB




รูปที่ ข.1 หน้าเริ่มต้นของซอฟต์แวร์ MATLAB

(2) เพิ่มข้อมูลโดยการคลิกขวาที่หน้าต่าง Workspace เลือก New จากนั้นตั้งชื่อชุดข้อมูล



รูปที่ ข.2 การเพิ่มข้อมูล และตั้งชื่อชุดข้อมูล


(3) เพิ่มข้อมูล input (ปริมาณผลผลิต) และ output (ค่าดัชนีพืชพรรณ) ลงบน workspace โดยนำมาจากชุดข้อมูลที่เตรียมไว้



	1	2	3	4	5	6	7	8	9	10	11	12
1	3.2600											
2	3.4400											
3	3.3000											
4	3.8200											
5	3.8700											
6	3.6600											
7	3.3800											
8	3.6800											
9	3.2400											
10	3.6200											
11	3.9800											
12	3.2600											
13	3.4600											

รูปที่ ข.3 การสร้างชุดข้อมูล


(4) หากต้องการทำ Normalization ต้องสร้างฟังก์ชันเพื่อทำการ Normalize โดยกำหนดชื่อข้อมูล input เป็น datain และเมื่อแปลค่าเสร็จจะได้ข้อมูลชื่อ dataout แสดงดังรูปที่ ข.4 จากนั้นให้ทำการเปลี่ยนชื่อกลับมาเป็น input เพื่อใช้ในขั้นตอนต่อไป




```
function dataout = scaledata(datain,minval,maxval)
dataout = datain+min(datain(:));
dataout = (dataout/range(dataout(:)))*(maxval-minval);
dataout = dataout + minval;
end
```

รูปที่ ข.4 การสร้างฟังก์ชันสำหรับการทำ Normalization

(5) การเรียกใช้ Neural Network Tool box: Neural Fitting app ให้ทำการพิมพ์ “nnstart” ที่ Command Window (รูปที่ ข.5) จากนั้นกด Enter จะเข้าสู่หน้าเริ่มต้น (รูปที่ ข.6) จากนั้นคลิก Next




รูปที่ ข.5 การเรียกใช้ Neural Network Tool box




รูปที่ ข.6 การเรียกใช้ Neural Fitting app

(6) กด Next เพื่อเริ่มใช้งาน ทำการเลือกชุดข้อมูลแสดงดังรูปที่ ข.7 จากนั้นเลือก Sample are: เป็น Matrix row เพื่อให้ดึงข้อมูลแต่ละตัวอย่างจากแต่ละแถว จากนั้นคลิก Next




รูปที่ ข.7 การเลือกชุดข้อมูล

(7) แบ่งชุดข้อมูลออกเป็นข้อมูลชุดฝึกฝน (Training), ข้อมูลชุดทดสอบ (Testing) และข้อมูลชุดตรวจสอบ (Validation) ในอัตราส่วนที่กำหนดไว้ จากนั้นคลิก Next




รูปที่ ข.8 การแบ่งชุดข้อมูล

(8) กำหนดจำนวนชั้นซ่อน (Number of hidden Neurons) โดยสามารถกำหนดได้ระหว่าง 1-10 ชั้นซ่อนเท่านั้น โครงสร้างของแบบจำลองแสดงในช่อง Neural Network จากนั้นคลิก Next




รูปที่ ข.9 การแบ่งชุดข้อมูล

(9) กำหนดอัลกอริทึม (Training Algorithm) โดยสามารถเลือกได้ 3 ชนิด คือ Scaled conjugate gradient algorithm, Levenberg-Marquardt algorithm และ Bayesian regularization




รูปที่ ข.10 กำหนดอัลกอริทึมสำหรับฝึกฝนแบบจำลอง

(10) กด Train เพื่อฝึกฝนแบบจำลอง โดยจะมีการแสดงหน้าต่าง Neural Network Training (nntraintool) ขึ้นมา (รูปที่ ข.11) ให้รอจนแล้วเสร็จจะได้ผลลัพธ์ดังรูปที่ ข.12




รูปที่ ข.11 หน้าต่าง Neural Network Training



รูปที่ ข.12 ผลลัพธ์ภายหลังการฝึกฝนแบบจำลอง

(11) ผลลัพธ์การฝึกฝนแบบจำลองสามารถดูเพิ่มเติมได้ในปุ่ม Plot Fit, Plot Error Histogram ,Plot Regression และ Performance หากต้องการฝึกฝนแบบจำลองใหม่ให้กดปุ่ม Return



รูปที่ ๑๓.13 Plot Fit, Plot Error Histogram ,Plot Regression และ Performance



ภาคผนวก ซ

ตารางผลการวิจัย

ตารางที่ ซ.1 ผลการประเมินประสิทธิภาพแบบจำลองทำนายน้ำหนักด้วยการเขียนโปรแกรมภาษาไพธอน

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	1	8	500	0.459	0.6775	0.5593
train	no	1	16	500	0.2705	0.5201	0.7403
train	no	1	32	500	0.1933	0.4397	0.8144
train	no	1	64	500	0.162	0.4025	0.8445
train	no	1	8	1000	0.2217	0.4709	0.7871
train	no	1	16	1000	0.1640	0.4050	0.8425
train	no	1	32	1000	0.1472	0.3837	0.8587
train	no	1	64	1000	0.1442	0.3797	0.8616
train	no	1	8	1500	0.1495	0.3867	0.8565
train	no	1	16	1500	0.1448	0.3805	0.8609
train	no	1	32	1500	0.1469	0.3833	0.859
train	no	1	64	1500	0.1444	0.3800	0.8614
train	no	2	8	500	0.2774	0.5267	0.7337
train	no	2	16	500	0.1697	0.4119	0.8371
train	no	2	32	500	0.1447	0.3804	0.8611
train	no	2	64	500	0.1494	0.3865	0.8566
train	no	2	8	1000	0.1445	0.3801	0.8613
train	no	2	16	1000	0.1493	0.3864	0.8567
train	no	2	32	1000	0.1466	0.3829	0.8593
train	no	2	64	1000	0.1476	0.3842	0.8583
train	no	2	8	1500	0.1431	0.3783	0.8626
train	no	2	16	1500	0.1478	0.3844	0.8581
train	no	2	32	1500	0.1448	0.3805	0.8610
train	no	2	64	1500	0.1491	0.3861	0.8568
train	no	3	8	500	0.2107	0.4590	0.7977
train	no	3	16	500	0.1521	0.3900	0.8539
train	no	3	32	500	0.1461	0.3822	0.8597
train	no	3	64	500	0.1465	0.3828	0.8593
train	no	3	8	1000	0.1476	0.3842	0.8583

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	3	16	1000	0.1473	0.3838	0.8585
train	no	3	32	1000	0.1505	0.3879	0.8555
train	no	3	64	1000	0.1505	0.3879	0.8555
train	no	3	8	1500	0.1491	0.3861	0.8568
train	no	3	16	1500	0.1472	0.3837	0.8586
train	no	3	32	1500	0.1474	0.3839	0.8584
train	no	3	64	1500	0.1488	0.3857	0.8572
train	no	4	8	500	0.1450	0.3808	0.8608
train	no	4	16	500	0.1474	0.3839	0.8585
train	no	4	32	500	0.1425	0.3775	0.8632
train	no	4	64	500	0.1493	0.3864	0.8567
train	no	4	8	1000	0.1455	0.3814	0.8603
train	no	4	16	1000	0.1531	0.3913	0.8530
train	no	4	32	1000	0.1459	0.3820	0.8599
train	no	4	64	1000	0.1424	0.3774	0.8633
train	no	4	8	1500	0.1448	0.3805	0.8610
train	no	4	16	1500	0.1472	0.3837	0.8587
train	no	4	32	1500	0.1442	0.3797	0.8616
train	no	4	64	1500	0.1414	0.3760	0.8642
train	no	5	8	500	0.1413	0.3759	0.8524
train	no	5	16	500	0.1413	0.3759	0.8655
train	no	5	32	500	0.1417	0.3764	0.8634
train	no	5	64	500	0.1409	0.3754	0.8635
train	no	5	8	1000	0.1406	0.3750	0.8756
train	no	5	16	1000	0.1405	0.3748	0.8756
train	no	5	32	1000	0.1393	0.3732	0.8722
train	no	5	64	1000	0.1392	0.3731	0.8721
train	no	5	8	1500	0.1401	0.3743	0.8723
train	no	5	16	1500	0.1400	0.3742	0.8726
train	no	5	32	1500	0.1350	0.3674	0.8714

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	5	64	1500	0.1332	0.3650	0.8712
train	no	6	8	500	0.1365	0.3695	0.8776
train	no	6	16	500	0.1342	0.3663	0.8789
train	no	6	32	500	0.1343	0.3665	0.8809
train	no	6	64	500	0.1356	0.3682	0.8814
train	no	6	8	1000	0.1335	0.3654	0.8754
train	no	6	16	1000	0.1325	0.3640	0.8856
train	no	6	32	1000	0.1320	0.3633	0.8875
train	no	6	64	1000	0.1335	0.3654	0.8889
train	no	6	8	1500	0.1320	0.3633	0.8714
train	no	6	16	1500	0.1310	0.3619	0.8821
train	no	6	32	1500	0.1314	0.3625	0.8811
train	no	6	64	1500	0.1308	0.3617	0.8809
train	no	7	8	500	0.1322	0.3636	0.8823
train	no	7	16	500	0.1291	0.3593	0.8825
train	no	7	32	500	0.1295	0.3599	0.8824
train	no	7	64	500	0.1290	0.3592	0.8823
train	no	7	8	1000	0.1307	0.3615	0.8812
train	no	7	16	1000	0.1206	0.3473	0.8821
train	no	7	32	1000	0.1257	0.3545	0.8834
train	no	7	64	1000	0.1254	0.3541	0.8823
train	no	7	8	1500	0.1258	0.3547	0.8834
train	no	7	16	1500	0.1250	0.3536	0.8811
train	no	7	32	1500	0.1249	0.3534	0.8850
train	no	7	64	1500	0.1211	0.3480	0.8898
train	no	8	8	500	0.1296	0.3600	0.8822
train	no	8	16	500	0.1255	0.3543	0.8856
train	no	8	32	500	0.1256	0.3544	0.8854
train	no	8	64	500	0.1254	0.3541	0.8876
train	no	8	8	1000	0.1253	0.3540	0.8823

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	8	16	1000	0.1207	0.3474	0.8854
train	no	8	32	1000	0.1208	0.3476	0.8831
train	no	8	64	1000	0.1209	0.3477	0.8823
train	no	8	8	1500	0.1194	0.3455	0.8844
train	no	8	16	1500	0.1195	0.3457	0.8801
train	no	8	32	1500	0.1198	0.3461	0.8889
train	no	8	64	1500	0.1180	0.3435	0.8851
train	no	9	8	500	0.1201	0.3466	0.8834
train	no	9	16	500	0.1190	0.3450	0.8856
train	no	9	32	500	0.1140	0.3376	0.8876
train	no	9	64	500	0.1121	0.3348	0.8823
train	no	9	8	1000	0.1101	0.3318	0.8808
train	no	9	16	1000	0.1127	0.3357	0.8805
train	no	9	32	1000	0.1167	0.3416	0.8844
train	no	9	64	1000	0.1033	0.3214	0.8834
train	no	9	8	1500	0.1023	0.3198	0.8800
train	no	9	16	1500	0.1045	0.3233	0.8810
train	no	9	32	1500	0.1062	0.3259	0.8811
train	no	9	64	1500	0.1065	0.3263	0.8853
train	no	10	8	500	0.1098	0.3314	0.8845
train	no	10	16	500	0.1086	0.3295	0.8820
train	no	10	32	500	0.1056	0.3250	0.8800
train	no	10	64	500	0.1070	0.3271	0.8801
train	no	10	8	1000	0.1012	0.3181	0.8841
train	no	10	16	1000	0.0929	0.3048	0.8824
train	no	10	32	1000	0.0950	0.3083	0.8867
train	no	10	64	1000	0.0998	0.3160	0.8845
train	no	10	8	1500	0.1021	0.3195	0.8855
train	no	10	16	1500	0.0922	0.3037	0.8827
train	no	10	32	1500	0.0910	0.3016	0.8863

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	10	64	1500	0.0912	0.3020	0.8834
train	yes	1	8	500	0.1525	0.3904	0.7153
train	yes	1	16	500	0.1656	0.4070	0.7169
train	yes	1	32	500	0.2425	0.4925	0.7245
train	yes	1	64	500	0.2355	0.4853	0.7235
train	yes	1	8	1000	0.1725	0.4154	0.7534
train	yes	1	16	1000	0.1675	0.4092	0.7549
train	yes	1	32	1000	0.1565	0.3956	0.7524
train	yes	1	64	1000	0.1737	0.4167	0.7634
train	yes	1	8	1500	0.1356	0.3683	0.7745
train	yes	1	16	1500	0.1257	0.3545	0.7644
train	yes	1	32	1500	0.1567	0.3959	0.7942
train	yes	1	64	1500	0.1356	0.3683	0.8224
train	yes	2	8	500	0.2874	0.5361	0.7240
train	yes	2	16	500	0.1889	0.4346	0.8187
train	yes	2	32	500	0.1420	0.3768	0.8495
train	yes	2	64	500	0.1389	0.3727	0.8517
train	yes	2	8	1000	0.1886	0.4343	0.7770
train	yes	2	16	1000	0.1513	0.3890	0.8466
train	yes	2	32	1000	0.1420	0.3768	0.8636
train	yes	2	64	1000	0.1400	0.3742	0.8656
train	yes	2	8	1500	0.1322	0.3636	0.8189
train	yes	2	16	1500	0.1398	0.3739	0.8547
train	yes	2	32	1500	0.1367	0.3697	0.8637
train	yes	2	64	1500	0.1544	0.3929	0.8667
train	yes	3	8	500	0.3013	0.5489	0.7107
train	yes	3	16	500	0.1771	0.4208	0.8299
train	yes	3	32	500	0.1523	0.3903	0.8537
train	yes	3	64	500	0.1468	0.3831	0.8591
train	yes	3	8	1000	0.2321	0.4818	0.7772

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	yes	3	16	1000	0.1766	0.4202	0.8304
train	yes	3	32	1000	0.1468	0.3831	0.8591
train	yes	3	64	1000	0.1447	0.3804	0.8610
train	yes	3	8	1500	0.2140	0.4626	0.7945
train	yes	3	16	1500	0.1724	0.4152	0.8345
train	yes	3	32	1500	0.1442	0.3797	0.8615
train	yes	3	64	1500	0.1419	0.3767	0.8638
train	yes	4	8	500	0.3077	0.5547	0.7046
train	yes	4	16	500	0.2124	0.4609	0.7960
train	yes	4	32	500	0.1497	0.3869	0.8563
train	yes	4	64	500	0.1477	0.3843	0.8582
train	yes	4	8	1000	0.2690	0.5187	0.7417
train	yes	4	16	1000	0.2037	0.4513	0.8044
train	yes	4	32	1000	0.1468	0.3831	0.8591
train	yes	4	64	1000	0.1433	0.3785	0.8624
train	yes	4	8	1500	0.2277	0.4772	0.7814
train	yes	4	16	1500	0.1663	0.4078	0.8403
train	yes	4	32	1500	0.1458	0.3818	0.8600
train	yes	4	64	1500	0.1419	0.3767	0.8638
train	yes	5	8	500	0.1432	0.3784	0.8653
train	yes	5	16	500	0.1422	0.3771	0.8652
train	yes	5	32	500	0.1403	0.3746	0.8643
train	yes	5	64	500	0.1456	0.3816	0.8655
train	yes	5	8	1000	0.1404	0.3747	0.8625
train	yes	5	16	1000	0.1440	0.3795	0.8660
train	yes	5	32	1000	0.1423	0.3772	0.8633
train	yes	5	64	1000	0.1435	0.3788	0.8621
train	yes	5	8	1500	0.1433	0.3785	0.8625
train	yes	5	16	1500	0.1416	0.3763	0.8653
train	yes	5	32	1500	0.1479	0.3846	0.8667

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	yes	5	64	1500	0.1434	0.3787	0.8689
train	yes	6	8	500	0.1427	0.3778	0.8634
train	yes	6	16	500	0.1487	0.3856	0.8666
train	yes	6	32	500	0.1456	0.3816	0.8609
train	yes	6	64	500	0.1312	0.3622	0.8605
train	yes	6	8	1000	0.1420	0.3768	0.8656
train	yes	6	16	1000	0.1425	0.3775	0.8678
train	yes	6	32	1000	0.1434	0.3787	0.8693
train	yes	6	64	1000	0.1356	0.3682	0.8605
train	yes	6	8	1500	0.1440	0.3795	0.8633
train	yes	6	16	1500	0.1451	0.3809	0.8650
train	yes	6	32	1500	0.1411	0.3756	0.8655
train	yes	6	64	1500	0.1332	0.3650	0.8601
train	yes	7	8	500	0.1334	0.3652	0.8650
train	yes	7	16	500	0.1344	0.3666	0.8634
train	yes	7	32	500	0.1321	0.3635	0.8634
train	yes	7	64	500	0.1356	0.3682	0.8645
train	yes	7	8	1000	0.1378	0.3712	0.8625
train	yes	7	16	1000	0.1312	0.3622	0.8606
train	yes	7	32	1000	0.1332	0.3650	0.8634
train	yes	7	64	1000	0.1399	0.3740	0.8627
train	yes	7	8	1500	0.1220	0.3493	0.8698
train	yes	7	16	1500	0.1211	0.3480	0.8633
train	yes	7	32	1500	0.1209	0.3477	0.8609
train	yes	7	64	1500	0.1211	0.3480	0.8611
train	yes	8	8	500	0.1385	0.3722	0.8646
train	yes	8	16	500	0.1343	0.3665	0.8609
train	yes	8	32	500	0.1345	0.3667	0.8600
train	yes	8	64	500	0.1267	0.3559	0.8766
train	yes	8	8	1000	0.1278	0.3575	0.8658

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	yes	8	16	1000	0.1246	0.3529	0.8622
train	yes	8	32	1000	0.1222	0.3496	0.8602
train	yes	8	64	1000	0.1221	0.3494	0.8755
train	yes	8	8	1500	0.1234	0.3513	0.8623
train	yes	8	16	1500	0.1256	0.3544	0.8656
train	yes	8	32	1500	0.1294	0.3597	0.8669
train	yes	8	64	1500	0.1237	0.3517	0.8743
train	yes	9	8	500	0.1398	0.3739	0.8621
train	yes	9	16	500	0.1321	0.3635	0.8623
train	yes	9	32	500	0.1322	0.3636	0.8645
train	yes	9	64	500	0.1389	0.3727	0.8666
train	yes	9	8	1000	0.1371	0.3703	0.8665
train	yes	9	16	1000	0.1376	0.3709	0.8634
train	yes	9	32	1000	0.1366	0.3696	0.8644
train	yes	9	64	1000	0.1330	0.3647	0.8608
train	yes	9	8	1500	0.1322	0.3636	0.8661
train	yes	9	16	1500	0.1343	0.3665	0.8632
train	yes	9	32	1500	0.1387	0.3724	0.8643
train	yes	9	64	1500	0.1345	0.3667	0.8696
train	yes	10	8	500	0.1396	0.3736	0.8621
train	yes	10	16	500	0.1370	0.3701	0.8657
train	yes	10	32	500	0.1324	0.3639	0.8675
train	yes	10	64	500	0.1300	0.3606	0.8634
train	yes	10	8	1000	0.1370	0.3701	0.8622
train	yes	10	16	1000	0.1356	0.3682	0.8635
train	yes	10	32	1000	0.1334	0.3652	0.8651
train	yes	10	64	1000	0.1304	0.3611	0.8666
train	yes	10	8	1500	0.1340	0.3661	0.8699
train	yes	10	16	1500	0.1353	0.3678	0.8676
train	yes	10	32	1500	0.1334	0.3652	0.8665

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	yes	10	64	1500	0.1311	0.3621	0.8660
test	no	1	8	500	0.5896	0.7679	0.4120
test	no	1	16	500	0.4597	0.6780	0.5415
test	no	1	32	500	0.3634	0.6028	0.6376
test	no	1	64	500	0.3115	0.5581	0.6894
test	no	1	8	1000	0.4024	0.6344	0.5986
test	no	1	16	1000	0.3175	0.5635	0.6833
test	no	1	32	1000	0.2707	0.5203	0.7301
test	no	1	64	1000	0.2677	0.5174	0.7330
test	no	1	8	1500	0.2794	0.5286	0.7213
test	no	1	16	1500	0.2681	0.5178	0.7326
test	no	1	32	1500	0.2684	0.5181	0.7323
test	no	1	64	1500	0.2659	0.5157	0.7348
test	no	2	8	500	0.4182	0.6467	0.5829
test	no	2	16	500	0.3473	0.5893	0.6536
test	no	2	32	500	0.2731	0.5226	0.7276
test	no	2	64	500	0.2784	0.5276	0.7223
test	no	2	8	1000	0.3890	0.6237	0.6120
test	no	2	16	1000	0.2967	0.5447	0.7040
test	no	2	32	1000	0.2894	0.5380	0.7114
test	no	2	64	1000	0.2716	0.5212	0.7291
test	no	2	8	1500	0.3312	0.5755	0.6697
test	no	2	16	1500	0.2889	0.5375	0.7118
test	no	2	32	1500	0.2721	0.5216	0.7287
test	no	2	64	1500	0.2652	0.5150	0.7355
test	no	3	8	500	0.4451	0.6672	0.5560
test	no	3	16	500	0.3169	0.5629	0.6839
test	no	3	32	500	0.2883	0.5369	0.7125
test	no	3	64	500	0.2761	0.5255	0.7246
test	no	3	8	1000	0.3965	0.6297	0.6045

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	no	3	16	1000	0.3121	0.5587	0.6887
test	no	3	32	1000	0.2810	0.5301	0.7197
test	no	3	64	1000	0.2710	0.5206	0.7297
test	no	3	8	1500	0.3673	0.6061	0.6337
test	no	3	16	1500	0.3193	0.5651	0.6815
test	no	3	32	1500	0.2932	0.5415	0.7076
test	no	3	64	1500	0.2671	0.5168	0.7336
test	no	4	8	500	0.4697	0.6853	0.5316
test	no	4	16	500	0.3131	0.5596	0.6877
test	no	4	32	500	0.2980	0.5459	0.7028
test	no	4	64	500	0.2975	0.5454	0.7033
test	no	4	8	1000	0.4349	0.6595	0.5663
test	no	4	16	1000	0.3561	0.5967	0.6448
test	no	4	32	1000	0.3192	0.5650	0.6817
test	no	4	64	1000	0.3057	0.5529	0.6951
test	no	4	8	1500	0.3956	0.6290	0.6055
test	no	4	16	1500	0.3482	0.5901	0.6527
test	no	4	32	1500	0.3036	0.5510	0.6972
test	no	4	64	1500	0.3028	0.5503	0.6980
test	no	5	8	500	0.2832	0.5322	0.7123
test	no	5	16	500	0.2920	0.5404	0.7145
test	no	5	32	500	0.2900	0.5385	0.7288
test	no	5	64	500	0.2721	0.5216	0.7234
test	no	5	8	1000	0.2726	0.5221	0.7254
test	no	5	16	1000	0.2821	0.5311	0.7446
test	no	5	32	1000	0.2880	0.5367	0.7410
test	no	5	64	1000	0.2723	0.5218	0.7204
test	no	5	8	1500	0.2723	0.5218	0.7253
test	no	5	16	1500	0.2867	0.5354	0.7241
test	no	5	32	1500	0.2889	0.5375	0.7426

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	no	5	64	1500	0.2523	0.5023	0.7624
test	no	6	8	500	0.2734	0.5229	0.7324
test	no	6	16	500	0.2736	0.5231	0.7456
test	no	6	32	500	0.2644	0.5142	0.7523
test	no	6	64	500	0.2587	0.5086	0.7556
test	no	6	8	1000	0.2690	0.5187	0.7330
test	no	6	16	1000	0.2621	0.5120	0.7635
test	no	6	32	1000	0.2622	0.5121	0.7555
test	no	6	64	1000	0.2502	0.5002	0.7735
test	no	6	8	1500	0.2546	0.5046	0.7523
test	no	6	16	1500	0.2582	0.5081	0.7656
test	no	6	32	1500	0.2534	0.5034	0.7777
test	no	6	64	1500	0.2440	0.4940	0.7809
test	no	7	8	500	0.2505	0.5005	0.7640
test	no	7	16	500	0.2515	0.5015	0.7509
test	no	7	32	500	0.2430	0.4930	0.7985
test	no	7	64	500	0.2410	0.4909	0.7889
test	no	7	8	1000	0.2545	0.5045	0.7675
test	no	7	16	1000	0.2432	0.4932	0.7874
test	no	7	32	1000	0.2201	0.4691	0.8432
test	no	7	64	1000	0.2559	0.5059	0.7653
test	no	7	8	1500	0.2490	0.4990	0.7894
test	no	7	16	1500	0.2421	0.4920	0.7812
test	no	7	32	1500	0.2213	0.4704	0.8508
test	no	7	64	1500	0.2950	0.5431	0.7209
test	no	8	8	500	0.2666	0.5163	0.7780
test	no	8	16	500	0.2646	0.5144	0.7765
test	no	8	32	500	0.2742	0.5236	0.7524
test	no	8	64	500	0.2767	0.5260	0.7422
test	no	8	8	1000	0.2750	0.5244	0.7756

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	no	8	16	1000	0.2822	0.5312	0.7742
test	no	8	32	1000	0.2830	0.5320	0.7642
test	no	8	64	1000	0.3036	0.5510	0.7454
test	no	8	8	1500	0.2924	0.5408	0.7232
test	no	8	16	1500	0.3021	0.5496	0.7856
test	no	8	32	1500	0.3011	0.5487	0.7755
test	no	8	64	1500	0.3042	0.5515	0.7500
test	no	9	8	500	0.2880	0.5367	0.7723
test	no	9	16	500	0.3001	0.5478	0.7145
test	no	9	32	500	0.3032	0.5506	0.7063
test	no	9	64	500	0.3031	0.5505	0.7043
test	no	9	8	1000	0.2935	0.5418	0.7874
test	no	9	16	1000	0.3145	0.5608	0.7226
test	no	9	32	1000	0.3256	0.5706	0.7054
test	no	9	64	1000	0.3245	0.5696	0.6923
test	no	9	8	1500	0.3021	0.5496	0.7500
test	no	9	16	1500	0.3335	0.5775	0.6895
test	no	9	32	1500	0.3395	0.5827	0.6777
test	no	9	64	1500	0.3478	0.5897	0.6434
test	no	10	8	500	0.3009	0.5485	0.7021
test	no	10	16	500	0.3211	0.5667	0.6935
test	no	10	32	500	0.3226	0.5680	0.7064
test	no	10	64	500	0.3369	0.5804	0.6822
test	no	10	8	1000	0.3134	0.5598	0.7064
test	no	10	16	1000	0.3313	0.5756	0.6956
test	no	10	32	1000	0.3383	0.5816	0.6953
test	no	10	64	1000	0.3398	0.5829	0.6964
test	no	10	8	1500	0.3374	0.5809	0.6956
test	no	10	16	1500	0.3346	0.5784	0.6922
test	no	10	32	1500	0.3322	0.5764	0.6910

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	no	10	64	1500	0.3532	0.5943	0.6524
test	yes	1	8	500	0.4353	0.6598	0.4647
test	yes	1	16	500	0.4236	0.6508	0.4636
test	yes	1	32	500	0.4355	0.6599	0.5136
test	yes	1	64	500	0.3564	0.5970	0.5366
test	yes	1	8	1000	0.3546	0.5955	0.7356
test	yes	1	16	1000	0.3466	0.5887	0.7355
test	yes	1	32	1000	0.3542	0.5951	0.7353
test	yes	1	64	1000	0.4347	0.6593	0.7637
test	yes	1	8	1500	0.2648	0.5145	0.7355
test	yes	1	16	1500	0.2756	0.5250	0.7255
test	yes	1	32	1500	0.2658	0.5155	0.7332
test	yes	1	64	1500	0.2714	0.5209	0.7314
test	yes	2	8	500	0.4700	0.6856	0.5312
test	yes	2	16	500	0.3268	0.5717	0.6741
test	yes	2	32	500	0.2686	0.5183	0.7321
test	yes	2	64	500	0.2684	0.5181	0.7323
test	yes	2	8	1000	0.2960	0.5441	0.7048
test	yes	2	16	1000	0.2686	0.5183	0.7321
test	yes	2	32	1000	0.2692	0.5188	0.7315
test	yes	2	64	1000	0.2681	0.5178	0.7326
test	yes	2	8	1500	0.2699	0.5195	0.7308
test	yes	2	16	1500	0.2681	0.5178	0.7326
test	yes	2	32	1500	0.2669	0.5166	0.7338
test	yes	2	64	1500	0.2687	0.5184	0.7320
test	yes	3	8	500	0.3879	0.6228	0.6131
test	yes	3	16	500	0.2747	0.5241	0.7260
test	yes	3	32	500	0.2669	0.5166	0.7338
test	yes	3	64	500	0.2693	0.5189	0.7314
test	yes	3	8	1000	0.2688	0.5185	0.7319

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	yes	3	16	1000	0.2690	0.5187	0.7317
test	yes	3	32	1000	0.2696	0.5192	0.7311
test	yes	3	64	1000	0.2681	0.5178	0.7326
test	yes	3	8	1500	0.2698	0.5194	0.7309
test	yes	3	16	1500	0.2675	0.5172	0.7333
test	yes	3	32	1500	0.2696	0.5192	0.7311
test	yes	3	64	1500	0.2682	0.5179	0.7325
test	yes	4	8	500	0.2721	0.5216	0.7287
test	yes	4	16	500	0.2692	0.5188	0.7315
test	yes	4	32	500	0.2669	0.5166	0.7338
test	yes	4	64	500	0.2679	0.5176	0.7328
test	yes	4	8	1000	0.2701	0.5197	0.7306
test	yes	4	16	1000	0.2720	0.5215	0.7287
test	yes	4	32	1000	0.2658	0.5156	0.7349
test	yes	4	64	1000	0.2671	0.5168	0.7336
test	yes	4	8	1500	0.2673	0.5170	0.7334
test	yes	4	16	1500	0.2696	0.5192	0.7311
test	yes	4	32	1500	0.2654	0.5152	0.7353
test	yes	4	64	1500	0.2638	0.5136	0.7369
test	yes	5	8	500	0.2534	0.5034	0.7335
test	yes	5	16	500	0.2556	0.5056	0.7324
test	yes	5	32	500	0.2574	0.5073	0.7334
test	yes	5	64	500	0.2525	0.5025	0.7325
test	yes	5	8	1000	0.2474	0.4974	0.7334
test	yes	5	16	1000	0.2483	0.4983	0.7356
test	yes	5	32	1000	0.2464	0.4964	0.7313
test	yes	5	64	1000	0.2404	0.4903	0.7300
test	yes	5	8	1500	0.2445	0.4945	0.7435
test	yes	5	16	1500	0.2321	0.4818	0.7355
test	yes	5	32	1500	0.2478	0.4978	0.7435

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	yes	5	64	1500	0.2494	0.4994	0.7436
test	yes	6	8	500	0.2367	0.4865	0.7464
test	yes	6	16	500	0.2288	0.4783	0.7465
test	yes	6	32	500	0.2380	0.4879	0.7444
test	yes	6	64	500	0.2445	0.4945	0.7379
test	yes	6	8	1000	0.2232	0.4724	0.7306
test	yes	6	16	1000	0.2152	0.4639	0.7375
test	yes	6	32	1000	0.2231	0.4723	0.7334
test	yes	6	64	1000	0.2246	0.4739	0.7467
test	yes	6	8	1500	0.2150	0.4637	0.7354
test	yes	6	16	1500	0.2023	0.4498	0.7323
test	yes	6	32	1500	0.2056	0.4534	0.7325
test	yes	6	64	1500	0.2183	0.4672	0.7313
test	yes	7	8	500	0.2147	0.4634	0.7532
test	yes	7	16	500	0.2175	0.4664	0.7574
test	yes	7	32	500	0.2100	0.4583	0.7522
test	yes	7	64	500	0.2124	0.4609	0.7565
test	yes	7	8	1000	0.2167	0.4655	0.7505
test	yes	7	16	1000	0.2011	0.4484	0.7611
test	yes	7	32	1000	0.2024	0.4499	0.7623
test	yes	7	64	1000	0.2053	0.4531	0.7650
test	yes	7	8	1500	0.1967	0.4435	0.7355
test	yes	7	16	1500	0.1944	0.4409	0.7326
test	yes	7	32	1500	0.1945	0.4410	0.7300
test	yes	7	64	1500	0.1932	0.4395	0.7535
test	yes	8	8	500	0.1975	0.4444	0.7732
test	yes	8	16	500	0.1878	0.4334	0.7835
test	yes	8	32	500	0.1883	0.4339	0.7824
test	yes	8	64	500	0.1898	0.4357	0.7864
test	yes	8	8	1000	0.1812	0.4257	0.7800

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	yes	8	16	1000	0.1722	0.4150	0.7975
test	yes	8	32	1000	0.1788	0.4228	0.7900
test	yes	8	64	1000	0.1775	0.4213	0.7934
test	yes	8	8	1500	0.1632	0.4040	0.7247
test	yes	8	16	1500	0.1694	0.4116	0.7125
test	yes	8	32	1500	0.1668	0.4084	0.7125
test	yes	8	64	1500	0.1614	0.4017	0.7201
test	yes	9	8	500	0.1621	0.4026	0.8009
test	yes	9	16	500	0.1535	0.3918	0.8066
test	yes	9	32	500	0.1622	0.4027	0.8032
test	yes	9	64	500	0.1605	0.4006	0.8036
test	yes	9	8	1000	0.1622	0.4027	0.8032
test	yes	9	16	1000	0.1556	0.3945	0.8076
test	yes	9	32	1000	0.1534	0.3917	0.8079
test	yes	9	64	1000	0.1555	0.3943	0.8070
test	yes	9	8	1500	0.1505	0.3879	0.7201
test	yes	9	16	1500	0.1479	0.3846	0.7199
test	yes	9	32	1500	0.1467	0.3830	0.7191
test	yes	9	64	1500	0.1414	0.3760	0.7189
test	yes	10	8	500	0.1309	0.3618	0.8142
test	yes	10	16	500	0.1211	0.3480	0.8167
test	yes	10	32	500	0.1221	0.3494	0.8123
test	yes	10	64	500	0.1245	0.3528	0.8166
test	yes	10	8	1000	0.1221	0.3494	0.8123
test	yes	10	16	1000	0.1109	0.3330	0.8156
test	yes	10	32	1000	0.1110	0.3332	0.8169
test	yes	10	64	1000	0.1134	0.3367	0.8122
test	yes	10	8	1500	0.1121	0.3348	0.7355
test	yes	10	16	1500	0.1166	0.3415	0.7265
test	yes	10	32	1500	0.1123	0.3351	0.7257
test	yes	10	64	1500	0.1104	0.3323	0.7275

ตารางที่ ข.2 ผลการประเมินประสิทธิภาพแบบจำลองทำนายปริมาณแบ่งด้วยการเขียนโปรแกรม
ภาษาไพธอน

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	1	8	500	4.9497	2.2248	0.4013
train	no	1	16	500	4.9615	2.2274	0.4081
train	no	1	32	500	5.0773	2.2533	0.4002
train	no	1	64	500	4.9272	2.2197	0.4038
train	no	1	8	1000	5.1809	2.2762	0.4038
train	no	1	16	1000	5.2209	2.2849	0.4074
train	no	1	32	1000	4.8720	2.2073	0.4064
train	no	1	64	1000	5.1435	2.2679	0.4096
train	no	2	8	500	4.8793	2.2089	0.4193
train	no	2	16	500	4.9744	2.2303	0.4129
train	no	2	32	500	5.2512	2.2915	0.4165
train	no	2	64	500	5.2567	2.2928	0.4190
train	no	2	8	1000	5.1533	2.2701	0.4103
train	no	2	16	1000	5.1854	2.2771	0.4107
train	no	2	32	1000	4.8760	2.2082	0.4184
train	no	2	64	1000	5.1608	2.2717	0.4129
train	no	3	8	500	4.5342	2.1294	0.4266
train	no	3	16	500	4.6695	2.1609	0.4247
train	no	3	32	500	4.4277	2.1042	0.4268
train	no	3	64	500	4.7772	2.1857	0.4285
train	no	3	8	1000	4.6999	2.1679	0.4260
train	no	3	16	1000	4.5347	2.1295	0.4268
train	no	3	32	1000	4.6975	2.1674	0.4220
train	no	3	64	1000	4.4258	2.1038	0.4270
train	no	4	8	500	4.5730	2.1385	0.4322
train	no	4	16	500	4.7343	2.1758	0.4388
train	no	4	32	500	4.5817	2.1405	0.4356
train	no	4	64	500	4.7089	2.1700	0.4305

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	4	8	1000	4.8293	2.1976	0.4393
train	no	4	16	1000	4.5707	2.1379	0.4346
train	no	4	32	1000	4.7088	2.1700	0.4376
train	no	4	64	1000	4.7076	2.1697	0.4342
train	no	5	8	500	4.0304	2.0076	0.4456
train	no	5	16	500	4.1458	2.0361	0.4477
train	no	5	32	500	4.2485	2.0612	0.4449
train	no	5	64	500	4.2811	2.0691	0.4434
train	no	5	8	1000	4.0848	2.0211	0.4461
train	no	5	16	1000	4.1378	2.0341	0.4485
train	no	5	32	1000	4.3930	2.0960	0.4426
train	no	5	64	1000	4.3961	2.0967	0.4418
train	no	6	8	500	3.7791	1.9440	0.4500
train	no	6	16	500	3.8864	1.9714	0.4590
train	no	6	32	500	3.8278	1.9565	0.4551
train	no	6	64	500	3.9702	1.9925	0.4596
train	no	6	8	1000	3.6966	1.9227	0.4503
train	no	6	16	1000	3.7151	1.9275	0.4548
train	no	6	32	1000	3.9688	1.9922	0.4501
train	no	6	64	1000	3.9789	1.9947	0.4549
train	no	7	8	500	3.2435	1.8010	0.4636
train	no	7	16	500	3.5007	1.8710	0.4671
train	no	7	32	500	3.5517	1.8846	0.4649
train	no	7	64	500	3.5203	1.8762	0.4635
train	no	7	8	1000	3.4741	1.8639	0.4693
train	no	7	16	1000	3.3026	1.8173	0.4670
train	no	7	32	1000	3.4544	1.8586	0.4613
train	no	7	64	1000	3.5870	1.8939	0.4683
train	no	8	8	500	3.4717	1.8632	0.4726
train	no	8	16	500	3.4848	1.8668	0.4736

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	no	8	32	500	3.5627	1.8875	0.4723
train	no	8	64	500	3.2869	1.8130	0.4724
train	no	8	8	1000	3.4412	1.8551	0.4768
train	no	8	16	1000	3.5816	1.8925	0.4758
train	no	8	32	1000	3.4598	1.8601	0.4737
train	no	8	64	1000	3.3896	1.8411	0.4708
train	no	9	8	500	3.3965	1.8430	0.4861
train	no	9	16	500	3.5367	1.8806	0.4834
train	no	9	32	500	3.3094	1.8192	0.4849
train	no	9	64	500	3.4576	1.8595	0.4835
train	no	9	8	1000	3.3991	1.8437	0.4839
train	no	9	16	1000	3.5825	1.8928	0.4820
train	no	9	32	1000	3.4618	1.8606	0.4831
train	no	9	64	1000	3.2855	1.8126	0.4860
train	no	10	8	500	3.5220	1.8767	0.4932
train	no	10	16	500	3.2774	1.8104	0.4920
train	no	10	32	500	3.3166	1.8211	0.4905
train	no	10	64	500	3.3697	1.8357	0.4939
train	no	10	8	1000	3.5167	1.8753	0.4905
train	no	10	16	1000	3.5466	1.8832	0.4904
train	no	10	32	1000	3.5106	1.8737	0.4933
train	no	10	64	1000	3.4249	1.8507	0.4901
train	yes	1	8	500	4.6730	2.1617	0.3515
train	yes	1	16	500	4.6741	2.1620	0.3527
train	yes	1	32	500	4.4363	2.1062	0.3515
train	yes	1	64	500	4.8398	2.2000	0.3559
train	yes	1	8	1000	4.5177	2.1255	0.3591
train	yes	1	16	1000	4.4316	2.1051	0.3596
train	yes	1	32	1000	4.6595	2.1586	0.3579
train	yes	1	64	1000	4.6040	2.1457	0.3530

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	yes	2	8	500	4.8009	2.1911	0.3670
train	yes	2	16	500	4.8092	2.1930	0.3636
train	yes	2	32	500	4.7936	2.1894	0.3672
train	yes	2	64	500	4.4564	2.1110	0.3633
train	yes	2	8	1000	4.4555	2.1108	0.3642
train	yes	2	16	1000	4.4906	2.1191	0.3612
train	yes	2	32	1000	4.7369	2.1764	0.3624
train	yes	2	64	1000	4.7546	2.1805	0.3658
train	yes	3	8	500	4.1981	2.0489	0.3712
train	yes	3	16	500	4.2135	2.0527	0.3770
train	yes	3	32	500	4.1427	2.0354	0.3793
train	yes	3	64	500	4.0885	2.0220	0.3749
train	yes	3	8	1000	4.2026	2.0500	0.3723
train	yes	3	16	1000	4.3693	2.0903	0.3771
train	yes	3	32	1000	4.0075	2.0019	0.3740
train	yes	3	64	1000	4.2664	2.0655	0.3727
train	yes	4	8	500	3.6297	1.9052	0.3847
train	yes	4	16	500	3.8906	1.9725	0.3836
train	yes	4	32	500	3.6450	1.9092	0.3838
train	yes	4	64	500	3.7677	1.9411	0.3868
train	yes	4	8	1000	3.6842	1.9194	0.3843
train	yes	4	16	1000	3.6673	1.9150	0.3824
train	yes	4	32	1000	3.7475	1.9358	0.3879
train	yes	4	64	1000	3.8981	1.9744	0.3898
train	yes	5	8	500	3.7491	1.9363	0.3913
train	yes	5	16	500	3.7676	1.9410	0.3902
train	yes	5	32	500	3.6564	1.9122	0.3926
train	yes	5	64	500	3.9638	1.9909	0.3989
train	yes	5	8	1000	3.9220	1.9804	0.3953
train	yes	5	16	1000	3.7390	1.9337	0.3918

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	yes	5	32	1000	3.6168	1.9018	0.3983
train	yes	5	64	1000	3.9681	1.9920	0.3991
train	yes	6	8	500	3.5672	1.8887	0.4035
train	yes	6	16	500	3.5566	1.8859	0.4045
train	yes	6	32	500	3.6066	1.8991	0.4088
train	yes	6	64	500	3.3909	1.8414	0.4072
train	yes	6	8	1000	3.5602	1.8868	0.4096
train	yes	6	16	1000	3.4668	1.8619	0.4070
train	yes	6	32	1000	3.2417	1.8005	0.4001
train	yes	6	64	1000	3.3062	1.8183	0.4042
train	yes	7	8	500	2.9925	1.7299	0.4156
train	yes	7	16	500	3.1124	1.7642	0.4166
train	yes	7	32	500	3.0855	1.7566	0.4167
train	yes	7	64	500	2.9327	1.7125	0.4101
train	yes	7	8	1000	3.1579	1.7771	0.4181
train	yes	7	16	1000	3.0925	1.7586	0.4104
train	yes	7	32	1000	3.2396	1.7999	0.4184
train	yes	7	64	1000	3.0161	1.7367	0.4145
train	yes	8	8	500	2.5864	1.6082	0.4230
train	yes	8	16	500	2.7033	1.6442	0.4285
train	yes	8	32	500	2.6869	1.6392	0.4275
train	yes	8	64	500	2.8416	1.6857	0.4202
train	yes	8	8	1000	2.5703	1.6032	0.4292
train	yes	8	16	1000	2.7354	1.6539	0.4225
train	yes	8	32	1000	2.8564	1.6901	0.4261
train	yes	8	64	1000	2.6067	1.6145	0.4299
train	yes	9	8	500	2.8515	1.6886	0.4383
train	yes	9	16	500	2.8793	1.6969	0.4390
train	yes	9	32	500	2.7376	1.6546	0.4332
train	yes	9	64	500	2.6142	1.6169	0.4394

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
train	yes	9	8	1000	2.7602	1.6614	0.4323
train	yes	9	16	1000	2.7605	1.6615	0.4347
train	yes	9	32	1000	2.7467	1.6573	0.4362
train	yes	9	64	1000	2.7614	1.6618	0.4370
train	yes	10	8	500	2.8162	1.6781	0.4414
train	yes	10	16	500	2.8836	1.6981	0.4407
train	yes	10	32	500	2.6803	1.6372	0.4429
train	yes	10	64	500	2.5798	1.6062	0.4427
train	yes	10	8	1000	2.5982	1.6119	0.4413
train	yes	10	16	1000	2.6141	1.6168	0.4437
train	yes	10	32	1000	2.6151	1.6171	0.4410
train	yes	10	64	1000	2.7137	1.6473	0.4404
test	no	1	8	500	8.9323	2.9887	0.3440
test	no	1	16	500	8.7688	2.9612	0.3666
test	no	1	32	500	8.7360	2.9557	0.3609
test	no	1	64	500	7.7134	2.7773	0.3528
test	no	1	8	1000	8.2306	2.8689	0.3697
test	no	1	16	1000	8.7942	2.9655	0.3651
test	no	1	32	1000	7.0308	2.6516	0.3546
test	no	1	64	1000	8.2405	2.8706	0.3454
test	no	2	8	500	6.1596	2.4819	0.3815
test	no	2	16	500	5.2284	2.2866	0.3843
test	no	2	32	500	6.1136	2.4726	0.3790
test	no	2	64	500	5.6689	2.3809	0.3805
test	no	2	8	1000	5.7217	2.3920	0.3907
test	no	2	16	1000	5.5195	2.3494	0.4024
test	no	2	32	1000	5.4257	2.3293	0.3871
test	no	2	64	1000	5.4164	2.3273	0.4171
test	no	3	8	500	4.7964	2.1901	0.4436
test	no	3	16	500	4.7611	2.1820	0.4489

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	no	3	32	500	4.1548	2.0383	0.4214
test	no	3	64	500	4.3103	2.0761	0.4455
test	no	3	8	1000	4.7024	2.1685	0.4331
test	no	3	16	1000	4.3531	2.0864	0.4451
test	no	3	32	1000	4.3820	2.0933	0.4449
test	no	3	64	1000	4.6847	2.1644	0.4384
test	no	4	8	500	8.2008	2.8637	0.4546
test	no	4	16	500	4.3025	2.0742	0.4593
test	no	4	32	500	6.6952	2.5875	0.4559
test	no	4	64	500	4.4545	2.1106	0.4554
test	no	4	8	1000	5.1717	2.2741	0.4555
test	no	4	16	1000	8.7695	2.9613	0.4597
test	no	4	32	1000	4.5142	2.1247	0.4521
test	no	4	64	1000	5.7721	2.4025	0.4509
test	no	5	8	500	5.6356	2.3739	0.4664
test	no	5	16	500	5.4550	2.3356	0.4664
test	no	5	32	500	5.3695	2.3172	0.4698
test	no	5	64	500	5.6026	2.3670	0.4665
test	no	5	8	1000	5.5323	2.3521	0.4662
test	no	5	16	1000	5.3402	2.3109	0.4668
test	no	5	32	1000	5.6156	2.3697	0.4671
test	no	5	64	1000	5.5855	2.3634	0.4698
test	no	6	8	500	6.2305	2.4961	0.4744
test	no	6	16	500	6.6564	2.5800	0.4787
test	no	6	32	500	6.3142	2.5128	0.4775
test	no	6	64	500	6.7575	2.5995	0.4755
test	no	6	8	1000	6.5720	2.5636	0.4727
test	no	6	16	1000	6.0215	2.4539	0.4741
test	no	6	32	1000	6.1290	2.4757	0.4754
test	no	6	64	1000	6.0780	2.4654	0.4746

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	no	7	8	500	7.4907	2.7369	0.4891
test	no	7	16	500	6.8207	2.6116	0.4867
test	no	7	32	500	7.1808	2.6797	0.4833
test	no	7	64	500	7.2082	2.6848	0.4825
test	no	7	8	1000	7.8167	2.7958	0.4851
test	no	7	16	1000	7.2546	2.6934	0.4824
test	no	7	32	1000	6.9742	2.6409	0.4807
test	no	7	64	1000	7.5144	2.7412	0.4870
test	no	8	8	500	8.7439	2.9570	0.4891
test	no	8	16	500	8.1317	2.8516	0.4883
test	no	8	32	500	7.9509	2.8197	0.4811
test	no	8	64	500	8.1757	2.8593	0.4871
test	no	8	8	1000	8.7875	2.9644	0.4870
test	no	8	16	1000	8.8911	2.9818	0.4868
test	no	8	32	1000	8.2103	2.8654	0.4855
test	no	8	64	1000	8.9025	2.9837	0.4852
test	no	9	8	500	8.7270	2.9542	0.4819
test	no	9	16	500	7.9959	2.8277	0.4851
test	no	9	32	500	8.6351	2.9386	0.4849
test	no	9	64	500	8.7612	2.9599	0.4822
test	no	9	8	1000	8.3008	2.8811	0.4844
test	no	9	16	1000	8.8464	2.9743	0.4827
test	no	9	32	1000	8.1443	2.8538	0.4826
test	no	9	64	1000	8.7727	2.9619	0.4803
test	no	10	8	500	8.3009	2.8811	0.4894
test	no	10	16	500	8.7922	2.9652	0.4883
test	no	10	32	500	8.4701	2.9103	0.4898
test	no	10	64	500	8.1728	2.8588	0.4872
test	no	10	8	1000	8.3484	2.8894	0.4829
test	no	10	16	1000	8.2553	2.8732	0.4857

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	no	10	32	1000	8.2411	2.8707	0.4883
test	no	10	64	1000	8.2387	2.8703	0.4900
test	yes	1	8	500	6.4519	2.5401	0.2776
test	yes	1	16	500	6.4408	2.5379	0.2744
test	yes	1	32	500	6.6265	2.5742	0.2759
test	yes	1	64	500	6.3877	2.5274	0.2761
test	yes	1	8	1000	6.6256	2.5740	0.2728
test	yes	1	16	1000	6.2580	2.5016	0.2764
test	yes	1	32	1000	6.3241	2.5148	0.2741
test	yes	1	64	1000	6.5374	2.5568	0.2763
test	yes	2	8	500	6.0390	2.4574	0.2886
test	yes	2	16	500	6.1667	2.4833	0.2857
test	yes	2	32	500	6.2343	2.4969	0.2894
test	yes	2	64	500	6.1243	2.4747	0.2841
test	yes	2	8	1000	6.2191	2.4938	0.2857
test	yes	2	16	1000	5.7658	2.4012	0.2844
test	yes	2	32	1000	5.9631	2.4419	0.2889
test	yes	2	64	1000	6.2463	2.4993	0.2817
test	yes	3	8	500	5.5873	2.3637	0.2968
test	yes	3	16	500	5.5008	2.3454	0.2925
test	yes	3	32	500	5.5218	2.3498	0.2999
test	yes	3	64	500	5.7139	2.3904	0.2946
test	yes	3	8	1000	5.5220	2.3499	0.2907
test	yes	3	16	1000	5.3882	2.3212	0.2926
test	yes	3	32	1000	5.5903	2.3644	0.2920
test	yes	3	64	1000	5.2981	2.3018	0.2930
test	yes	4	8	500	4.8438	2.2009	0.3036
test	yes	4	16	500	4.8421	2.2005	0.3078
test	yes	4	32	500	5.0465	2.2464	0.3025
test	yes	4	64	500	4.8431	2.2007	0.3072

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	yes	4	8	1000	5.2386	2.2888	0.3073
test	yes	4	16	1000	5.2726	2.2962	0.3026
test	yes	4	32	1000	4.9849	2.2327	0.3075
test	yes	4	64	1000	5.2693	2.2955	0.3020
test	yes	5	8	500	4.4750	2.1154	0.3187
test	yes	5	16	500	4.7150	2.1714	0.3180
test	yes	5	32	500	4.5321	2.1289	0.3106
test	yes	5	64	500	4.4801	2.1166	0.3114
test	yes	5	8	1000	4.5754	2.1390	0.3138
test	yes	5	16	1000	4.5241	2.1270	0.3176
test	yes	5	32	1000	4.7048	2.1691	0.3191
test	yes	5	64	1000	4.5044	2.1224	0.3185
test	yes	6	8	500	4.1893	2.0468	0.3291
test	yes	6	16	500	4.3545	2.0868	0.3239
test	yes	6	32	500	4.3617	2.0885	0.3252
test	yes	6	64	500	4.1570	2.0389	0.3290
test	yes	6	8	1000	4.1037	2.0258	0.3255
test	yes	6	16	1000	4.0823	2.0205	0.3227
test	yes	6	32	1000	4.2264	2.0558	0.3237
test	yes	6	64	1000	4.1908	2.0471	0.3247
test	yes	7	8	500	4.2469	2.0608	0.3356
test	yes	7	16	500	4.2035	2.0502	0.3374
test	yes	7	32	500	4.1761	2.0435	0.3372
test	yes	7	64	500	4.1326	2.0329	0.3358
test	yes	7	8	1000	4.0281	2.0070	0.3379
test	yes	7	16	1000	4.1096	2.0272	0.3312
test	yes	7	32	1000	4.0477	2.0119	0.3390
test	yes	7	64	1000	4.0959	2.0238	0.3325
test	yes	8	8	500	4.3369	2.0825	0.3494
test	yes	8	16	500	4.1998	2.0493	0.3486

Dataset	Dropout	Hidden layer	Node	Epoch	MSE	RMSE	R ²
test	yes	8	32	500	4.3861	2.0943	0.3484
test	yes	8	64	500	4.3821	2.0933	0.3402
test	yes	8	8	1000	4.3050	2.0749	0.3424
test	yes	8	16	1000	4.0362	2.0090	0.3493
test	yes	8	32	1000	4.3027	2.0743	0.3402
test	yes	8	64	1000	4.3590	2.0878	0.3427
test	yes	9	8	500	4.1287	2.0319	0.3552
test	yes	9	16	500	4.0003	2.0001	0.3567
test	yes	9	32	500	4.1872	2.0463	0.3591
test	yes	9	64	500	4.3892	2.0950	0.3537
test	yes	9	8	1000	4.0609	2.0152	0.3581
test	yes	9	16	1000	4.1642	2.0406	0.3583
test	yes	9	32	1000	4.2226	2.0549	0.3505
test	yes	9	64	1000	4.3869	2.0945	0.3587
test	yes	10	8	500	4.0441	2.0110	0.3615
test	yes	10	16	500	4.3713	2.0908	0.3634
test	yes	10	32	500	4.2980	2.0732	0.3610
test	yes	10	64	500	4.1784	2.0441	0.3646
test	yes	10	8	1000	4.1961	2.0484	0.3604
test	yes	10	16	1000	4.1334	2.0331	0.3641
test	yes	10	32	1000	4.1451	2.0360	0.3636
test	yes	10	64	1000	4.0736	2.0183	0.3612

ตารางที่ ซ.3 ผลการประเมินประสิทธิภาพแบบจำลองทำนายน้ำหนักรักด้วยซอฟต์แวร์ MATLAB

Algorithm	Dataset	Hidden layer	MSE	RMSE	R ²
BR	train	1	0.01290	0.1136	0.7788
BR	train	2	0.01267	0.1126	0.7855
BR	train	3	0.01287	0.1134	0.7919
BR	train	4	0.01259	0.1122	0.7944
BR	train	5	0.01260	0.1122	0.7870
BR	train	6	0.01097	0.1047	0.8236
BR	train	7	0.01006	0.1003	0.8110
BR	train	8	0.01098	0.1048	0.8173
BR	train	9	0.01691	0.1300	0.8092
BR	train	10	0.01089	0.1044	0.8137
BR	test	1	0.01519	0.1232	0.7769
BR	test	2	0.01534	0.1239	0.7587
BR	test	3	0.01576	0.1255	0.7349
BR	test	4	0.01642	0.1281	0.7098
BR	test	5	0.01410	0.1187	0.7824
BR	test	6	0.01570	0.1253	0.7358
BR	test	7	0.01021	0.1010	0.8098
BR	test	8	0.01266	0.1125	0.7907
BR	test	9	0.01799	0.1341	0.8531
BR	test	10	0.01754	0.1324	0.8342
LM	train	1	0.01245	0.1116	0.7940
LM	train	2	0.01243	0.1115	0.8023
LM	train	3	0.01301	0.1141	0.8250
LM	train	4	0.01259	0.1122	0.8329
LM	train	5	0.01258	0.1122	0.7923
LM	train	6	0.01038	0.1019	0.8370
LM	train	7	0.01008	0.1004	0.8318
LM	train	8	0.00920	0.0959	0.8399
LM	train	9	0.01021	0.1010	0.8149

Algorithm	Dataset	Hidden layer	MSE	RMSE	R ²
LM	train	10	0.01106	0.1052	0.8134
LM	test	1	0.01278	0.1130	0.7674
LM	test	2	0.01676	0.1295	0.6800
LM	test	3	0.01284	0.1133	0.7624
LM	test	4	0.01398	0.1182	0.7545
LM	test	5	0.01310	0.1145	0.7245
LM	test	6	0.01146	0.1071	0.7419
LM	test	7	0.01048	0.1024	0.8040
LM	test	8	0.01111	0.1054	0.7473
LM	test	9	0.01092	0.1045	0.8217
LM	test	10	0.01659	0.1288	0.8176
LM	validate	1	0.01493	0.1222	0.6761
LM	validate	2	0.01371	0.1171	0.7970
LM	validate	3	0.01525	0.1235	0.7684
LM	validate	4	0.01538	0.1240	0.7253
LM	validate	5	0.01530	0.1237	0.7584
LM	validate	6	0.01336	0.1156	0.8093
LM	validate	7	0.01071	0.1035	0.8032
LM	validate	8	0.01121	0.1059	0.7475
LM	validate	9	0.01245	0.1116	0.8241
LM	validate	10	0.01055	0.1027	0.8228
SCG	train	1	0.01235	0.1111	0.7919
SCG	train	2	0.01321	0.1149	0.7753
SCG	train	3	0.01202	0.1096	0.8000
SCG	train	4	0.01493	0.1222	0.8082
SCG	train	5	0.01222	0.1105	0.7938
SCG	train	6	0.01034	0.1017	0.8237
SCG	train	7	0.01013	0.1006	0.8297
SCG	train	8	0.01089	0.1044	0.8244
SCG	train	9	0.01210	0.1100	0.7992

Algorithm	Dataset	Hidden layer	MSE	RMSE	R ²
SCG	train	10	0.01194	0.1093	0.8046
SCG	test	1	0.01434	0.1197	0.7664
SCG	test	2	0.01399	0.1183	0.7705
SCG	test	3	0.01399	0.1183	0.7740
SCG	test	4	0.01434	0.1197	0.7628
SCG	test	5	0.01625	0.1275	0.7661
SCG	test	6	0.01824	0.1351	0.7349
SCG	test	7	0.01034	0.1017	0.8093
SCG	test	8	0.01335	0.1155	0.8094
SCG	test	9	0.01260	0.1122	0.8054
SCG	test	10	0.01054	0.1027	0.8246
SCG	validate	1	0.01524	0.1235	0.7326
SCG	validate	2	0.01417	0.1190	0.7580
SCG	validate	3	0.01425	0.1194	0.7527
SCG	validate	4	0.01501	0.1225	0.7443
SCG	validate	5	0.01745	0.1321	0.7755
SCG	validate	6	0.01412	0.1188	0.7856
SCG	validate	7	0.01099	0.1048	0.8062
SCG	validate	8	0.01268	0.1126	0.7870
SCG	validate	9	0.01024	0.1012	0.8077
SCG	validate	10	0.01002	0.1001	0.8182

ตารางที่ ๔.4 ผลการประเมินประสิทธิภาพแบบจำลองทำนายปริมาณแบ่งด้วยซอฟต์แวร์ MATLAB

Algorithm	Dataset	Hidden layer	MSE	RMSE	R ²
BR	train	1	1.4772	1.2154	0.6834
BR	train	2	1.6557	1.2867	0.6602
BR	train	3	1.4444	1.2018	0.7103
BR	train	4	1.4118	1.1882	0.7166
BR	train	5	1.3425	1.1587	0.7305
BR	train	6	1.5702	1.2531	0.6879
BR	train	7	1.3841	1.1765	0.7183
BR	train	8	1.4685	1.2118	0.7170
BR	train	9	1.2981	1.1394	0.7330
BR	train	10	1.2957	1.1383	0.7389
BR	test	1	2.6801	1.6371	0.6069
BR	test	2	1.0597	1.0294	0.7810
BR	test	3	1.6269	1.2755	0.6576
BR	test	4	1.6298	1.2767	0.6747
BR	test	5	2.3394	1.5295	0.4947
BR	test	6	1.8314	1.3533	0.4708
BR	test	7	1.9032	1.3796	0.7131
BR	test	8	0.7668	0.8757	0.7946
BR	test	9	2.3775	1.5419	0.6592
BR	test	10	2.1783	1.4759	0.6066
LM	train	1	1.5354	1.2391	0.6939
LM	train	2	1.4749	1.2145	0.7036
LM	train	3	1.4636	1.2098	0.6999
LM	train	4	1.7033	1.3051	0.6946
LM	train	5	1.3232	1.1503	0.7202
LM	train	6	1.4372	1.1988	0.7050
LM	train	7	1.2898	1.1357	0.7381
LM	train	8	1.2620	1.1234	0.7319
LM	train	9	1.4752	1.2146	0.7073

Algorithm	Dataset	Hidden layer	MSE	RMSE	R ²
LM	train	10	1.4728	1.2136	0.7098
LM	test	1	2.7743	1.6656	0.5068
LM	test	2	1.6299	1.2767	0.6493
LM	test	3	1.0294	1.0146	0.7742
LM	test	4	1.6574	1.2874	0.6595
LM	test	5	1.3735	1.1720	0.7627
LM	test	6	0.9518	0.9756	0.8242
LM	test	7	1.3055	1.1426	0.7141
LM	test	8	2.2994	1.5164	0.6274
LM	test	9	1.3733	1.1719	0.7274
LM	test	10	0.8847	0.9406	0.7885
LM	validate	1	0.9224	0.9604	0.7048
LM	validate	2	1.5823	1.2579	0.6902
LM	validate	3	1.2473	1.1168	0.8159
LM	validate	4	0.7641	0.8741	0.7084
LM	validate	5	2.1786	1.4760	0.6810
LM	validate	6	1.6992	1.3035	0.7133
LM	validate	7	2.2287	1.4929	0.6536
LM	validate	8	1.7983	1.3410	0.6757
LM	validate	9	0.8016	0.8953	0.8256
LM	validate	10	1.2766	1.1299	0.7632
SCG	train	1	1.6633	1.2897	0.6856
SCG	train	2	1.7183	1.3108	0.6423
SCG	train	3	1.8120	1.3461	0.6320
SCG	train	4	1.4992	1.2244	0.6442
SCG	train	5	1.3935	1.1805	0.6973
SCG	train	6	1.5234	1.2343	0.7030
SCG	train	7	1.4908	1.2210	0.7141
SCG	train	8	1.6172	1.2717	0.6618
SCG	train	9	1.5146	1.2307	0.6863

Algorithm	Dataset	Hidden layer	MSE	RMSE	R ²
SCG	train	10	1.5581	1.2482	0.6897
SCG	test	1	1.9694	1.4033	0.5998
SCG	test	2	1.1288	1.0624	0.8151
SCG	test	3	1.2215	1.1052	0.7857
SCG	test	4	1.6908	1.3003	0.7583
SCG	test	5	1.2920	1.1367	0.7843
SCG	test	6	1.6295	1.2765	0.6872
SCG	test	7	1.5790	1.2566	0.6546
SCG	test	8	1.8796	1.3710	0.6791
SCG	test	9	1.0264	1.0131	0.8095
SCG	test	10	1.2335	1.1106	0.7594
SCG	validate	1	1.0395	1.0195	0.6298
SCG	validate	2	1.8127	1.3464	0.5442
SCG	validate	3	1.3557	1.1643	0.5655
SCG	validate	4	1.0662	1.0326	0.6320
SCG	validate	5	1.9598	1.3999	0.7000
SCG	validate	6	1.1187	1.0577	0.6864
SCG	validate	7	1.3582	1.1654	0.5700
SCG	validate	8	1.0989	1.0483	0.7799
SCG	validate	9	1.6735	1.2936	0.6975
SCG	validate	10	1.2657	1.1250	0.6727

ภาคผนวก ณ

ผลงานวิจัยที่ได้รับการเผยแพร่ในระหว่างการศึกษา



รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา

อนาวิล เพ็ชรบุรณิล และสุรเดช ตัญตรัยรัตน์. (2565) การตรวจจับโรคทางใบมันสำปะหลังจากภาพถ่ายทางอากาศด้วยการเรียนรู้เชิงลึก. การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36, 19-22 กรกฎาคม 2565, ประจวบคีรีขันธ์, ประเทศไทย.

อนาวิล เพ็ชรบุรณิล และสุรเดช ตัญตรัยรัตน์. (2566) การประเมินผลผลิตมันสำปะหลัง ด้วยภาพถ่ายจากอากาศยานไร้คนขับ. วารสารแก่นเกษตร, 51(6), 1136-1151.



การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002



การตรวจจับโรคทางใบมันสำปะหลังจากภาพถ่ายทางอากาศด้วยการเรียนรู้เชิงลึก Deep Learning for Cassava Leaf Disease Detection Using Aerial Imagery

อนาวิน เพ็ชรบุรณิล^{1*} และ สุรเดช ตัญญูรัตน์²

¹สาขาวิชาวิศวกรรมเครื่องกล สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี
111 ถนนมหาวิทยาลัย ตำบลสุรนารี อำเภอเมืองนครราชสีมา จังหวัดนครราชสีมา รหัสไปรษณีย์ 30000
²สาขาวิชาวิศวกรรมเครื่องกล สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี
111 ถนนมหาวิทยาลัย ตำบลสุรนารี อำเภอเมืองนครราชสีมา จังหวัดนครราชสีมา รหัสไปรษณีย์ 30000
*ติดต่อ: anavin.pech@gmail.com

บทคัดย่อ

มันสำปะหลังเป็นแหล่งคาร์โบไฮเดรตที่สำคัญของมนุษย์ และเป็นพืชเศรษฐกิจที่มีความสำคัญในประเทศไทย โรคทางใบของมันสำปะหลังส่งผลกระทบต่อปริมาณผลผลิตที่ลดลง เพื่อแก้ไขปัญหาดังกล่าวงานวิจัยนี้จึงนำเสนอการใช้เทคนิคการเรียนรู้เชิงลึกเพื่อตรวจจับโรคใบด่างมันสำปะหลัง โครงข่ายประสาทเทียมแบบคอนโวลูชันเป็นหนึ่งในเทคนิคการเรียนรู้เชิงลึกที่ใช้กับข้อมูลเชิงรูปภาพ และเป็นที่ยอมรับอย่างมากในการเฝ้าระวังศัตรูพืชและโรคพืช You Only Look Once (YOLO) เป็นชนิดของสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชันแบบประมวลผลครั้งเดียวที่เป็นที่ยอมรับมากในการตรวจจับวัตถุ สำหรับงานวิจัยนี้จะใช้ข้อมูลภาพถ่ายจากอากาศยานไร้คนขับ โดยเป็นชุดข้อมูลภาพถ่ายการแพร่ระบาดของโรคใบด่างมันสำปะหลังภายในแปลงสำหรับการฝึกฝนโมเดล ผลการประเมินโมเดลให้ค่า Mean Average Precision (mAP) เท่ากับ 99.7%

คำหลัก: การจำแนกโรคใบด่างมันสำปะหลัง, การเรียนรู้เชิงลึก, อากาศยานไร้คนขับ

Abstract

Cassava is a major source of carbohydrates for human and valuable agricultural products in Thailand. The inflection of cassava leaf disease has resulted in a decreasing of cassava yields. To address this issue the present research aims to propose a deep learning model for cassava foliar disease detection. Convolution neural network (CNN), Which is the most popular deep learning methods, has the potential to developed plant contagion surveillance. YOLO (You Only Look Once), the CNN-based architecture with single stage detector, is omnipresent in the field of computer vision and object detection. This kind of deep learning methods offer a utility to be easily created with UAV Imagery. Using a dataset of cassava inflection images taken in-field to training a classification model. The Mean Average Precision (mAP) of model was 99.7%.

Keywords: Cassava Disease Detection, Deep Learning, Unmanned Aerial Vehicle (UAV)

มหาวิทยาลัยเทคโนโลยีสุรนารี

การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002



1 บทนำ

มันสำปะหลังเป็นพืชเศรษฐกิจที่สำคัญของประเทศไทย และเป็นพืชอาหารที่สำคัญของโลก เพราะมันสำปะหลังเป็นแหล่งคาร์โบไฮเดรตที่มีราคาถูกกว่าผลผลิตแป้งชนิดชนิดอื่น มีการนำมันสำปะหลังไปแปรรูปในอุตสาหกรรมอาหาร ยา เคมีภัณฑ์ และเครื่องสำอาง [1] มันสำปะหลังเป็นพืชอาหารที่มีคนบริโภคมากเป็นอันดับห้าของโลก รองจาก ข้าวโพด ข้าวเจ้า ข้าวสาลี และมันฝรั่ง [2] สำหรับประเทศไทยมันสำปะหลังเป็นหนึ่งในห้าของพืชเศรษฐกิจที่สำคัญของไทย เช่นเดียวกับข้าว ยางพารา ปาล์ม และอ้อย โดยพื้นที่ปลูกมันสำปะหลังส่วนใหญ่อยู่ในภาคตะวันออกเฉียงเหนือและจังหวัดที่มีการเพาะปลูกมันสำปะหลังมากที่สุด คือ นครราชสีมา กำแพงเพชร ชัยภูมิ กาฬสินธุ์ และอุบลราชธานี ตามลำดับ ประเทศไทยผลิตมันสำปะหลังมากที่สุดในอาเซียนโดยเฉลี่ย 25 ล้านตัน และปริมาณผลผลิตสูงสุดที่ผลิตได้คือ 30 ล้านตัน ในปี 2551-2552 [3]

โรคใบด่างมันสำปะหลัง (Cassava mosaic disease: CMD) เป็นโรคที่เกิดจากเชื้อไวรัสในสกุล *Begomovirus* อาการจะเห็นได้ชัดเจนที่ส่วนยอดและใบ โดยจะแสดงเกิดอาการใบด่าง ใบหงิกงอ เสียวรูปทรง และ ลำต้นแคระแกร็น ส่วนหัวมันจะมีขนาดเล็กกว่าต้นมันสำปะหลังปกติ สำหรับทวีปเอเชียพบรายงานการระบาดของเชื้อไวรัส 2 ชนิด ได้แก่ เชื้อ *Indian cassava mosaic virus* (ICMV) พบรายงานระบาดในประเทศอินเดีย และ เชื้อ *Sri Lankan cassava mosaic virus* (SLCMV) พบรายงานการระบาดในประเทศศรีลังกา อินเดีย จีน เวียดนาม กัมพูชา รวมถึงประเทศไทย ด้วยการระบาดของโรคใบด่างมันสำปะหลังเกิดได้จากการนำท่อนพันธุ์มันสำปะหลังที่เป็นโรคมาปลูกทำให้ต้นมันสำปะหลังที่งอกมาใหม่เป็นโรค ประกอบกับในแปลงปลูกในมันสำปะหลังมีแมลงหวี่ขาวยวบซึ่งเป็นพาหะที่ดูดกินน้ำเลี้ยงต้นมันสำปะหลังที่เป็นโรคไปสู่ต้นมันสำปะหลังปกติ จึงทำให้ต้นปกติเป็นโรค โดยในแปลงมันสำปะหลังมักจะพบการเกิดโรคทั้งที่มาจากท่อนพันธุ์และที่เกิดโรคจากแมลงหวี่ขาวยวบ [4] ปัจจุบันโรคใบด่างมันสำปะหลังซึ่งเป็นหนึ่งในปัญหาที่สำคัญของงานด้านการอารักขาพืช โดยยังไม่มีวิธีการรักษาให้หายขาดได้ เกษตรกรทำได้เพียงตรวจพบและทำลายเท่านั้น

โดยต้องอาศัยแรงงานในการเดินสำรวจจึงทำให้การควบคุมการแพร่ระบาดเป็นไปได้ยาก

จากประเด็นปัญหาดังกล่าวข้างต้น จึงทำให้เทคโนโลยีการรับรู้ระยะไกล (Remote Sensing) เข้ามามีบทบาทสำคัญในการรวบรวมข้อมูลจากภาพถ่ายทางอากาศในการเก็บรวบรวมข้อมูลในรูปแบบภาพถ่าย เพื่อช่วยด้านการวัดและเก็บข้อมูลภายในแปลง เนื่องจากอากาศยานไร้คนขับ (Unmanned Aerial Vehicle) หรือ โดรนมีราคาไม่สูงนัก จึงมีการนำมาใช้ประโยชน์ในงานเกษตรกรรมอย่างแพร่หลาย อาทิ การนำไปสำรวจแปลงขนาดใหญ่ เพื่อวิเคราะห์พื้นที่เพาะปลูก รวมไปถึงการวางแผนเก็บเกี่ยวให้แม่นยำมากขึ้น หรือการใช้งานในเฉพาะด้าน เช่น การติดตามสารเคมีทางการเกษตรแบบเฉพาะจุด การตรวจความสมบูรณ์ของดินพืช การประมาณค่าชีวมวลเหนือพื้นดิน เป็นต้น ทำให้เกษตรกรปรับเปลี่ยนไปเป็นเกษตรแม่นยำสูง (Precision Agriculture) ซึ่งมีความแม่นยำมากขึ้น ลดต้นทุนการผลิต และได้ประสิทธิภาพเพิ่มขึ้น [5]

เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence) มีบทบาทอย่างมากต่อการพัฒนาทางการเกษตร โดยเฉพาะทางการตรวจจับโรคพืช การเรียนรู้ของเครื่อง (Machine Learning) เป็นที่นิยมอย่างมากในการตรวจจับโรคพืช โดยจากการศึกษาทางวิจัยที่เกี่ยวข้องได้มีการนำสถาปัตยกรรมของการเรียนรู้ของเครื่อง ได้แก่ Support Vector Machine (SVM) Random Forest K-Nearest Neighbor (K-NN) และ Naive Bayes มาใช้ในการพัฒนาโมเดลเพื่อตรวจจับโรคทางใบของพืช อาทิ มะเขือเทศ [6], ข้าวสาลี [7] และข้าวโพด [8] งานวิจัยดังกล่าวมุ่งเน้นในการหาคุณลักษณะภายในภาพที่ใช้ในการตรวจจับวัตถุ อาทิ ระดับสี ระดับสีเทา แสงเงา ขอบภาพ และรูปแบบที่ใช้ในการจำแนกและตรวจจับจากข้อมูลชุดฝึกฝน เพื่อให้ได้ความถูกต้องและแม่นยำมากขึ้น

การเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network) หรือ CNN เป็นที่นิยมอย่างมากในงานวิจัยก่อนหน้านี้ โดย CNN เป็นสถาปัตยกรรมที่ใช้ในงานด้าน Computer Vision และ Object Recognition

การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002



หรือการมองเห็น รับรู้ และจดจำของคอมพิวเตอร์ อัลกอริทึมที่มีพื้นฐานมาจาก CNN เช่น AlexNet [9] VGGNet [10] GoogLeNet [11] ResNet [12] และ MobileNet [13] ได้ถูกนำมาใช้ในการตรวจจับโรคพืชในแปลงที่ศึกษาวิจัย

สำหรับการตรวจจับโรคทางใบของมันสำปะหลัง ได้มีผู้ศึกษาวิจัยก่อนหน้านี้ได้นำข้อมูลภาพถ่ายใบมันสำปะหลังด้วยกล้องดิจิทัลมาใช้ในการจำแนกชนิดของโรคทางใบในมันสำปะหลังด้วยอัลกอริทึมที่ต่างกัน โดย A. Ramcharan และคณะ [14] ได้ใช้อัลกอริทึม Inception V3 ในการแยกคุณลักษณะข้อมูล และใช้อัลกอริทึม Support Vector Machine (SVM) และ K-Nearest Neighbor (K-NN) ในการจำแนกโรคทางใบมันสำปะหลัง 5 ชนิด คือ brown leaf spot (BLS), red mite damage (RMD), green mite damage (GMD), cassava brown streak disease (CBSD) และ cassava mosaic disease (CMD) ข้อมูลที่ใช้ถูกรวบรวมจากภาพถ่ายที่เก็บจากกล้องในโทรศัพท์มือถือจำนวน 2,756 ภาพพบว่า SVM ให้ความถูกต้องในการจำแนกมากกว่า K-NN ที่ค่าความแม่นยำสูงสุดร้อยละ 98

ต่อมาได้มีผู้วิจัยใช้อัลกอริทึม Single Shot Detection (SSD) มาใช้ในการจำแนกภาพถ่ายของโรคทางใบของมันสำปะหลังด้วยชุดข้อมูลเดียวกันกับงานวิจัยก่อนหน้านี้ [15] สำหรับงานวิจัยนี้ได้ศึกษาการจำแนก CBSD CMD GMD กับใบพืชที่มีสุขภาพดี ผลการศึกษาพบว่าข้อมูลชุดทดสอบให้ความแม่นยำสูงสุดที่ร้อยละ 94 ในขณะที่เมื่อนำโมเดลมาใช้กับข้อมูลในพื้นที่จริงพบว่าให้ความแม่นยำที่ร้อยละ 80

ในการศึกษาเปรียบเทียบประสิทธิภาพของโมเดลในการจำแนกได้มีผู้ศึกษาเปรียบเทียบอัลกอริทึมที่มีพื้นฐานมาจากโครงข่ายประสาทเทียมแบบคอนโวลูชันสำหรับงานด้าน Computer Vision โดย S. Srivastava และคณะ [16] ได้ทำการเปรียบเทียบประสิทธิภาพของอัลกอริทึม Single Shot Detector (SSD) Faster Region Convolution Neural Network (Faster R-CNN) ที่ใช้ SVM สำหรับการจำแนก และ You Only Look Once (YOLO) โดยใช้ชุดข้อมูล Microsoft COCO พบว่า YOLO มีประสิทธิภาพดีกว่าอัลกอริทึมอื่น

จากประเด็นปัญหาเรื่องการแพร่ระบาดของโรคใบด่างมันสำปะหลัง และประโยชน์ของอากาศยานไร้คนบิน และเทคโนโลยีการเรียนรู้เชิงลึก งานวิจัยนี้จึงนำเสนอการใช้ข้อมูลภาพถ่ายจากอากาศยานไร้คนบิน และโมเดล YOLO v5 ซึ่งเป็นหนึ่งในโมเดลการเรียนรู้เชิงลึกเพื่อตรวจจับโรคใบด่างมันสำปะหลัง

2 วิธีวิจัย

2.1 ข้อมูลที่ใช้ในการวิจัย

ข้อมูลที่ใช้ในการวิจัยเก็บรวบรวมจากแปลงมันสำปะหลังที่ปลูกอยู่ภายในพื้นที่ฟาร์มมหาวิทยาลัยเทคโนโลยีสุรนารี จำนวน 1 แปลง เนื้อที่แปลง 5 ไร่ เป็นมันสำปะหลังสายพันธุ์พิรุณ 2 โดยเป็นแปลงที่มีอายุ 10 เดือน เก็บรวบรวมข้อมูลในช่วงเดือนกรกฎาคม พ.ศ. 2564

อากาศยานไร้คนบินที่ใช้ในการเก็บข้อมูลคือ อากาศยานไร้คนบินรุ่น DJI Phantom 4 Pro ชนิด 4 มอเตอร์ 4 ใบพัด น้ำหนัก 1.38 กิโลกรัม (รวมแบตเตอรี่) เพดานบินสูงสุดไม่เกิน 6,000 เมตรเหนือระดับน้ำทะเล โดยติดตั้งกล้องถ่ายภาพความละเอียด 20 ล้านพิกเซล ระบุตำแหน่งในการบินด้วยระบบ GPS/GLONASS



รูปที่ 1 คือ อากาศยานไร้คนบินที่ใช้ในงานวิจัย

การบินถ่ายภาพเป็นการบินแบบอัตโนมัติโดยใช้ซอฟต์แวร์ Pix4D Capture สำหรับวางแผนและควบคุมการบิน แผนการบินถ่ายภาพเพื่อการเก็บข้อมูลแสดงดังรูปที่ 2 โดยกำหนดความสูงในการบิน 10 เมตร ความเร็วในการบิน 5 เมตรต่อวินาที ได้รับความละเอียดจุดภาพ (Ground Sampling Distance หรือ GSD) ขนาดเท่ากับ 0.27 เซนติเมตรต่อพิกเซล กำหนดให้มีการซ้อนทับของภาพ (Overlap) เท่ากับ 80% รายละเอียดในการวางแผนการบินแสดงดังตารางที่ 1

การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002



รูปที่ 2 การวางแผนการบินด้วย Pix4D Capture

ตารางที่ 1 รายละเอียดการวางแผนการบิน

ตัวแปร	กำหนดขนาด	หมายเหตุ
ความสูงการบิน	10 เมตร	
ความเร็วการบิน	5 เมตร/วินาที	ความเร็วเฉลี่ย
GSD	0.27 เซนติเมตร/พิกเซล	
Front overlap	80%	
Side overlap	80%	

2.2 การเตรียมข้อมูล

ข้อมูลภาพถ่ายดิจิทัลเป็นข้อมูลที่มีลักษณะเป็นค่าตัวเลขในแต่ละจุดหรือพิกเซล โดยจะเก็บค่าความสว่างเป็นตัวเลขระหว่าง 0 ถึง 255 ภาพสีจะประกอบด้วยข้อมูล 3 ชั้น คือ แดง เขียว และน้ำเงิน (RGB)

ในการตรวจจับวัตถุ (Object Detection) จะต้องผ่านขั้นตอนการทำ Image Label เพื่อระบุประเภท (Label) ของข้อมูลตัวอย่างที่ต้องการจำแนก โดยการวาดกรอบ (Bounding box) รอบข้อมูลตัวอย่างที่สนใจ

ชุดข้อมูล (Dataset) ประกอบด้วยภาพถ่ายจำนวน 62 ภาพที่ถูกปรับขนาดภาพเท่ากับ 416x416 และนำมาสร้าง Image Label แบ่งออกเป็น 2 ประเภท คือ Healthy จำนวน 2,087 รูป และ Disease จำนวน 675 รูป รวมจำนวน Image label จำนวน 2,762 รูป ลักษณะของชุดข้อมูลตัวอย่างที่ใช้ในงานวิจัยแสดงในรูปที่ 3 และ 4

ชุดข้อมูลจะถูกแบ่งออกเป็นข้อมูลชุดฝึกฝน (Training set) ข้อมูลสำหรับปรับโมเดล (Validation set)

และข้อมูลชุดทดสอบ (Test set) ในอัตราส่วนร้อยละ 80:10:10 โดยข้อมูลชุดทดสอบจะไม่ถูกนำมาใช้ในการฝึกฝนโมเดล



รูปที่ 3 ชุดข้อมูลตัวอย่างประเภท Disease



รูปที่ 4 ชุดข้อมูลตัวอย่างประเภท Healthy

2.3 โมเดลการเรียนรู้เชิงลึก

สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ประกอบด้วยสองส่วน คือ Feature Extraction สำหรับการแยกแยะคุณลักษณะเด่นของวัตถุภายในภาพ และนำคุณลักษณะเด่นเป็น Input เข้าประมวลผลในโครงข่ายประสาทเทียมเพื่อเข้าสู่กระบวนการ Classification

You Only Look Once (YOLO) เป็นอัลกอริทึมแบบประมวลผล 1 ครั้งแล้วได้ผลลัพธ์ ทำให้มีความเร็วและความแม่นยำสูง จึงได้รับความนิยมอย่างมากในการตรวจจับวัตถุแบบ Real-time หลักการทำงานของ YOLO จะแบ่งภาพออกเป็นตารางกริด (grid) ก่อนส่งเข้าประมวลผลเพื่อจำแนกประเภท (Classification) และระบุตำแหน่ง (Localization) โดยความแตกต่างของสถาปัตยกรรม CNN Image Classification และ YOLO คือ CNN จะมี Label ระบุ class ของภาพ แต่ในส่วนของ YOLO จะมี Label เป็นเวกเตอร์หรือเมทริกซ์ขนาด 1 มิติ โดยพิจารณาภาพที่ถูกแบ่งออกเป็นกริด หากไม่มีวัตถุที่สนใจอยู่ในกริดโมเดลจะเลือกไม่พิจารณาบริเวณนั้น เมื่อโมเดลพิจารณาครบทุกกริดจะได้ Tensor หรือเมทริกซ์ขนาด 3 มิติ ซึ่งเป็นค่า Label ในแต่ละกริดภายในภาพ

การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002



โมเดล YOLO มีการประมวลผลภาพสำหรับทำ Augmentation ให้สำหรับการฝึกฝนโมเดล สำหรับการป้องกันการเกิด Overfitting [17] สำหรับ YOLOv5 เป็นเวอร์ชันอัปเดตให้มีความเร็ว และแม่นยำมากขึ้น โดยแบ่งออกเป็น 3 ขนาดคือ small (s) medium (m) และ large (l) โดยแบ่งออกตามจำนวนพารามิเตอร์ที่ใช้เพิ่มขึ้นในการประมวลผล มีผู้ทำการศึกษาเปรียบเทียบประสิทธิภาพของโมเดล YOLO อื่นในด้านความเร็ว และความแม่นยำในการตรวจจับเซลล์เม็ดเลือด พบว่า YOLOv5 มีความแม่นยำสูงกว่าโมเดลอื่น 10% เมื่อเทียบกับ YOLOv4 และแม่นยำสูงกว่า 15% เมื่อเทียบกับ YOLOv3 แต่ใช้เวลาในการฝึกฝนโมเดลมากกว่า [18]

งานวิจัยนี้จึงนำเสนอการตรวจจับโรคใบด่างมันสำปะหลังภายในแปลงด้วยโมเดล YOLOv5s ที่มีจำนวนพารามิเตอร์ในการประมวลผลไม่เกิน 7.3 ล้าน โดยเลือกประมวลผลโมเดลบนแพลตฟอร์ม Google Colab ซึ่งมีการประมวลผลด้วย GPU บนระบบ Cloud โดยกำหนดจำนวนข้อมูลที่ใช้ประมวลผลแต่ละรอบ (Batch size) เท่ากับ 32 และจำนวนรอบที่ใช้ในการประมวลผล (Epochs) เท่ากับ 1,000 รอบ

2.4 การประเมินประสิทธิภาพโมเดล

การประเมินประสิทธิภาพของโมเดลจะใช้ตาราง Confusion Matrix โดยพิจารณาจาก TP และ TN เป็นค่าที่ทำนายได้ถูกต้อง และค่า FP และ FN เป็นค่าที่ทำนายผิด ลักษณะของตาราง Confusion Matrix แสดงในรูปที่ 5

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

รูปที่ 5 Confusion Matrix

จากรูปที่ 5 พิจารณาประสิทธิภาพโมเดลโดยพิจารณาจากการคำนวณค่า Precision (P), Recall (R), F1 score และ Mean Average Precision (mAP)

Precision คือ ความแม่นยำผลทำนาย โดยสนใจผลทำนายหรือ Prediction คำนวณจากสัดส่วนผลการทำนาย Positive และ Negative โดยแสดงว่าผลการทำนายจากร้อยละที่ทำนายถูกต้อง แสดงได้ดังสมการที่ (1)

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

Recall คือการวัดความแม่นยำ ที่สนใจจากผลลัพธ์เทียบกับค่าจริง แสดงได้ดังสมการที่ (2)

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

F1 Score เป็นค่าที่แสดงประสิทธิภาพของโมเดล โดยคำนวณค่าเฉลี่ย Precision กับ Recall Model ที่มีประสิทธิภาพสูง F1 score จะมีค่าสูงแสดงได้ดังสมการที่ (3)

$$F1\ score = \frac{2 \cdot P \cdot R}{P + R} \quad (3)$$

Mean Average Precision (mAP) คือค่าเฉลี่ยความแม่นยำที่ โดย mAP@.5 คือ mAP ที่ IoU 0.5 และ mAP@.5:.95 คือ mAP ที่ IoU 0.5 – 0.95 โดยค่า IoU คือค่าที่บ่งบอกการซ้อนทับของผลเฉลย (Ground Truth) และผลการทำนาย (Predict)


การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002




3 ผลการวิจัย

ผลการวิจัยเมื่อทำการนำชุดข้อมูลฝึกฝนป้อนให้กับ
โมเดล โดยกำหนดรอบการประมวลผล 1,000 รอบ และ
Batch size มีขนาด 32 ใช้เวลาในการประมวลผลรวม 24
นาที่ 20 วินาที โดยพล็อตบันทึกผลการฝึกฝนโมเดล แสดงใน
รูปที่ 6 และ 7



รูปที่ 6 บันทึกการ Train แสดงค่า Loss




รูปที่ 7 บันทึกการ Train แสดงค่า Precision Recall และ
Mean Average Precision

จากรูปที่ 6 และ 7 พบว่าให้ค่า Training Loss และ
Validation Loss เท่ากับ 0.002 และ 0.001 ตามลำดับ
สำหรับค่า Precision รวม เท่ากับ 99.8% ค่า Recall รวม
เท่ากับ 99.2% ค่า F1-Score รวมเท่ากับ 0.995 และมีค่า
Mean Average Precision (mAP) เท่ากับ 0.997 หรือ
99.7% ผลการประเมินความแม่นยำของโมเดลแสดงดังตาราง
ที่ 2

ตารางที่ 2 ผลการประเมินความแม่นยำโมเดล

Class	P	R	F1-score	mAP @.5	mAP @.5-.95
All	0.998	0.992	0.995	0.997	0.850
Disease	1.000	0.989	0.994	0.996	0.845
Healthy	0.995	0.994	0.994	0.998	0.855

หลังจากขั้นตอนการฝึกฝนโมเดลจะได้ค่า Weight
เพื่อใช้สำหรับการตรวจจับวัตถุในชุดข้อมูลทดสอบ ซึ่งเป็น
ข้อมูลที่ไม่ถูกใช้ในการฝึกฝนโมเดลมาก่อน ตัวอย่างผลการ
ตรวจจับวัตถุในชุดข้อมูลทดสอบ แสดงได้ในรูปที่ 8 และ 9



รูปที่ 8 ผลการตรวจจับวัตถุในชุดข้อมูลทดสอบ

การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002



รูปที่ 9 ผลการตรวจจับต้นมันสำปะหลังที่มีสุขภาพดี (Healthy) และเป็นโรค (Disease) ภายในรูป

4 สรุปผลการวิจัย

งานวิจัยนี้ได้ทำการประเมินประสิทธิภาพของโมเดล YOLOv5 ในการตรวจจับโรคใบด่างมันสำปะหลังภายในแปลงมันสำปะหลังสายพันธุ์พิจิตร 2 อายุ 10 เดือน โดยมีเนื้อที่ปลูก 5 ไร่ภายในพื้นที่มหาวิทยาลัยเทคโนโลยีสุรนารี จากข้อมูลภาพถ่ายที่ได้จากอากาศยานไร้คนบังคับจำนวน 62 ภาพ ซึ่งถูกนำมาสร้างชุดข้อมูล Image label จำนวน 2,762 รูป โดยแบ่งออกเป็น 2 ประเภท คือ Healthy จำนวน 2,087 รูป และ Disease จำนวน 675 รูป แบ่งชุดข้อมูลออกเป็น ชุดฝึกฝน ข้อมูลสำหรับปรับจูนโมเดล และชุดทดสอบ ในอัตราส่วนร้อยละ 80:10:10 นำชุดข้อมูลมาประมวลผล ข้อมูลด้วยโมเดล YOLOv5s ที่กำหนดกำหนดจำนวนข้อมูลที่ ใช้ประมวลผลในแต่ละรอบ เท่ากับ 32 และจำนวนรอบที่ใช้ ในการประมวลผล เท่ากับ 1,000 รอบโดยประมวลผลโมเดล บนแพลตฟอร์ม Google Colab พบว่าผลการประเมินได้ ค่า Precision รวม เท่ากับ 99.8% ค่า Recall รวม เท่ากับ 99.2% ค่า F1-Score รวมเท่ากับ 0.995 และมีค่าเฉลี่ยความแม่นยำรวม (mAP) ที่ 99.7% สำหรับค่า Training Loss และ Validation Loss มีค่าเท่ากับ 0.002 และ 0.001 ตามลำดับ จากผลการศึกษารังนี้เห็นเพียงการศึกษาใน 1 แปลงตัวอย่างในช่วงอายุ 10 เดือนหลังปลูกเท่านั้น หากเพิ่มจำนวนแปลงที่ใช้เก็บข้อมูล ในหลากหลายสายพันธุ์ และช่วงอายุของต้นมันสำปะหลัง จะสามารถเพิ่มประสิทธิภาพของ

โมเดลให้มากขึ้น และสามารถนำไปใช้งานได้ในพื้นที่แปลงมันสำปะหลังที่หลากหลายยิ่งขึ้น

5 กิตติกรรมประกาศ

ขอขอบคุณห้องปฏิบัติการ Autonomous Control and System Engineering Laboratory (ACSE) สาขาวิชาวิศวกรรมเครื่อง มหาวิทยาลัยเทคโนโลยีสุรนารี ที่ให้การสนับสนุนในการทำงานวิจัย และขอขอบคุณสาขาวิชาเทคโนโลยีผลิตพืช สำนักวิชาเทคโนโลยีการเกษตร มหาวิทยาลัยเทคโนโลยีสุรนารี สำหรับการให้ความอนุเคราะห์พื้นที่เก็บข้อมูลงานวิจัย

6 เอกสารอ้างอิง

- [1] สำนักงานเศรษฐกิจการเกษตร (2558). ข้อมูลการผลิตสินค้าเกษตร, [ระบบออนไลน์], แหล่งที่มา <https://www.oae.go.th/view/1/ตารางแสดงรายละเอียดมันสำปะหลัง/TH-TH>, เข้าดูเมื่อวันที่ 11/03/2022
- [2] วชิริน มีรอด, กุลวรงค์ สุวรรณศรี และ กฤษดา บำรุงวงศ์ (2558). การศึกษาผลกระทบและเตรียมความพร้อมของภาคเกษตรไทย สู่ประชาคมอาเซียน: กรณีศึกษามันสำปะหลัง. ปทุมธานี: สำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ, พฤษภาคม 2557, หน้า 11 – 21.
- [3] สำนักงานเศรษฐกิจการเกษตร (2556). ข้อมูลการผลิตสินค้าเกษตร, [ระบบออนไลน์], แหล่งที่มา www.oae.go.th/view/1/ตารางแสดงรายละเอียดมันสำปะหลัง/TH-TH, เข้าดูเมื่อวันที่ 11/03/2022
- [4] สถาบันวิจัยพืชไร่ กรมวิชาการเกษตร (2551). เอกสารแนะนำพันธุ์มันสำปะหลัง, [ระบบออนไลน์], แหล่งที่มา www.opsmoac.go.th%2Fphayao-dwl-files, เข้าดูเมื่อวันที่ 11/03/2022
- [5] ศูนย์วิจัยกสิกรรมไทย. (2560). โดรนเพื่อการเกษตร...กำลังมาแรงเพื่อสร้างทางเลือกในยุคเกษตร 4.0, [ระบบออนไลน์], แหล่งที่มา <https://www.newsdata.today.com/images/News/OO1-2-18/8699.pdf>, เข้าดูเมื่อวันที่ 11/03/2022
- [6] C. S. Hlaing, and S. M. M. Zaw (2017). Model-based statistical features for mobile phone image of tomato plant disease classification, Applications and

การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36
วันที่ 19-22 กรกฎาคม พ.ศ. 2565 จังหวัดประจวบคีรีขันธ์

CST-0002



- Technologies (PDCAT), vol.18, December 2017, pp. 223 - 229.
- [7] A. Johannes, A. Picon, A. Alvarez-Gila, J. Echazarra, S. Rodriguez-Vaamonde, A. D. Navajas, and A. Ortiz-Barredo (2017). Automatic plant disease diagnosis using mobile capture devices, *Computers and electronics in agriculture*, vol.138, June 2017, pp. 200-209.
- [8] B. Kusumo, A. Heryana, O. Mehendra, and H. Predede (2019). Machine learning-based for automatic detection of corn-plant diseases using image processing, *International Conference on Computer, Control, Informatics and its Applications (IC3INA)*, November 2019, pp. 93 - 97.
- [9] R. Yuwana, E. Suryawati, V. Zilvan, A. Ramdan, H. Pardede, and F. Fauziah (2019). Multi-condition training on deep convolutional neural networks for robust plant diseases detection, *International Conference on Computer, Control, Informatics and its Applications (IC3INA)*, October 2019, pp. 30 - 35.
- [10] D. Oppenheim, G. Shani, O. Erlich, and L. Tsrer (2019) Using deep learning for image-based potato tuber disease detection, *Phytopathology*, vol.109, April 2019, pp.1083 - 1087.
- [11] S. Mohanty, D. Hughes, and M. Salath (2016) Using deep learning for image- based plant disease Detection, *Frontiers in Plant Science*, vol.7, September 2016, pp.59069 - 59080.
- [12] R. Veeraballi, M. Nagugari, C. Annavarapu, and E. Gownipuram (2020) Deep learning based approach for classification and detection of papaya leaf diseases, *Advances in Intelligent Systems and Computing*, vol.940, January 2020, pp.291 - 302.
- [13] K. Ferentinos (2018) Deep learning models for plant disease detection and diagnosis, *Computers and Electronics in Agriculture*, vol.145, February 2018, pp.311 - 318.
- [14] A. Ramcharan, K. Baranowski, P. McCloskey, B. Ahmed, J. Legg, and D. P. Hughes (2017) Deep Learning for Image-Based Cassava Disease Detection, *Frontiers in Plant Science*, vol.8, October 2017.
- [15] A. Ramcharan, P. McCloskey, K. Baranowski, N. Mbilinyi, L. Mrisho, M. Ndalawha, J. Legg and, D. P. Hughes (2019) A mobile-Based Deep Learning Model for Cassava Disease Diagnosis, *Frontiers in Plant Science*, vol.10, March 2019.
- [16] S. Srivastava, A. V. Divekar, C. Anilkumar, I. Naik, V. Kulkarni and, V. Pattabiraman (2021) Comparative analysis of deep learning image detection algorithms, *Journal of Big Data*, vol.66, May 2021.
- [17] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi (2016) You Only Look Once: Unified, Real-Time Object Detection, *arXiv*, vol.1, May 2016.
- [18] A. Ramya (2021) Comparison of YOLOv3, YOLOv4 and YOLOv5 Performance for Detection of Blood Cells, *International Research Journal of Engineering and Technology (IJRET)*, vol.4, April 2021, pp.4225 - 4229.



Content List Available at ThaiJo

Khon Kaen Agriculture Journal

Journal Home Page : <https://li01.tci-thaijo.org/index.php/agkasetkaj>

การประเมินผลผลิตมันสำปะหลัง ด้วยภาพถ่ายจากอากาศยานไร้คนขับ

A cassava yield estimation using aerial imagery-derived UAV

อนาวิน เพ็ชรบุณินิล^{1*} และ สุรเดช ตัญญูรัตน์¹Anawin Pechbooranin^{1*} and Suradet Tantrairatn¹¹ สาขาวิชาวิศวกรรมเครื่องกล สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี 111 ถนนมหาวิทยาลัย ตำบลสุรนารี อำเภอเมืองนครราชสีมา จังหวัดนครราชสีมา รหัสไปรษณีย์ 30000¹ School of Mechanical Engineering, Institute of Engineering, Suranaree University of Technology, 111, University Avenue, Muang Nakhon Ratchasima, Nakhon Ratchasima, 30000

บทคัดย่อ: การประเมินผลผลิตมันสำปะหลังได้อย่างรวดเร็วและแม่นยำส่งผลดีต่อโรงงานอุตสาหกรรมของไทย งานวิจัยนี้มีวัตถุประสงค์เพื่อประเมินผลผลิตของมันเป็นสำปะหลังพันธุ์ระยอง 72 ในช่วง 8-12 เดือนหลังปลูกโดยใช้ภาพถ่ายหลายช่วงคลื่นจากอากาศยานไร้คนขับที่มีความละเอียดภาพ 0.33 ซม. และทำการสุ่มตัวอย่างเพื่อรวบรวมข้อมูลภาคพื้นดิน ดำเนินการศึกษาโดยเปรียบเทียบประสิทธิภาพของการประเมินผลผลิตด้วยดัชนีพืชพรรณ ExG, GRVI และ NDVI กับแบบจำลองสมการถดถอยเชิงเส้น การประเมินน้ำหนักของหัวมันสำปะหลังสดพบว่าดัชนีพืชพรรณ NDVI ให้ค่า R^2 สูงที่สุดที่ 0.82 และมีค่า RMSE เท่ากับ 0.38 กก./ตร.ม. ขณะที่การประเมินปริมาณแป้งในหัวมันสำปะหลังสดหรือเปอร์เซ็นต์แป้ง พบว่ามีค่า R^2 ค่อนข้างต่ำโดยดัชนี ExG ให้ค่าสูงที่สุดเท่ากับ 0.34 และมีค่า RMSE เท่ากับ 3.35 % เนื่องจากปริมาณแป้งในหัวมันสำปะหลังสดจะเปลี่ยนแปลงไปตามปัจจัยภายนอกมากกว่าลักษณะความสมบูรณ์ของลำต้นและใบ การประเมินผลผลิตในงานวิจัยนี้มีความจำเพาะกับมันเป็นสำปะหลังพันธุ์ระยอง 72 ที่ปลูกในชุดดินบุรี แต่สามารถนำไปใช้เป็นแนวทางในการประเมินผลผลิตในพื้นที่อื่นได้

คำสำคัญ: อากาศยานไร้คนขับ; การประเมินผลผลิต; มันสำปะหลัง

ABSTRACT: Accurate evaluation of cassava production makes benefits the Thai industrial sector. This research's objective was to evaluate cassava yield (Rayong 72) at 8-12 months after planting using multispectral images from unmanned aerial vehicle (UAV) with GSD 0.33 cm and ground sampling data. A study compared the efficiency of yield evaluation with ExG, GRVI, and NDVI vegetation indices with linear regression models. The prediction yield model found that the weight of fresh cassava root with NDVI vegetation index gave the highest R^2 at 0.82 and has an RMSE of 0.38 kg/m². In contrast, the starch percentage of fresh cassava found that R^2 was relatively low, with the ExG index giving it the highest value. The highest is 0.34 and has an RMSE of 3.35%. This was because the percentage of starch in fresh cassava tubers varied more according to external factors than the integrity of the stems and leaves. This research was specific to Rayong 72 cassava cultivar grown in Khon Buri soil series, however, it can be used as a guide for evaluating production in other areas.

Keywords: unmanned aerial vehicle; yield prediction; cassava

บทนำ

มันสำปะหลังเป็นพืชเศรษฐกิจที่สำคัญของประเทศไทยและเป็นพืชอาหารที่สำคัญของโลก เนื่องด้วยมันเป็นแหล่งคาร์โบไฮเดรตที่มีราคาถูกกว่าผลผลิตแป้งชนิดชนิดอื่น มันสำปะหลังถูกแปรรูปในอุตสาหกรรมอาหาร อาหารสัตว์ ยา กระดาษ

* Corresponding author: anawin.pech@gmail.com

Received: date; December 9, 2022 Accepted: date; October 25, 2023 Published: date; December 12, 2023

เคมีภัณฑ์ และพลังงานชีวภาพ มันสำปะหลังเป็นพืชอาหารที่มีคนบริโภคมากเป็นอันดับ 5 ของโลก รองจาก ข้าวโพด ข้าวสาลี ข้าวเจ้า และมันฝรั่ง (วิชิติน และคณะ, 2558; ชัยวิทย์, 2566) สำหรับประเทศไทยมันสำปะหลังเป็น 1 ใน 5 ของพืชเศรษฐกิจที่สำคัญของไทย เช่นเดียวกับข้าว ยางพารา ปาล์ม และอ้อย โดยมีเกษตรกรผู้ปลูกมันสำปะหลังประมาณ 738,153 ครัวเรือนส่วนใหญ่เป็นเกษตรกรรายย่อย พื้นที่เพาะปลูกมันสำปะหลังเฉลี่ยต่อครัวเรือนอยู่ที่ 23,552 ตร.ม./ครัวเรือน โดยมีพื้นที่ปลูกทั้งประเทศจำนวน 17,379.16 ตร.กม. พื้นที่ปลูกส่วนใหญ่อยู่ในภาคตะวันออกเฉียงเหนือจำนวน 9,414,8384 ตร.กม. และจังหวัดที่มีการเพาะปลูกมันสำปะหลังมากที่สุด คือ นครราชสีมา ชัยภูมิ กำแพงเพชร กาญจนบุรี นครสวรรค์ และอุบลราชธานี ตามลำดับ (สำนักงานเศรษฐกิจการเกษตร, 2565) ประเทศไทยผลิตมันสำปะหลังอันดับที่ 3 ของโลก และอันดับที่ 1 ของภูมิภาคเอเชียตะวันออกเฉียงใต้ มีปริมาณส่งออกเฉลี่ย 29 ล้านตัน คิดเป็นสัดส่วนทางการตลาดที่ร้อยละ 9.6 ของประเทศผู้ส่งออกทั่วโลกและปริมาณผลผลิตสูงสุดที่ผลิตได้คือ 35 ล้านตันในปี 2564-2565 ความต้องการมันสำปะหลังเพิ่มขึ้นอย่างต่อเนื่องทั้งตลาดภายในประเทศ และตลาดส่งออก เนื่องมาจากการขยายตัวอย่างต่อเนื่องของอุตสาหกรรมในประเทศจีน โดยมีความต้องการใช้มันสำปะหลังในการผลิตเอทานอล และอาหารสัตว์ นอกจากนี้ความต้องการมันสำปะหลังสำหรับการแปรรูปเพื่อบริโภคเป็นอาหารยังคงเพิ่มขึ้น เนื่องจากสถานการณ์ความขัดแย้งระหว่างยูเครนและรัสเซีย อย่างไรก็ตามปริมาณผลผลิตที่ไม่แน่นอนเนื่องจากสภาพอากาศ และการระบาดของโรคใบด่างมันสำปะหลังยังคงเป็นอุปสรรคสำคัญของอุตสาหกรรมมันสำปะหลัง (ชัยวิทย์, 2566)

ปัญหาความไม่สมดุลระหว่างผลผลิตที่ผลิตได้และปริมาณความต้องการทำให้เกิดปัญหามันสำปะหลังขาดแคลนและล้นตลาด ในบางช่วงเวลาส่งผลเสียโดยตรงต่ออุตสาหกรรมที่ใช้มันสำปะหลังเป็นวัตถุดิบหลัก (มูลนิธิสถาบันมันสำปะหลังฯ, 2557) โดยกลุ่มที่ได้รับผลกระทบมากที่สุดคือเกษตรกรชาวไร่มันสำปะหลังรายย่อยซึ่งเป็นกลุ่มอุตสาหกรรมต้นน้ำ หากมีการคาดการณ์ปริมาณผลผลิตที่แม่นยำจะส่งผลดีต่อการวางแผนการผลิต ปัจจุบันการคาดการณ์ปริมาณผลผลิตมันสำปะหลังยังมีข้อจำกัดหลายประการ เนื่องจากวิธีการตรวจวัดภาคสนามภายในแปลงขนาดใหญ่มีความยุ่งยากสูงทำให้เกษตรกรยังคงใช้วิธีการคาดคะเนด้วยประสบการณ์ โดยปัญหาที่พบคือยิ่งแปลงมีขนาดใหญ่ยิ่งเกิดโอกาสประเมินผิดพลาดได้มาก (Chu et al., 2017) เทคโนโลยีการสำรวจระยะไกลจึงเป็นเครื่องมือที่มีบทบาทสำคัญด้านการตรวจวัดและวิเคราะห์ข้อมูลภายในแปลงโดยช่วยเพิ่มความแม่นยำ ลดระยะเวลาและประหยัดทรัพยากรในการสำรวจพื้นที่ทางการเกษตรขนาดใหญ่ (Jensen, 2007)

การสำรวจระยะไกลโดยใช้ข้อมูลภาพถ่ายดาวเทียมสำหรับงานด้านการเกษตรยังมีข้อจำกัดที่ช่วงเวลาในการโคจรที่รอบที่จำเพาะช่วงเวลาและภาพมีความละเอียดจุดภาพที่ต่ำ ส่งผลให้ความละเอียดของภาพไม่เพียงพอต่อการวิเคราะห์ข้อมูลที่ต้องการ เทคโนโลยีอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) จึงเป็นทางเลือกที่เหมาะสมกว่าในการเก็บข้อมูลภายในแปลงด้วยความสะดวก รวดเร็ว มีความละเอียดข้อมูลสูง และมีต้นทุนที่ต่ำกว่า (Zhao and Lee, 2020)

งานวิจัยจำนวนมากได้นำเสนอแนวทางการคาดการณ์ปริมาณผลผลิตทางการเกษตรโดยใช้ข้อมูลภาพถ่ายทางอากาศจากเซนเซอร์ที่ติดตั้งบนอากาศยานไร้คนขับ โดยข้อมูลภาพจะเป็นข้อมูลที่ได้จากการสะท้อนของวัตถุด้วยภาพถ่ายในช่วงคลื่นแสงที่ตามองเห็นได้ในช่วงคลื่นแสงสีแดง (Red) สีเขียว (Green) และสีน้ำเงิน (Blue) หรือภาพ RGB และภาพถ่ายหลายช่วงคลื่น (Multispectral Images) ข้อมูลการสะท้อนจะถูกนำมาคำนวณด้วยสมการเพื่อหาค่าดัชนีพืชพรรณ (Vegetation Index) ในการแสดงบริเวณที่เป็นพืช โดยงานวิจัยของ พรหมชัย และคณะ (2561) ได้ศึกษาวิธีการติดตามการเจริญเติบโตของข้าวด้วยภาพถ่ายจากอากาศยานไร้คนขับโดยใช้ดัชนีพืชพรรณ Normalize Red Blue Difference Index ที่คำนวณจากแสงในช่วงคลื่นสีแดงและน้ำเงินที่ได้จากภาพถ่าย RGB ในการติดตามการเจริญเติบโตในระยะข้าวแตกกอจนถึงเมล็ดข้าวสุกแก่ จากการศึกษาพบว่าความสัมพันธ์ของการสะท้อนแสงสองชนิดสามารถใช้ในการติดตามการเจริญเติบโตของพืชได้ ดัชนีพืชพรรณที่ได้จากภาพถ่ายด้วยกล้องถ่ายภาพหลายช่วงคลื่น (Multispectral Sensor) จะสามารถเก็บข้อมูลภาพถ่ายในช่วงคลื่นอินฟราเรดย่านใกล้ (Near Infrared: NIR) ได้โดยเป็นที่ยอมรับอย่างมากในการคำนวณหาดัชนี Normalize Difference Vegetation Index (NDVI) เพื่อใช้ในการติดตามพื้นที่เพาะปลูกโดยได้มีผู้ศึกษาประสิทธิภาพของการใช้ดัชนี NDVI เปรียบเทียบกับดัชนีที่ได้จากภาพถ่าย RGB ในการติดตามการเจริญเติบโตของนาข้าว (ปริยฉัตร, 2563) พบว่าดัชนี Excess Green (ExG), Visible Difference Vegetation Index (VDVI) และ Green Red Vegetation Index (GRVI) มีความสัมพันธ์ในระดับสูงกับค่าดัชนี NDVI ที่ระยะข้าวแตกกอ และพบว่าดัชนี GRVI ให้ความถูกต้องสูงสุดที่ร้อยละ 90.32 Tumtisan

(2017) ได้ศึกษาการคาดการณ์ผลผลิตข้าวโพดโดยใช้ดัชนีพืชพรรณจากภาพถ่ายด้วยอากาศยานไร้คนขับด้วยกล้อง RGB จำนวน 7 ดัชนี ได้แก่ ExG, CIVE, VEG, ExGR, NGRDI และ COM โดยหาความสัมพันธ์ระหว่างค่าดัชนีพืชพรรณ ปริมาณผลผลิตและชีวมวลของพืชโดยใช้สมการถดถอยเชิงเส้น จากการศึกษาพบว่าดัชนี ExG ให้ค่าสัมประสิทธิ์การตัดสินใจ (R^2) สูงสุดที่ 0.50 จีรวัฒน์ และคณะ (2562) ได้ศึกษาวิธีการทำนายผลผลิตของอ้อยโดยใช้ภาพถ่ายจากกล้องถ่ายภาพหลายช่วงคลื่นที่ติดตั้งบนอากาศยานไร้คนขับ เพื่อคำนวณดัชนีพืชพรรณ NDVI และ $CI_{red\ edge}$ ร่วมกับข้อมูลปริมาตรแบบจำลองพื้นผิวเชิงตัวเลข (Digital Surface Model, DSM) เพื่อนำมาหาความสัมพันธ์กับผลผลิตภายในแปลง การศึกษานี้พบว่าการใช้ข้อมูล DSM ให้ค่า R^2 สูงที่สุดที่ 0.82 สำหรับดัชนี NDVI และ $CI_{red\ edge}$ ให้ค่า R^2 ที่ 0.77 และ 0.78 ตามลำดับ ทั้งนี้ข้อมูล DSM บ่งบอกถึงปริมาตรของอ้อยซึ่งมีผลโดยตรงต่อปริมาณผลผลิตของอ้อยแต่ไม่ได้ให้ข้อมูลเกี่ยวกับความสมบูรณ์ของลำต้นอ้อย และงานวิจัยนี้ยังไม่ได้ทำการตัดส่วนที่ไม่ใช่พืชออกจากข้อมูลภาพที่ใช้ในการสร้างสมการทำนายจึงทำให้เกิดความผิดพลาดขึ้น มันสำปะหลังเป็นพืชที่ให้ผลผลิตในรูปของหัวใต้ดินการประเมินผลผลิตมันสำปะหลังจึงเป็นเรื่องที่ค่อนข้างยากและอาศัยประสบการณ์เป็นสำคัญ อย่างไรก็ตามความอุดมสมบูรณ์ของพืชที่แสดงออกจากลักษณะของลำต้นและใบอาจเป็นสิ่งที่บ่งชี้ถึงปริมาณผลผลิต (กรมวิชาการเกษตร, 2547) โดยผลผลิตมันสำปะหลังจะพิจารณาที่น้ำหนักของหัวมันสำปะหลังสด และปริมาณแป้งในหัวมันสำปะหลังสดหรือเปอร์เซ็นต์แป้งในระยะเก็บเกี่ยวที่ 8 ถึง 12 เดือนหลังปลูกเป็นสำคัญ

จากงานวิจัยดังกล่าวข้างต้นผู้วิจัยจึงนำเทคนิคการประมาณผลผลิตด้วยการเรียนรู้ของเครื่อง (Machine Learning) มาประยุกต์ใช้ในการคาดการณ์ผลผลิตมันสำปะหลังโดยงานวิจัยนี้มีวัตถุประสงค์เพื่อหาแนวทางการประมาณน้ำหนัก และปริมาณแป้งในหัวมันสำปะหลังสดจากข้อมูลดัชนีพืชพรรณ ExG, GRVI และ NDVI ที่คำนวณได้ภาพถ่ายหลายช่วงคลื่นด้วยกล้อง RGB และ กล้องถ่ายภาพหลายช่วงคลื่นที่ติดตั้งบนอากาศยานไร้คนขับในพื้นที่แปลงตัวอย่าง งานวิจัยนี้มีขอบเขตการประมาณปริมาณผลผลิตในช่วง 3 เดือนก่อนระยะเก็บเกี่ยว หรือในช่วง 8 – 12 เดือนหลังปลูก สำหรับมันสำปะหลังพันธุ์ระยอง 72 ที่ปลูกบนชุดดิน ครบุรี ด้วยแบบจำลองสมการถดถอยเชิงเส้น และประเมินประสิทธิภาพของแบบจำลองโดยใช้ค่า R^2 และค่ารากที่สองของความผิดพลาดกำลังสองเฉลี่ย (RMSE) ของแบบจำลองด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ เพื่อหาค่าดัชนีพืชพรรณที่มีความเหมาะสมที่สุดในการประเมินปริมาณผลผลิต

วิธีการศึกษา

ตัวอย่างที่ใช้ในการศึกษา

งานวิจัยนี้ศึกษาบนแปลงมันสำปะหลังพันธุ์ระยอง 72 ของเกษตรกรในพื้นที่ตำบลเฉลียง อำเภอบึงสามพัน จังหวัดนครราชสีมา พิกัด 14°22'33.4416"N 102°17'54.73622"E โดยมีพื้นที่เพาะปลูกที่ใช้ในการศึกษารวม 12,800 ตร.ม. (Figure 1) มีระยะห่างระหว่างแถว 120 ซม. ระยะระหว่างต้น 70 ซม. ให้น้ำด้วยระบบสายน้ำหยดเพื่อควบคุมการได้รับน้ำของพืช ซึ่งส่งผลโดยตรงต่อการเจริญเติบโตของต้นมันสำปะหลังภายในแปลง (Machikowa et al., 2020; Santisopasri et al., 2001; Sriroth et al., 2001) แปลงตัวอย่างปลูกเมื่อวันที่ 14 พฤษภาคม พ.ศ. 2564 แบ่งพื้นที่แปลงออกเป็น 12 แปลงย่อย โดยมีพื้นที่แปลงย่อยละ 900 ตร.ม. การศึกษานี้เก็บข้อมูลตัวอย่างในช่วง 8 – 11 เดือนหลังปลูก (ประมาณ 240 – 360 วันหลังปลูก) ระหว่างเดือนธันวาคม พ.ศ. 2564 ถึงกุมภาพันธ์ พ.ศ. 2565 ความถี่ในการเก็บข้อมูลทุก 30 วัน โดยแบ่งการเก็บข้อมูลออกเป็น 3 รอบ ได้แก่ รอบที่ 1 วันที่ 28 ธันวาคม พ.ศ. 2564 รอบที่ 2 วันที่ 29 มกราคม พ.ศ. 2565 และรอบที่ 3 วันที่ 29 กุมภาพันธ์ พ.ศ. 2565 ข้อมูลที่ใช้ในการศึกษาประกอบด้วยตัวแปรสำคัญจำนวน 5 ตัวแปร ได้แก่ ดัชนีพืชพรรณ 3 ดัชนีคือ NDVI, ExG และ GRVI น้ำหนักของหัวมันสำปะหลังสดเฉลี่ย และปริมาณแป้งในหัวมันสำปะหลังสดเฉลี่ย ตัวแปรสำคัญแต่ละตัวจะประกอบด้วยข้อมูลจำนวน 36 ข้อมูลจากจำนวนตัวอย่างทั้งหมดในการศึกษานี้ 360 ตัวอย่าง




Figure 1 Study area at Khon Buri District, Nakhon Ratchasima Province

แผนการปฏิบัติงาน

วิธีการศึกษาเริ่มจากการเก็บข้อมูลภาพถ่ายจากอากาศยานไร้คนขับโดยใช้กล้องถ่ายภาพ 2 ชนิด คือ กล้อง RGB และกล้องถ่ายภาพหลายช่วงคลื่น จากนั้นจึงเก็บข้อมูลตัวอย่างมันสำปะหลังภายในแปลง คือ น้ำหนักของหัวมันสำปะหลังสด (Weight) และปริมาณแป้งในหัวมันสำปะหลังสดหรือเปอร์เซ็นต์แป้ง (Percent Starch) ภายในวันเดียวกัน เพื่อจัดทำชุดข้อมูลในแต่ละรอบการเก็บข้อมูล ขั้นตอนถัดไปคือการชั่งน้ำหนักและวัดปริมาณแป้งของตัวอย่างหัวมันสำปะหลังสด สำหรับข้อมูลภาพถ่ายจะถูกนำไปเข้าสู่ขั้นตอนการประมวลผลภาพ และคำนวณค่าดัชนีพืชพรรณ เมื่อเก็บข้อมูลครบทุกรอบการเก็บข้อมูลจึงนำข้อมูลผลผลิตกับค่าตัวเลขดัชนีพืชพรรณ (Vegetation index) ของแต่ละตัวอย่างมาจัดทำชุดข้อมูล (Dataset) โดยแบ่งข้อมูลออกเป็นข้อมูลชุดฝึกฝน (Training set) จำนวน 29 ข้อมูล (ร้อยละ 80) เพื่อใช้ในการฝึกฝนแบบจำลองสมการถดถอยเชิงเส้น (Linear Regression model) และข้อมูลชุดทดสอบ (Test set) จำนวน 7 ข้อมูล (ร้อยละ 20) เพื่อทดสอบแบบจำลอง จากนั้นจึงประเมินประสิทธิภาพแบบจำลองจากข้อมูลทั้ง 2 ชุดโดยใช้ค่า R^2 และ RMSE จากข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ แผนการปฏิบัติงานของงานวิจัยนี้แสดงขั้นตอนได้ใน Figure 2




Figure 2 Research plan flowchart

อากาศยานไร้คนขับที่ใช้ในการเก็บข้อมูล

อากาศยานที่ใช้ในการเก็บข้อมูลภาพถ่าย เป็นอากาศยานไร้คนขับรุ่น DJI Phantom 4 Pro ชนิด 4 มอเตอร์ 4 ใบพัด น้ำหนัก 1.38 กก. รวมแบตเตอรี่ (Figure 3) มีเพดานบินสูงสุดไม่เกิน 6,000 ม. เหนือระดับน้ำทะเล มีการติดตั้งกล้องสำหรับบันทึกภาพถ่าย RGB ภายในตัวเป็นกล้องรุ่น Canon EOS 600D-3.6-4000x3000 (DJI, 2016) นอกจากนี้ยังได้ทำการติดตั้งกล้องถ่ายภาพหลายช่วงคลื่นรุ่น Parrot SEQUOIA พร้อมด้วย Sunshine sensor, GPS และแบตเตอรี่ขนาด 5,000 mAh 5 V 2.4 A น้ำหนักรวม 197 ก. โดยจะใช้ในการถ่ายภาพ 4 ช่วงคลื่นได้แก่ Green, Red, Red Edge และ NIR แต่ละช่วงมีความถี่ 550 , 660, 735 และ 790 nm ตามลำดับ เป็นภาพขนาด 1280 x 960 pixel (Parrot, 2022) ภาพที่ได้จะถูกใช้ในการคำนวณหาค่าดัชนีพืชพรรณ



Figure 3 UAV: DJI Phantom 4 Pro and Multispectral Sensor: Parrot SEQUOIA

การวางแผนการบิน

การถ่ายภาพเพื่อทำแผนที่แปลงจำเป็นต้องใช้ภาพถ่ายจำนวนมากในการประมวลผลเพื่อให้ได้แผนที่ที่มีความละเอียดสูงซอฟต์แวร์ Pix4D Capture จึงถูกนำมาใช้ในการวางแผนการบินเพื่อถ่ายภาพสำหรับเก็บข้อมูลแปลงมันสำปะหลัง การเก็บข้อมูลภาพถ่ายจะถูกเก็บภายในวันเดียวกับการเก็บข้อมูลภาคพื้นดินในพื้นที่แปลงตัวอย่าง โดยกำหนดค่าการถ่ายภาพเป็นแบบตาราง (Grid) โดยมีลักษณะเป็นโครงข่ายเส้นขนานเพื่อให้สามารถบินเก็บภาพได้อย่างครอบคลุมแม่นยำ กำหนดค่าอัตราส่วนการซ้อนทับ (Frontal overlapping) เท่ากับ 80% และอัตราส่วนการเยื้อง (Side overlapping) เท่ากับ 70% เพื่อให้ภาพสามารถต่อกันได้โดยกำหนดค่าอัตราส่วนซ้อนทับและส่วนเยื้องขั้นต่ำที่ 75% และ 60% ตามลำดับ (สำนักวิศวกรรมการผังเมือง, 2564) แผนการบินครอบคลุมพื้นที่ขนาด 12,800 ตร.ม. กำหนดความสูงในการบิน 30 ม. ความเร็วในการบิน 4 เมตรต่อวินาทีดังที่แสดงใน Figure 4




Figure 4 Flight Plan

สำหรับการตั้งค่าการถ่ายภาพด้วยกล้องถ่ายภาพหลายช่วงคลื่นรุ่น Parrot SEQUOIA นั้นสามารถเชื่อมต่อกับระบบ Wi-Fi ของตัวกล้อง โดยตั้งค่าความเร็วในการถ่ายภาพผ่านทาง HTML Interface ของ Parrot SEQUOIA โดยจะตั้งค่าการถ่ายภาพแบบ Time-lapse กำหนดความสูงที่ 30 ม. ความเร็วในการบินที่ 4 เมตร/วินาที (ความเร็วโดยประมาณ) และ %overlap ที่ 80 ทำให้ได้ค่า Timelapse interval อยู่ที่ 1.4 วินาทีต่อ shot จากการคำนวณ

ค่าความสูงเป็นตัวแปรที่ใช้ในการกำหนดค่า Ground Sampling Distance (GSD) ซึ่งเป็นค่าที่บ่งบอกถึงความถูกต้องทางราบและทางตั้งที่ระดับความเชื่อมั่น 95% ค่า GSD สำหรับภาพถ่าย RGB มีค่าเท่ากับ 0.82 ซม. และสำหรับภาพถ่ายด้วยกล้องถ่ายภาพหลายช่วงคลื่นมีค่าเท่ากับ 0.33 ซม. นอกจากนี้ความสูงยังส่งผลโดยตรงต่อระยะเวลาที่ใช้ในการบิน และจำนวนภาพที่เพิ่มขึ้นจากความสูงที่ต่ำลง เวลาที่เหมาะสมในการบินเก็บข้อมูลต้องคำนึงถึงการเกิดเงาสะท้อนจากมุมรังสีของดวงอาทิตย์โดยกำหนดช่วงเวลาในการบินระหว่างเวลา 9.00 น. ถึงเวลา 14.00 น. ซึ่งเป็นเวลาที่ดวงอาทิตย์อยู่สูงจากมุม 45 องศาจากเส้นขอบฟ้า (สำนักวิศวกรรมการผังเมือง, 2564)

การประมวลผลข้อมูลภาพ

ข้อมูลภาพถ่ายที่แปลงจากอากาศยานไร้คนขับจะถูกนำมาประมวลผลเพื่อสร้างแผนที่ภาพถ่ายออร์โธ (Ortho photo map) ในรูปแบบของข้อมูลราสเตอร์โดยใช้ซอฟต์แวร์ Pix4D Mapper โดยจะมีการประมวลผลข้อมูลแยกกันระหว่างภาพที่ได้จากกล้อง RGB และภาพถ่ายจากกล้องถ่ายภาพหลายช่วงคลื่นที่ติดตั้งบนอากาศยานทำให้ได้แผนที่ภาพถ่ายออร์โธจำนวน 2 ภาพของแต่ละรอบการเก็บข้อมูล สำหรับข้อมูลภาพถ่าย RGB จะถูกประมวลผลใน Template 3D Map ได้แผนที่ภาพถ่ายออร์โธที่ประกอบด้วยารซ้อนทับกันของภาพในช่วงคลื่นสีแดง (Red: R) เขียว (Green: G) และน้ำเงิน (Blue: B) สำหรับภาพที่ได้จากกล้องถ่ายภาพหลายช่วงคลื่นจะถูกนำไปประมวลผลใน Template AgMultispectral ได้แผนที่ภาพถ่ายออร์โธของช่วงคลื่น Green, Red, Red Edge และ NIR โดยภาพการสะท้อนของช่วงคลื่นต่างๆ จะถูกแปลงเป็นค่าข้อมูลเชิงเลข (Digital Number) ในแต่ละพิกเซลสำหรับคำนวณดัชนีพืชพรรณ

การคำนวณดัชนีพืชพรรณ

ค่าดัชนีพืชพรรณเป็นหนึ่งในเครื่องมือที่ถูกใช้ในการจำแนกพืชออกจากวัตถุอื่นภายในภาพด้วยคุณสมบัติการสะท้อนและดูดกลืนแสงของใบพืช โดยใช้ในการระบุความหนาแน่น ความสมบูรณ์ของพืชพรรณ และติดตามการเจริญเติบโตของพืช (Jiang et al., 2020) การคำนวณค่าดัชนีพืชพรรณในงานวิจัยนี้แบ่งออกเป็น 2 ส่วน คือ การคำนวณค่าดัชนีพืชพรรณจากภาพถ่าย RGB ได้แก่ดัชนี ExG และดัชนี GRVI และการคำนวณดัชนี NDVI จากภาพถ่ายด้วยกล้องถ่ายภาพหลายช่วงคลื่น

ดัชนี NDVI เป็นดัชนีพืชพรรณที่คำนวณจากการสะท้อนแสงในช่วงคลื่นแสงสีแดง (R) จากการดูดกลืนแสงของใบพืช และช่วงคลื่น NIR ที่ได้จากกล้องถ่ายภาพหลายช่วงคลื่น โดยพืชไม่ดูดกลืนแสงในช่วงคลื่น NIR แต่จะกระเจิงแสงจากโครงสร้างของใบ ดัชนี NDVI มีค่าระหว่าง -1 ถึง 1 เมื่อมีค่าเข้าใกล้ 1 มากแสดงถึงความอุดมสมบูรณ์ของพืชที่มาก (Tucker, 1979) สมการดัชนี NDVI แสดงดังสมการที่ 1

$$NDVI = (NIR - Red) / (NIR + Red) \quad (1)$$

ดัชนี ExG เป็นดัชนีพืชพรรณที่แสดงระดับความเป็นสีเขียวจากภาพถ่าย RGB ได้แก่ สีแดง (R) เขียว (G) และน้ำเงิน (B) ถ้า ExG มีค่าสูงหมายถึงมีความเป็นพืชพรรณใบเขียวหนาแน่นอย่างอุดมสมบูรณ์ (วัฒนพันธุ์, 2561; Woebbecke et al., 1995) คำนวณได้จากสมการที่ 2

$$ExG = 2g - r - b \quad (2)$$

โดยที่ r เป็นค่า normalized ของความยาวคลื่นแสงสีแดง คำนวณได้จาก $r = R/(R+G+B)$

g เป็นค่า normalized ของความยาวคลื่นแสงสีเขียว คำนวณได้จาก $g = G/(R+G+B)$

b เป็นค่า normalized ของความยาวคลื่นแสงสีน้ำเงิน คำนวณได้จาก $b = B/(R+G+B)$

ดัชนี GRVI เป็นดัชนีที่คำนวณจากภาพถ่าย RGB โดยมีลักษณะคล้ายกับดัชนี NDVI แต่จะใช้แสงในช่วงคลื่นสีเขียวมาทดแทนการใช้ช่วงคลื่น NIR (Starý et al., 2020) คำนวณได้จากสมการที่ 3

$$GRVI = (Green - Red) / (Green + Red) \quad (3)$$

ดัชนีพืชพรรณทั้ง 3 ชนิดในงานวิจัยนี้ถูกคำนวณจากภาพที่ได้จากการประมวลผลในขั้นตอนก่อนหน้า โดยทำการคำนวณภายในซอฟต์แวร์ QGIS 3.20.3 โดยใช้เครื่องมือ Raster Calculator จากนั้นทำการจำแนกพืชออกจากวัตถุอื่นแล้วหาค่าดัชนีพืชพรรณเฉลี่ยของแต่ละดัชนีในบริเวณที่มีการเก็บตัวอย่างโดยใช้ซอฟต์แวร์ ArcGIS คำสั่ง Zonal statistics as table tool แต่ละรอบการเก็บตัวอย่างจะได้ข้อมูลดัชนีพืชพรรณเฉลี่ยชนิดละ 12 ข้อมูล ตัวอย่างแผนที่ภาพถ่ายออร์โธที่นำไปคำนวณค่าดัชนีพืชพรรณ 3 ชนิด คือ ExG, GRVI และ NDVI เทียบกับภาพ RGB แสดงใน โดยค่าแถบสีแสดงถึงค่าของดัชนีในแต่ละภาพ Figure 5




Figure 5 Orth photo maps: (a) RGB (b) ExG (c) GRVI (d) NDVI

การเก็บข้อมูลในแปลงตัวอย่าง

การเก็บข้อมูลภาคพื้นดินในพื้นที่แปลงตัวอย่างจะทำการศึกษาข้อมูลปริมาณผลผลิต 2 ชนิดข้อมูลคือ น้ำหนักของหัวมันสำปะหลังสดด้วยเครื่องชั่งสปริง (กก./ตร.ม.) และวัดปริมาณแป้งในหัวมันสำปะหลังสดหรือเปอร์เซ็นต์แป้ง (%) ด้วยเครื่อง Reimann Scale Balance แสดงใน Figure 6 โดยอาศัยวิธีการเก็บข้อมูลแบบ Simple Random Sampling ที่เหมาะสมกับการเก็บข้อมูลเชิงปริมาณโดยเหมาะสมกับข้อมูลที่มีลักษณะคล้ายคลึงกันในพื้นที่เดียวกันเพื่อเป็นตัวแทนของข้อมูลทั้งหมด (Noor et al., 2022) โดยแบ่งพื้นที่แปลงออกเป็น 3 แปลง (plot) ตามการวางแนวของสายน้ำหยดแต่ละแปลงจะแบ่งออกเป็น 4 แปลงย่อย (subplot) รวม 12 แปลงย่อยและสุ่มเลือกบริเวณที่สนใจในการสุ่มวัดผลผลิตให้กระจายทั่วแปลงย่อยนั้น จำนวนแปลงย่อยละ 10 ตัวอย่าง หมายเลขแปลงและหมายเลขแปลงย่อยบนพื้นที่แปลงตัวอย่างแสดงใน Figure 7 นำข้อมูลตัวอย่างมาหาค่าเฉลี่ยต่อ 1 ตร.ม. ในแต่ละแปลงย่อย เพื่อให้ได้ข้อมูลที่เป็นตัวแทนของข้อมูลแปลงย่อยนั้นในแต่ละรอบ โดยในแต่ละรอบการเก็บข้อมูลจะได้ข้อมูลปริมาณผลผลิตแต่ละชนิดจำนวน 12 ข้อมูลจากตัวอย่างที่เก็บภายในแปลง 120 ตัวอย่าง รวมข้อมูลปริมาณผลผลิตแต่ละชนิดในรอบจำนวน 36 ข้อมูลจากตัวอย่างที่เก็บภายในแปลง 360 ตัวอย่าง



Figure 6 Reiman Scale Balance




Figure 7 Plots and Subplot in study area

การสร้างแบบจำลองเพื่อประเมินผลผลิตของมันสำปะหลัง

เมื่อได้ค่าดัชนีพืชพรรณและข้อมูลปริมาณผลผลิตในแต่ละตัวอย่างแล้วจึงหาความสัมพันธ์ระหว่างปริมาณผลผลิตกับดัชนีพืชพรรณโดยแยกพิจารณาออกเป็น 2 ประเด็นคือ ความสัมพันธ์ระหว่างน้ำหนักของหัวมันสำปะหลังสดกับค่าดัชนีพืชพรรณ และความสัมพันธ์ระหว่างปริมาณแป้งในหัวมันสำปะหลังหรือเปอร์เซ็นต์แป้งกับค่าดัชนีพืชพรรณ ความสัมพันธ์ดังกล่าวถูกนำมาใช้กับวิธีการทำนายด้วยการเรียนรู้ของเครื่องจากแบบจำลองสมการถดถอยเชิงเส้น โดยเป็นแบบจำลองทางคณิตศาสตร์ที่อาศัยความสัมพันธ์เชิงเส้นเกี่ยวกับการศึกษาตัวแปรอิสระที่ส่งอิทธิพลต่อตัวแปรตาม (มุสดี และกรวัฒน์, 2560) แสดงได้ดังสมการที่ 4

$$Y = \alpha + \beta X \quad (4)$$

โดยที่ Y คือ ตัวแปรตาม

X คือ ตัวแปรอิสระ

α คือ สัมประสิทธิ์การถดถอยซึ่งเป็นจุดตัดบนแกน Y

β คือ สัมประสิทธิ์การถดถอยซึ่งเป็นความชันของเส้นตรง

การประเมินประสิทธิภาพของแบบจำลองสมการถดถอย จะใช้ค่าสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R^2) โดยมีค่าระหว่าง 0 ถึง 1 หาก R^2 มีค่าเท่ากับ 1 หมายถึงแบบจำลองทำนายได้ตรงตามเป้าหมายทั้งหมด และหากมีค่าเท่ากับ 0 หมายถึงแบบจำลองทำนายได้ไม่ตรงตามเป้าหมายทั้งหมด (กิตติสุชาติ, 2564) โดยค่า R^2 สามารถคำนวณได้จากสมการที่ 5

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_j)^2}{\sum (y_i - \bar{y}_j)^2} \quad (5)$$

โดยที่ y_i คือ ข้อมูลเป้าหมาย

$\hat{y}_j$ คือ ข้อมูลการทำนาย

$\bar{y}_j$ คือ ค่าเฉลี่ยจากข้อมูลเป้าหมาย

นอกจากนี้ยังมีการประเมินความคลาดเคลื่อนของสมการที่ใช้ในการประเมินผลผลิตโดยใช้ค่ารากที่สองของความผิดพลาดกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ที่เป็นค่าการวัดความผิดพลาดที่นิยม โดยคำนวณค่าเฉลี่ยของผลรวมของผลต่างระหว่างข้อมูลเป้าหมายและข้อมูลการทำนายยกกำลังสองและทำให้กลับมามีอยู่ในหน่วยเดียวกันด้วยการใส่รากที่สอง (กิตติสุชาติ, 2564) สมการคำนวณค่า RMSE แสดงในสมการที่ 6

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_j)^2} \quad (6)$$

ผลการศึกษาและวิจารณ์

แผนที่ภาพถ่ายหลายช่วงคลื่นที่ถูกนำไปคำนวณหาค่าดัชนีพืชพรรณ 3 ชนิด คือ ExG, GRVI และ NDVI แล้วจะถูกนำไปสกัดค่า (Extract) เพื่อหาค่าเฉลี่ยของดัชนีพืชพรรณในแต่ละพล็อตและเปรียบเทียบกับข้อมูลปริมาณผลผลิตภายในแปลงเพื่อใช้ในการสร้างแบบจำลองสมการถดถอยเชิงเส้นโดยใน Figure 8 และ Figure 9 แสดงข้อมูลในรูปแบบ Scatter plot เพื่อหาความสัมพันธ์ระหว่างข้อมูลเป้าหมายคือ ปริมาณผลผลิตน้ำหนัก (Yield weight) และเปอร์เซ็นต์แป้ง (Percent starch) ของผลผลิตมันสำปะหลังภายในแปลง (Actual Yield) กับค่าที่ได้จากการทำนาย (Predicted Yield) ด้วยค่าดัชนีพืชพรรณต่าง ๆ จากข้อมูลชุดฝึกฝนจำนวน 29 ข้อมูล




Figure 8 Scatter plot of actual and predicted yield weight with (a) ExG (b) GRVI (c) NDVI




Figure 9 Scatter plot of actual and predicted percent starch with (a) ExG (b) GRVI (c) NDVI

Table 1 The evaluation of models with training set

Vegetation indices	Yield weight		Percent starch	
	R ²	RMSE (kg/m ²)	R ²	RMSE (%)
ExG	0.80	0.47	0.13	2.26
GRVI	0.78	0.47	0.03	2.39
NDVI	0.85	0.40	0.39	1.90

ผลการศึกษาด้วยข้อมูลชุดฝึกฝน (Table 1) ให้ค่า R² ของแบบจำลองการคาดการณ์ปริมาณผลผลิตน้ำหนักด้วยดัชนี NDVI มากที่สุดที่ 0.85 และได้ค่า R² ของแบบจำลองที่ใช้ดัชนี GRVI น้อยที่สุดที่ค่า 0.78 ขณะที่แบบจำลองการคาดการณ์ปริมาณแป้งพบว่า ดัชนี NDVI ให้ค่า R² มากที่สุดที่ 0.39 และ GRVI น้อยที่สุดที่ 0.03 โดยค่า R² ที่ได้จากการคำนวณด้วยข้อมูลปริมาณผลผลิตจริงเทียบกับปริมาณผลผลิตที่จากการทำนายด้วยแบบจำลองบ่งบอกถึงประสิทธิภาพในการทำนาย โดยหากมีค่าเข้าใกล้ 1 จะบ่งบอกถึงแบบจำลองมีประสิทธิภาพในการทำนายที่สูง และหากมีค่าเข้าใกล้ 0 หมายถึงแบบจำลองมีประสิทธิภาพในการทำนายต่ำ (กิตติสุชาติ, 2564) สำหรับการประเมินความคลาดเคลื่อนของค่าที่ได้จากการทำนายด้วยแบบจำลองด้วย RMSE (Table 1) จะบ่งชี้ถึงค่าความผิดพลาดในการทำนายในหน่วยเดียวกันกับข้อมูลเป้าหมายที่ใช้ในการฝึกฝนแบบจำลอง โดยพบว่าการคาดการณ์ปริมาณผลผลิตน้ำหนักด้วยดัชนี NDVI มีค่า RMSE ต่ำที่สุดที่ 0.40 กก./ตร.ม. ขณะที่ดัชนี GRVI มีค่า RMSE สูงที่สุดที่ 0.47 กก./ตร.ม. สำหรับการประเมินปริมาณแป้งในหัวมันสำปะหลังสด พบว่าดัชนี NDVI ให้ค่า RMSE ต่ำที่สุดที่ 1.90% ขณะที่ดัชนี GRVI ให้ค่า RMSE สูงที่สุดที่ 2.39% ทั้งนี้เป็นการคาดการณ์ปริมาณแป้งเฉลี่ยต่อหนึ่งหน่วยพื้นที่ที่ทำนายเก็บตัวอย่าง

สำหรับผลการศึกษาแบบจำลองด้วยข้อมูลชุดฝึกฝนการประเมินผลผลิตด้วยค่าดัชนี NDVI มีความแม่นยำสูงที่สุดเนื่องจากมีการคำนวณค่าการสะท้อนของแสงในช่วงคลื่น NIR และ Red โดย NIR จะบ่งบอกถึงความสมบูรณ์ของใบพืชโดยตรง (Tucker, 1979) ขณะที่ดัชนี GRVI และ ExG คำนวณจากการสะท้อนแสงในช่วงคลื่น RGB ที่ตามองเห็นได้ ซึ่งบ่งบอกได้ถึงความเร็วและความหนาแน่นของพืชเท่านั้น

อย่างไรก็ตามมีความจำเป็นต้องประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบ เพื่อทดสอบว่าแบบจำลองสามารถทำงานได้ดีกับข้อมูลที่ไม่เคยถูกใช้ในการฝึกฝนแบบจำลองมาก่อน (ผฤณ และคณะ, 2566) ผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบ เพื่อวิเคราะห์ประสิทธิภาพการใช้ดัชนีพืชพรรณแต่ละชนิดในการประเมินน้ำหนักและปริมาณแป้งในหัวมันสำปะหลังสดภายในแปลง โดยหาค่า R² และ RMSE แสดงใน Table 2

Table 2 The evaluation of models with test set

Vegetation indices	Yield weight		Percent starch	
	R ²	RMSE (kg/m ²)	R ²	RMSE (%)
ExG	0.68	0.51	0.34	3.35
GRVI	0.48	0.65	0.10	3.92
NDVI	0.82	0.38	0.34	3.36

ผลการศึกษาพบว่าการประเมินน้ำหนักของหัวมันสำปะหลังสดภายในแปลงในระยะเก็บเกี่ยว ดัชนี NDVI ให้มีค่า R² สูงที่สุดที่ 0.82 โดยมีความหมายว่าแบบจำลองสามารถทำนายค่าปริมาณผลผลิตได้ใกล้เคียงข้อมูลปริมาณผลผลิตจริงภายในแปลงสูงที่สุดที่ร้อยละ 82 ในขณะที่ค่าดัชนี GRVI ให้ค่า R² ต่ำสุดในการศึกษาคือ 0.48 ทั้งนี้เนื่องจากค่าดัชนี NDVI มีการพิจารณาการสะท้อนแสงในช่วงคลื่น NIR ที่สามารถใช้ในการจำแนกพืชพรรณและวัตถุที่ปกคลุมดินจากคุณสมบัติค่าความแตกต่างการสะท้อนของช่วงคลื่น NIR กับช่วง

คลื่นแสงสีแดง ในขณะที่ดัชนี ExG และ GRVI คำนวณจากการสะท้อนและดูดกลืนแสงในช่วงคลื่น RGB ซึ่งเป็นช่วงคลื่นแสงที่ตามองเห็นเท่านั้น สำหรับค่า RMSE ของแบบจำลองพบว่า NDVI มีค่าต่ำที่สุดกล่าวคือมีความผิดพลาดในการทำนายน้ำหนักของผลผลิตอยู่ที่ 0.38 กก./ตร.ม. ในขณะที่ GRVI มีความผิดพลาดสูงที่สุดที่ 0.65 กก./ตร.ม.

การศึกษานี้ยังชี้ว่าดัชนีพืชพรรณ NDVI มีความเหมาะสมในการประเมินน้ำหนักมันสำปะหลังสดด้วยภาพถ่ายจากอากาศยานไร้คนขับสูงที่สุด รองลงมาคือดัชนี ExG และ GRVI ตามลำดับ โดยการศึกษาชี้ให้เห็นว่าดัชนีพืชพรรณมีความสอดคล้องกับปริมาณผลผลิตมันสำปะหลังด้วยอาศัยข้อมูลจากการถ่ายภาพด้วยภาพถ่ายทางอากาศ สอดคล้องกับงานวิจัยของวชิรพร และคณะ (2555) ที่มีการใช้ภาพถ่ายจากดาวเทียมไทยโชดที่มีความละเอียดจุดภาพ 15 ม. ในการประเมินผลผลิตมันสำปะหลัง อย่างไรก็ตามการใช้ภาพถ่ายจากอากาศยานไร้คนขับที่มีความละเอียดจุดภาพสูงกว่าในหน่วย ซม. จะให้ความถูกต้องแม่นยำของแบบจำลองสูงกว่า โดยงานวิจัยของ พงศ์ และถาวร (2564) ได้ใช้อากาศยานไร้คนขับในการคาดการณ์ปริมาณผลผลิตข้าวโดยใช้ดัชนีพืชพรรณ NDVI TGI และ GNDVI พบว่าการทำนายปริมาณผลผลิตมีความใกล้เคียงกับผลผลิตจริง นอกจากนี้ยังมีงานวิจัยก่อนหน้านี้ที่ใช้ดัชนีพืชพรรณในการประมาณผลผลิตทางการเกษตรของพืชเศรษฐกิจในประเทศไทย อาทิ อ้อย (จิรวัดน์ และคณะ, 2562; โพธิ์วุฒิ และคณะ, 2564) ข้าว (ปรีชญ์, 2563; พรหมชัย และคณะ, 2561) และมันสำปะหลัง (วชิรพร และคณะ, 2555) โดยหากพิจารณาเลือกใช้ดัชนีพืชพรรณจากภาพถ่ายด้วยกล้องที่เก็บข้อมูลในช่วงคลื่น RGB ดัชนี ExG มีความเหมาะสมกว่า GRVI ในด้านความแม่นยำ ดัชนี ExG ดันทุนที่ต่ำกว่าดัชนี NDVI ที่เก็บข้อมูลด้วยกล้องถ่ายภาพหลายช่วงคลื่นที่ติดตั้งบนอากาศยานไร้คนขับการประเมินผลผลิตทางการเกษตร (สิตาวีร์, 2559) อย่างไรก็ตาม ดัชนี ExG ยังมีข้อจำกัดที่ความแม่นยำของแบบจำลองเมื่อเทียบกับดัชนี NDVI

ผลการศึกษาพบว่าการใช้ดัชนีพืชพรรณจากภาพถ่ายที่จากเซนเซอร์ที่ติดตั้งบนอากาศยานนักบินเพื่อประเมินปริมาณแป้งในหัวมันสำปะหลังสดภายในแปลงตัวอย่าง (Table 2) พบว่ามีค่า R^2 ค่อนข้างต่ำโดยดัชนี ExG ให้ค่าสูงที่สุดเท่ากับ 0.34 และมีค่า RMSE สูงถึง 3.35% โดยปริมาณแป้งในหัวมันสำปะหลังสดจะเปลี่ยนแปลงไปตามระยะการเจริญเติบโตของต้นสำปะหลัง อีกทั้งยังเปลี่ยนแปลงตามสภาพอากาศในพื้นที่ปลูก ถูกลมที่เริ่มปลูก รูปแบบการให้น้ำ และฤดูกาลเก็บเกี่ยว (Santisopasri et al., 2001; Siroth et al., 2001; Janket et al., 2020) ดังนั้นการประมาณปริมาณแป้งในหัวมันสำปะหลังสดจึงไม่อาจทำการประมาณได้จากภาพถ่ายที่ได้จากเซนเซอร์บนอากาศยานไร้คนขับเท่านั้น จำเป็นต้องอาศัยข้อมูลที่เกี่ยวข้องกับการเพาะปลูก อาทิ พันธุ์ ถูกลมเพาะปลูก รูปแบบการให้น้ำ เป็นต้น และอาจใช้แบบจำลอง Multiple Linear Regression หรือแบบจำลองที่มีความซับซ้อนยิ่งขึ้น เช่น โครงข่ายประสาทเทียม (Artificial neural network) ในการวิเคราะห์ข้อมูลเพิ่มเติม

ทั้งนี้จากการประมาณผลผลิตมันสำปะหลังเป็นการประเมินทางอ้อมโดยใช้ข้อมูลดัชนีพืชพรรณที่ถ่ายจากมุมมองด้านบนของแปลงเทียบกับข้อมูลน้ำหนักหัวมันสำปะหลังสดที่ขุดจากใต้ดิน ทำให้การศึกษานี้เป็นการศึกษาแนวโน้มและความเป็นไปได้ในการประเมินผลผลิตในเบื้องต้นเพียงเท่านั้น อีกทั้งงานวิจัยนี้มีขอบเขตในการศึกษาที่แปลงมันสำปะหลังพันธุ์ระยอง 72 ที่ปลูกบนชุดดินครบุรีด้วยระบบสายนํ้าหยดเท่านั้น วิธีการในการดำเนินงานวิจัยนี้จึงอาจเหมาะสมกับมันสำปะหลังที่มีลักษณะเช่นเดียวกับที่ได้กล่าวมาในเบื้องต้น

สรุป

การศึกษการประเมินผลผลิตมันสำปะหลังโดยใช้ดัชนีพืชพรรณ NDVI, ExG และ GRVI ที่คำนวณจากภาพถ่ายที่ได้จากเซนเซอร์บนอากาศยานไร้คนขับและข้อมูลที่ได้จากการเก็บในแปลงตัวอย่าง โดยใช้แบบจำลองสมการถดถอยเชิงเส้น พบว่าการประเมินน้ำหนักของหัวมันสำปะหลังสดด้วยดัชนีพืชพรรณ NDVI ให้ค่า R^2 สูงที่สุด รองลงมาคือ ExG และ GRVI ตามลำดับ โดยดัชนี NDVI ให้ความผิดพลาดในการคาดการณ์ปริมาณผลผลิตเพียง 0.38 กก./ตร.ม. เนื่องจากคุณสมบัติของการดูดกลืนและสะท้อนแสงในช่วงคลื่นอินฟราเรดย่านใกล้และคลื่นแสงสีแดงของใบพืช ในขณะที่ดัชนีพืชพรรณที่คำนวณจากแสงในช่วงคลื่น RGB ดัชนี ExG มีความเหมาะสมที่สุดด้วยมีความถูกต้องค่อนข้างสูง และการเก็บภาพถ่าย RGB มีต้นทุนที่ต่ำกว่า โดยดัชนี ExG มีความผิดพลาดในการคาดการณ์ปริมาณผลผลิตที่ 0.51 กก./ตร.ม. เมื่อพิจารณาการประเมินปริมาณแป้งในหัวมันสำปะหลังสดด้วยดัชนีพืชพรรณ NDVI, ExG และ GRVI และแบบจำลองสมการถดถอยเชิงเส้นพบว่าผลการประเมินมีความถูกต้องที่ค่อนข้างต่ำเนื่องจากการเก็บข้อมูลภาพถ่ายด้วยกล้องที่ติดตั้งบน

อากาศยานแสดงถึงความอุดมสมบูรณ์ของพืชจากสมบัตการสะท้อนแสงของใบเท่านั้น ไม่ได้พิจารณาถึงสภาพของดินและสภาพอากาศภายในแปลง โดยหากต้องการความแม่นยำที่สูงขึ้นควรจะมีการศึกษาการใช้ข้อมูลภาพถ่ายจากอากาศยานไร้คนขับร่วมกับข้อมูลอื่นที่เกี่ยวข้องกับการเพาะปลูกด้วยหรือใช้แบบจำลองที่มีความซับซ้อนมากขึ้น ซึ่งจะช่วยให้แบบจำลองมีความแม่นยำที่สูงขึ้น ทั้งนี้การศึกษานี้เป็นเพียงแนวทางที่ใช้ในการประเมินผลผลิตมันสำปะหลังตามขอบเขตของสายพันธุ์มันสำปะหลัง ช่วงเวลาในการเก็บข้อมูล และลักษณะพื้นที่ในแปลงที่ศึกษาเท่านั้น

คำขอบคุณ

คณะผู้วิจัยขอขอบคุณห้องปฏิบัติการ Autonomous Control and System Engineering Laboratory (ACSE) สาขาวิชาวิศวกรรมเครื่อง สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี ที่ให้การสนับสนุนวัสดุอุปกรณ์และแนวทางในการเก็บข้อมูลด้วยอากาศยานไร้คนขับสำหรับงานวิจัย และขอขอบคุณท่านผู้ช่วยศาสตราจารย์ ดร. ฐิติพร มะณีโกภา สาขาวิชาเทคโนโลยีการผลิตพืช สำนักวิชาเทคโนโลยีการเกษตร มหาวิทยาลัยเทคโนโลยีสุรนารี สำหรับการให้ความอนุเคราะห์วัสดุอุปกรณ์ แนวทางเก็บข้อมูลภาคพื้นดิน และข้อมูลที่เป็นประโยชน์ต่อการดำเนินงานวิจัย

เอกสารอ้างอิง

- กรมวิชาการเกษตร. 2547. เอกสารวิชาการมันสำปะหลัง. กรมวิชาการเกษตร, กรุงเทพฯ.
- กิตติสุชาติ พลสุภา. 2564. ระบบอัจฉริยะขั้นสูง: ทฤษฎี อัลกอริทึม และการประยุกต์ใช้. สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง, กรุงเทพฯ.
- ชญณ ชินประสาทศักดิ์, ปรีชาพล อินทรสุข, นันทน์ พูลสามปอก และณัฐพร สนพะเนาว์. 2566. แก่นแท้ของ Deep Learning : AI อธิบายด้วยภาพ. สำนักพิมพ์ เมตบายเอไอ, นนทบุรี.
- จิรวรรณ โนติโธสง, ชวัญตรี แสงประชาอนารักษ์, เจษฎา โพธิ์สม, เสรี วงศ์พิเชษฐ์, ศุภสิทธิ์ คนใหญ่, มหิธร ว่องมาติ และ Chanreksa Chea. 2562. การศึกษาความเป็นไปได้ในการทำนายผลผลิตอ้อยในแปลงโดยใช้ดัชนีพืชพรรณ NDVI, CI red edge และปริมาตรจากแบบจำลองพื้นผิวเชิงตัวเลข. แก่นเกษตร. 47: 679-694.
- ชัยวิช ไชยเจริญกุล. 2566. แนวโน้มธุรกิจ/อุตสาหกรรม ปี 2566-68 อุตสาหกรรมมันสำปะหลัง. แหล่งข้อมูล: https://www.krungrsri.com/getmedia/863b0aec-1bf1-449b-9b6b-1235a3a05650/IO_Cassava_230203_TH_EX.pdf.aspx. ค้นเมื่อ 15 กันยายน 2566.
- ปริญธร จุลถาวร. 2563. การศึกษานาข้าวโดยอากาศยานไร้คนขับ: การติดตามการเจริญเติบโตของข้าวด้วยดัชนีพืชพรรณ RGB และการวัดความสูงของต้นข้าวด้วยแบบจำลองพื้นผิวเชิงตัวเลข. วิทยานิพนธ์ ปริญญาศิลปศาสตร บัณฑิตมหาวิทยาลัยธรรมศาสตร์. ปทุมธานี.
- ผุสดี บุญรอด และกรวัฒน์ พลเยี่ยม. 2560. แบบจำลองการพยากรณ์ราคามันสำปะหลังโดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น. วิทยาศาสตร์และเทคโนโลยี. 25: 533-543.
- พงศ์ หลงมูล และถาวร อ่อนประไพ. 2564. การประมาณผลผลิตข้าวด้วยค่าดัชนีพืชพรรณโดยใช้ข้อมูลภาพแบบหลายช่วงคลื่นจากอากาศยานไร้คนขับ. วารสารเกษตร. 37: 193-205.
- โพธิ์วุฒิ บุญเรือง, ชยันต์ ภักดีไทย และศิวา แก้วปลั่ง. 2564. การประเมินภาพถ่ายทางอากาศจากอากาศยานไร้คนขับสำหรับประมาณผลผลิตอ้อย. แก่นเกษตร. 49: 306-313.
- มูลนิธิสถาบันพัฒนามันสำปะหลังแห่งประเทศไทย. 2557. รายงานผลการติดตามภาวะการผลิตมันสำปะหลังฤดูการผลิต 2556/2557. มูลนิธิสถาบันพัฒนามันสำปะหลังแห่งประเทศไทย, กรุงเทพฯ.
- วลัยพร ศะติประภา, นริลักษณ์ วรรณสาย, สุภาพร ราชันทีก และณิชา โพทอง. 2555. ความสัมพันธ์ระหว่างดัชนีพืชพรรณผลต่างนอร์มัลไลซ์กับผลผลิตมันสำปะหลังในจังหวัดกำแพงเพชร. วิชาการเกษตร. 30: 290-299.

- วัชริน มีรอด, กุลวรางค์ สุวรรณศรี และกฤษฎา บำรุงวงศ์. 2558. การศึกษาผลกระทบและเตรียมความพร้อมของภาคเกษตรไทยสู่ประชาคมอาเซียน: กรณีศึกษามันสำปะหลัง. สำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ, ปทุมธานี.
- วัฒนพันธุ์ ฤทธิ์เต็ม. 2561. การติดตามวิเคราะห์เปรียบเทียบการเจริญเติบโตและโรคใบขาวในแต่ละช่วงอายุของอ้อยด้วยภาพถ่ายจากอากาศยานไร้คนขับ และซอฟต์แวร์ฟรีสเปค. วิทยานิพนธ์ ปริญญาวิทยาศาสตร บัณฑิต มหาวิทยาลัยนเรศวร. พิษณุโลก.
- พรหมชัย สุพรรณ, ธนัช เอกเกื้อกูล, เนติ ศรีหาหนุ และศิวา แก้วปลั่ง. 2561. การติดตามการเจริญเติบโตของนาข้าวด้วยภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ. น. 548-554. ใน: การประชุมทางวิชาการมหาวิทยาลัยเกษตรศาสตร์ ครั้งที่ 56: สาขาวิทยาศาสตร์และพันธุวิศวกรรม, สาขาสถาปัตยกรรมศาสตร์และวิศวกรรมศาสตร์, สาขาอุตสาหกรรมเกษตร, สาขาทรัพยากรธรรมชาติและสิ่งแวดล้อม. 30 มกราคม - 2 กุมภาพันธ์ 2561 มหาวิทยาลัยเกษตรศาสตร์, กรุงเทพฯ.
- ลิตาวีร์ จีระวิรุฬห์. 2559. สมาร์ทฟาร์ม (Smart farm) การทำการเกษตรที่เป็นมิตรกับสิ่งแวดล้อม. แหล่งข้อมูล: <http://library2.parliament.go.th/ebook/content-issue/2559/hi2559-093.pdf>. ค้นเมื่อ 6 เมษายน 2564.
- สำนักงานเศรษฐกิจการเกษตร. 2558. โอกาสสินค้าเกษตรสู่ประชาคมอาเซียน. แหล่งข้อมูล: http://www.oae.go.th/download/download_journal/2558/yearbook57.Pdf. ค้นเมื่อ 29 พฤษภาคม 2564.
- สำนักงานเศรษฐกิจการเกษตร. 2565. ข้อมูลการผลิตสินค้าเกษตร. แหล่งข้อมูล: <https://www.oae.go.th/view/1/ข้อมูลการผลิตสินค้าเกษตร/TH-TH>. ค้นเมื่อ 15 กันยายน 2566.
- สำนักวิศวกรรมกรมการผังเมือง. 2564. การสำรวจและจัดทำแผนที่ด้วยอากาศยานไร้คนขับ. สำนักพิมพ์ แอคซิฟ 888, กรุงเทพฯ.
- Chu, T., M. J. Starek, M. J. Brewer, S. C. Murray, and L. S. Pruter. 2017. Assessing loading severity over an experimental maize (*Zea mays* L.) field using UAS images. *Remote Sensing*. 9: 923.
- DJI. 2016. Phantom 4 Pro/Pro+ User Manual V1.0 2016.11. Available: https://dl.djicdn.com/downloads/phantom_4_pro/Phantom+4+Pro+Pro+Plus+User+Manual+v1.0.pdf. Accessed Nov.18, 2022.
- Janket, A., N. Vorasoot, B. Toomsan, W. Kaewpradit, S. Jogloy, P. Theerakulpisut, C.C. Holbrook, C. K. Kvien, and P. Banterng. 2020. Starch accumulation and granule size distribution of cassava cv. Rayong 9 grown under irrigated and rainfed conditions using different growing seasons. *Agronomy*. 10: 412.
- Jensen, J. R. 2007. Remote sensing of vegetation. Remote sensing of the environment: an earth resource perspective. Pearson Prentice Hall, Upper Saddle River, NJ.
- Jiang, X., M. Gao, and Z. Gao. 2020. A novel index to detect green-tide using UAV-based RGB imagery. *Estuarine, Coastal and shelf science*. 245.
- Machikowa, T., T. Thong-ob, and S. Wonprasaid. 2020. Effect of soil moisture and determination of critical soil moisture contents of cassava. *Indian Journal of Agricultural Research*. 54: 483-488.
- Noor, S., O. Tajik, and J. Golzar. 2022. Simple random sampling. *International Journal of Education and Language Studies*. 1: 78-82.
- Parrot. 2022. Parrot SEQUOIA User guide. Available: https://www.parrot.com/assets/s3fs-public/2021-09/bd_sequoia_integration_manual_en_0.pdf. Accessed Nov, 18, 2022.
- Santisopasri, V., K. Kurotjanavong, S. Chotineeranat, K. Piyachomkwan, K. Sriroth, and C. G. Oates. 2001. Impact of water stress on yield and quality of cassava starch. *Industrial Crops and Products*. 13: 115-129.
- Sriroth, K., S. Piyachomkwan, and C. G. Oates. 2001. Environmental conditions during root development: Drought constraint on cassava starch quality. *Euphytica*. 120: 95-102.
- Stary, K., Z. Jelinek, J. Kumhalová, and J. Chyba. 2020. Comparing RGB-based vegetation indices from uav imageries to estimate hops canopy area. *Agronomy Research*. 18: 2592-2601.

- Tucker, C. J. 1979. Red and photographic in-infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*. 8: 127-150.
- Tumlisan, G. Y. 2017. Monitoring growth development and yield estimation of maize using very high-resolution UAV-images in Gronau, Germany. M. S. Thesis. University of Twente, Enschede, Netherlands.
- Woebbecke, D. M., G. E. Meyer, K. Von Bargen, and D. A. Mortensen. 1995. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*. 38: 259-269.
- Zhao, H., and J. Lee. 2020. The feasibility of consumer RGB camera drones in evaluating multitemporal vegetation status of a selected area: a technical note. *Applied Geography*. 6: 480-488.



ประวัติผู้เขียน

นายอนาวิล เพ็ชรบุรณิล เกิดเมื่อวันที่ 22 เมษายน พ.ศ. 2540 ที่อำเภอเมืองนครราชสีมา จังหวัดนครราชสีมา สำเร็จการศึกษาระดับปริญญาตรีวิศวกรรมศาสตรบัณฑิต (วิศวกรรมอากาศยาน) เกียรตินิยมอันดับ 1 จากมหาวิทยาลัยเทคโนโลยีสุรนารี จังหวัดนครราชสีมา เมื่อ พ.ศ. 2563 เข้าศึกษาต่อในระดับปริญญาโทในหลักสูตรวิศวกรรมเครื่องกลและระบบกระบวนการ (แผน ก.2) ในภาคการศึกษาที่ 1 ปีการศึกษา 2563 ระหว่างการศึกษาได้รับการสนับสนุนการศึกษาภาคติดบัณฑิตแก่บัณฑิตเกียรตินิยมเพื่อศึกษาระดับบัณฑิตศึกษา เป็นระยะเวลา 2 ปี

ในระหว่างการศึกษาได้รับมอบหมายให้เป็นผู้ช่วยสอนในรายวิชา ENG25 2140 Engineering Graphics II, ENG 25 2100 Introduction to Artificial Intelligence, 525671 Artificial Intelligence, 525487 Machine Learning, 525488/551475 Self-Driving Ground Vehicle System, 525401/585307 Industrial Automations, 525340 Mechanical Engineering Laboratory, 525443 Thermal and Fluid System Laboratory, 537342 Aeronautical Engineering Laboratory I, 537343 Aeronautical Engineering Laboratory II, 537403 Aircraft Design, 525210 Fundamental of Computer Aided Engineering, 525306 Computer Aided Engineering for Mechanical Engineering, 536313 Computer Aided Engineering for Automotive Engineering และ 537404 Computer Aided Engineering for Aeronautical Engineering

ทั้งนี้ ผู้วิจัยได้สะสมความรู้และประสบการณ์จากการทำงานในห้องปฏิบัติการ Autonomous control and system engineering laboratory (ACSE) อาคารเครื่องมือ 5 และอาคารเครื่องมือ 11 โดยได้นำความรู้ขณะที่ศึกษาในระดับบัณฑิตศึกษามาประยุกต์ใช้กับงานวิจัย โดยได้มีโอกาสในการทำงานวิจัยในด้านอากาศยานไร้คนขับเพื่อการทำแผนที่ทางทะเล เทคโนโลยีภูมิสารสนเทศ และเทคโนโลยีปัญญาประดิษฐ์ ได้รับการเผยแพร่ผลงานทางวิชาการจำนวนทั้งสิ้น 2 ผลงาน คือ

- 1) อนาวิล เพ็ชรบุรณิล และสุรเดช ตัญตรัยรัตน์. (2565) การตรวจจับโรคทางใบมันสำปะหลังจากภาพถ่ายทางอากาศด้วยการเรียนรู้เชิงลึก. การประชุมวิชาการเครือข่ายวิศวกรรมเครื่องกลแห่งประเทศไทย ครั้งที่ 36, 19-22 กรกฎาคม 2565, ประจวบคีรีขันธ์, ประเทศไทย.
- 2) อนาวิล เพ็ชรบุรณิล และสุรเดช ตัญตรัยรัตน์. (2566) การประเมินผลผลิตมันสำปะหลัง ด้วยภาพถ่ายจากอากาศยานไร้คนขับ. วารสารแก่นเกษตร, 51(6), 1136-1151.