



การวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าโดยใช้การเรียนรู้เชิงลึกสำหรับสมาร์ตฟาร์ม


วิทยานิพนธ์  
ของ  
พัชรี ศรีพุทธา

เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์

พฤษภาคม 2565

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

การวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าโดยใช้การเรียนรู้เชิงลึกสำหรับสมาร์ตฟาร์ม




เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์

พฤษภาคม 2565

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

Analysis of the Fungi Disease on Fairy Mushroom using Deep Learning for Smart  
Farming

Patcharee Sriputta



A Thesis Submitted in Partial Fulfillment of Requirements  
for Doctor of Philosophy (Computer Science)

May 2022

Copyright of Maharakham University



คณะกรรมการสอบวิทยานิพนธ์ ได้พิจารณาวิทยานิพนธ์ของนางสาวพัชรี ศรีพุทธา แล้วเห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชา วิทยาการคอมพิวเตอร์ ของมหาวิทยาลัยมหาสารคาม

คณะกรรมการสอบวิทยานิพนธ์

ประธานกรรมการ

(ผศ. ดร. วรรัตน์ สงฆ์แป้น )

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(ผศ. ดร. สุชาติ คุ้มมะณี )

กรรมการ

(ผศ. ดร. ฉัตรเกล้า เจริญผล )

กรรมการ

(ผศ. ดร. รพีพร ชำชอง )

กรรมการ

(ผศ. ดร. พัฒนพงษ์ ชมภูวิเศษ )

มหาวิทยาลัยอนุมัติให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร ปริญญา ปรัชญาดุษฎีบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์ ของมหาวิทยาลัยมหาสารคาม

(ผศ. ศศิธร แก้วมัน )

คณบดีคณะวิทยาการสารสนเทศ

(รศ. ดร. กริสน์ ชัยมูล )

คณบดีบัณฑิตวิทยาลัย


ชื่อเรื่อง	การวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าโดยใช้การเรียนรู้เชิงลึกสำหรับสมาร์ตฟาร์ม		
ผู้วิจัย	พัชรี ศรีพุทธา		
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. สุชาติ คุ่มมะณี		
ปริญญา	ปรัชญาดุษฎีบัณฑิต	สาขาวิชา	วิทยาการคอมพิวเตอร์
มหาวิทยาลัย	มหาวิทยาลัยมหาสารคาม	ปีที่พิมพ์	2565

### บทคัดย่อ

เห็ดเป็นพืชเศรษฐกิจที่มีคุณค่าทางโภชนาการสูงและมีความสำคัญในหลายประเทศ อย่างไรก็ตาม ปัญหาสำคัญสำหรับการเพาะเห็ดคือโรคเชื้อรา เนื่องจากสามารถสร้างความเสียหายอย่างกว้างขวางต่อเห็ดภายในระยะเวลาอันสั้น (ภายใน 48 ชั่วโมง) แม้ว่าในปัจจุบันเห็ดจะปลูกในระบบสมาร์ตฟาร์มที่แม่นยำ นอกจากนี้ สปอร์เห็ดยังเป็นอันตรายต่อสุขภาพของเกษตรกรผู้เพาะเห็ด ในงานวิจัยนี้ ได้มีการพัฒนาระบบการวินิจฉัยและตรวจหาโรคเชื้อรา (กรณีศึกษา: เห็ดนางฟ้า) โดยใช้เทคนิคการเรียนรู้เชิงลึกที่หลากหลายวิธี การทำงานร่วมกับหุ่นยนต์ถ่ายภาพ และระบบอินเทอร์เน็ตของสรรพสิ่ง (Internet of Things: IoT) ที่แม่นยำภายใต้เงื่อนไขของสภาพแวดล้อมการทำฟาร์มอัจฉริยะ มีวัตถุประสงค์เพื่อลดต้นทุนของการสูญเสียเห็ดที่เกิดจากโรคเชื้อรา บรรเทาปัญหาสุขภาพของเกษตรกรที่เกิดจากสปอร์ของเห็ด และจัดการกับจุดอ่อนของระบบสมาร์ตฟาร์มในปัจจุบัน ระบบประกอบด้วย 4 ส่วน: 1). หุ่นยนต์อัตโนมัติสำหรับจับภาพเห็ดในสมาร์ตฟาร์มแบบเรียลไทม์ สื่อสารข้อมูลภาพผ่านเทคโนโลยีไร้สาย 2) อุปกรณ์เซ็นเซอร์ตรวจจับสภาพแวดล้อม เช่น อุณหภูมิและความชื้น เป็นต้น 3). ระบบตรวจจับเชื้อราด้วยเทคนิคการเรียนรู้เชิงลึก และ 4). ระบบแจ้งเตือนเมื่อตรวจพบเชื้อราโดยใช้อัลกอริทึมการเรียนรู้เชิงลึกเพื่อทดสอบโมเดลก่อนนำไปใช้งานจริง สำหรับการแจ้งเตือนโรคเชื้อราเขียวของเห็ดนางฟ้า ได้แก่ DenseNet201, ResNet50, InceptionV3 และ VGGNet19 โดยใช้ชุดข้อมูลรูปภาพที่เป็นโรคเชื้อราและไม่เป็นโรคเชื้อราจำนวน 4,000 ภาพ ผลการทดลองโมเดลพบว่าอัลกอริทึม DenseNet201 มีความแม่นยำสูงสุดสำหรับการทดสอบกับสองเทคนิค คือ augmentation และ non - augmentation โดยงานวิจัยนี้ได้เลือกใช้ผลการทดลองด้วยเทคนิค augmentation สำหรับสร้างระบบการแจ้งเตือนแบบอัตโนมัติ ซึ่งผลการทดลองพบว่า DenseNet201 มีค่าความแม่นยำ 86.50% InceptionV3 มีค่าความแม่นยำ 77.74% VGGNet19 มีค่าความแม่นยำ 76.24% และสุดท้ายคือ ResNet50 มีค่าความแม่นยำ 70.74% ตามลำดับ และระบบที่นำเสนอสามารถตรวจหาโรคเชื้อราเขียวได้อย่างรวดเร็วภายในเวลาเพียง 1-6 ชั่วโมงเท่านั้น เป็นผลให้ผู้ปลูกเห็ดสามารถลดจำนวนเห็ดที่เสียหายจากโรคเชื้อราและลด

ความเสี่ยงของการสัมผัสสปอร์ของเห็ดโดยตรง

คำสำคัญ : เห็ด, เห็ดนางฟ้า, โรคน้ำเชื้อรา, การเรียนรู้เชิงลึก, หุ่นยนต์, IoT, สมาร์ทฟาร์ม




<b>TITLE</b>	Analysis of the Fungi Disease on Fairy Mushroom using Deep Learning for Smart Farming		
<b>AUTHOR</b>	Patcharee Sriputta		
<b>ADVISORS</b>	Assistant Professor Suchart Khummanee , Ph.D.		
<b>DEGREE</b>	Doctor of Philosophy	<b>MAJOR</b>	Computer Science
<b>UNIVERSITY</b>	Maharakham University	<b>YEAR</b>	2022

### ABSTRACT

*Mushrooms are highly nutritious and vital cash crops in many countries. However, a critical problem for mushroom cultivation is fungal diseases, as they can inflict widespread damage on mushrooms within a relatively short period (within 48 hours), even though mushrooms are currently grown in precision farming systems. Besides, mushroom spores are also harmful to the health of mushroom farmers. In this paper, a fungal disease diagnosis and detection system (Case study: Fairy mushroom) is developed using various deep learning techniques, working with robots (Photographic robots) and precise IoT systems under the conditions of intelligent farming environment. The aims are to reduce the cost of mushroom wastage caused by fungal diseases, alleviate the health problems of farmers caused by mushroom spores, and address the vulnerabilities of the current intelligent farm system. The system consists of four parts: 1). automated robots for capturing images of mushrooms in intelligent farming in real-time, communicating image data over wireless technology, 2). sensor devices for detecting environmental conditions such as temperature and humidity, etc., 3). a fungal detection system with deep learning techniques, and 4). a notification system when a fungus is detected. The classification algorithms to recognize fungal diseases include DenseNet201, ResNet50, InceptionV3, and VGGNet19 based on the image database of 4,000 images of non-fungus and fungal mushrooms equally. The experimental results of the classification of fungal diseases show that DenseNet201 is the highest accuracy of 86.50% (DenseNet201 is most suitable for detecting fungal disease for existing*

smart farms), InceptionV3 is 77.74%, VGGNet19 is 76.24%, and the last is ResNet50, equal to 77.74% respectively. In particular, the proposed system can detect fungal diseases rapidly in only 1-6 hours. As a result, mushroom growers can reduce the number of mushrooms damaged by fungal diseases and reduce the risk of direct exposure to mushroom spores.

Keyword : Mushroom, Fairy mushroom, Fungal disease, Deep Learning (DL), Smart farming, Robots, IoT





## กิตติกรรมประกาศ

วิทยานิพนธ์ เรื่อง "การวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าโดยใช้การเรียนรู้เชิงลึกสำหรับสมาร์ตฟาร์ม" ฉบับนี้สามารถพัฒนาจนสำเร็จลุล่วงไปได้ด้วยดีโดยได้รับการดูแลเป็นอย่างดีจาก ผศ.ดร. สุชาติ คุ่มมะณี ที่เป็นทั้งที่ปรึกษาโครงการวิจัยและกรุณาสั่งสอนให้คำแนะนำ ให้คำปรึกษา และช่วยชี้แนะแนวทาง ตรวจสอบแก้ไขข้อบกพร่องต่าง ๆ ในการค้นคว้าหาความรู้ เพื่อนำมาใช้ในการเขียนโครงการวิจัยฉบับนี้ ผู้จัดทำรู้สึกซาบซึ้งในความกรุณาและอนุเคราะห์จากท่านอาจารย์ที่ปรึกษาเป็นอย่างมากและขอกราบขอบพระคุณคณะกรรมการสอบทุกท่านเป็นอย่างสูงที่ให้คำแนะนำ ข้อเสนอแนะต่าง ๆ รวมทั้งฟาร์มเห็ดดุขภูฟ้าฟาร์มเห็ดและฟาร์มเห็ดทุกฟาร์มที่ให้ความร่วมมือในทุก ๆ ส่วนตลอดมา

ขอขอบพระคุณ คุณพ่อ คุณแม่ ญาติพี่น้อง รวมถึงเพื่อน ๆ พี่ ๆ และน้อง ๆ ทุกคนที่ได้ช่วยเหลือให้คำแนะนำ และกำลังใจต่าง ๆ มากมายให้สามารถเดินต่อในโครงการวิจัยนี้ นอกจากนี้ผู้จัดทำขอขอบพระคุณอาจารย์ในภาควิชาวิทยาการคอมพิวเตอร์ทุกท่าน ที่ได้ให้ความรู้ คำแนะนำ ที่สามารถนำมาปรับใช้ในระหว่างที่กำลังศึกษาเหล่าเรียน ตลอดจนการใช้ประโยชน์จากความรู้เพื่อการทำงานต่อไป รวมทั้งโครงการวิจัยนี้ได้รับทุนสนับสนุนจากมหาวิทยาลัยมหาสารคาม คุณค่าและประโยชน์อันพึงมีมาจากโครงการวิจัยฉบับนี้ผู้จัดทำขอขอบแต่ผู้มีคุณทุกท่าน


พัชรี ศรีพุทธา

พูน ปณ จิต โธ ชีเว

## สารบัญ


	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	ฉ
กิตติกรรมประกาศ.....	ช
สารบัญ.....	ณ
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 หลักการและเหตุผล.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ความสำคัญของการวิจัย.....	3
1.4 ขอบเขตของการวิจัย.....	3
1.5 นิยามศัพท์เฉพาะ.....	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 เห็ดนางฟ้า.....	5
2.2 โรคราเขียว.....	7
2.3 กล้องวงจรปิด.....	11
2.4 เกษตรอัจฉริยะ.....	22
2.5 การสร้างฟาร์มอัจฉริยะ.....	31
2.6 การประมวลผลภาพ.....	34
2.7 การเรียนรู้เชิงลึก.....	43
2.8 โครงข่ายประสาทเทียม.....	47
2.9 โครงข่ายประสาทเทียมแบบสังวัตนาการ.....	50
2.10 Mask R-CNN.....	60
2.11 การประเมินผล.....	66
2.12 งานวิจัยที่เกี่ยวข้อง.....	69
บทที่ 3 วิธีดำเนินการวิจัย.....	79
3.1 ศึกษากระบวนการเกิดโรคราเขียวของเห็ดนางฟ้า.....	80
3.2 วิเคราะห์และออกแบบระบบโรงเรือนเกษตรอัจฉริยะร่วมกับเกษตรกร.....	83

3.3 การออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือนเกษตรอัจฉริยะ .....	85
3.4 การออกแบบและพัฒนาระบบการวิเคราะห์โรคเชื้อราเขียวของเห็ดนางฟ้า .....	90
บทที่ 4 ผลการวิจัย .....	101
4.1 ผลการประเมินสมาร์ฟาร์ม .....	101
4.2 ผลการออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือนสมาร์ฟาร์ม.....	101
4.3 ผลการออกแบบและพัฒนาระบบการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้า .....	103
4.4 สรุปผลการทดลอง .....	111
4.5 สรุปเทคนิคและวิธีการที่เลือกใช้ในงานวิจัย .....	112
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ.....	112
5.1 สรุป และอภิปรายผล .....	112
5.2 ปัญหา และอุปสรรค.....	114
5.3 ข้อเสนอแนะ.....	114
บรรณานุกรม.....	115
ประวัติผู้เขียน.....	126



## สารบัญตาราง

	หน้า
ตารางที่ 2.1 สภาพแวดล้อมในการเจริญเติบโตของเห็ด .....	7
ตารางที่ 2.2 ตัวอย่างลักษณะการเจริญเติบโตของราเขียว .....	9
ตารางที่ 2.3 มุมกล้องและตัวอย่างภาพ .....	16
ตารางที่ 2.4 เซ็นเซอร์ที่ใช้ในการทำงานในระบบฟาร์มอัจฉริยะ .....	32
ตารางที่ 2.5 ตัวควบคุมการทำงานที่ส่งการผ่านเซ็นเซอร์ .....	33
ตารางที่ 2.6 ตาราง Confusion matrix .....	66
ตารางที่ 2.7 สรุปงานวิจัยที่เกี่ยวข้อง.....	69
ตารางที่ 3.1 อุปกรณ์แต่ละตัวที่ติดอยู่กับหุ่นยนต์ .....	89
ตารางที่ 4.1 เกณฑ์การประเมินเกษตรอัจฉริยะ .....	101
ตารางที่ 4.2 เกณฑ์การประเมินสำหรับหุ่นยนต์สร้างภาพ .....	103
ตารางที่ 4.3 เปรียบเทียบผลการทดสอบโมเดล CNN .....	106
ตารางที่ 4.4 ผลการวิเคราะห์โรคเชื้อราแบบทันที (Real-time) .....	108
ตารางที่ 4.5 การวิเคราะห์ข้อมูล ตอนที่ 1 ข้อมูลทั่วไปของผู้ตอบแบบสอบถาม .....	109
ตารางที่ 4.6 การวิเคราะห์ข้อมูล ตอนที่ 2 ความคิดเห็นเกี่ยวกับประสิทธิภาพของระบบ .....	110
ตารางที่ 4.7 ตารางสรุปเทคนิค วิธีการและการเลือกใช้ฟังก์ชัน .....	112




## สารบัญภาพ

	หน้า
ภาพที่ 2.1 ตัวอย่างก้อนเห็ดที่เป็นราเขียว .....	9
ภาพที่ 2.2 กล้องวงจรปิดแบบมาตรฐาน (Standard Camera) .....	12
ภาพที่ 2.3 กล้องวงจรปิดแบบอินฟราเรด (Infrared Camera) .....	13
ภาพที่ 2.4 กล้องวงจรปิดแบบโดม (Dome Camera) .....	13
ภาพที่ 2.5 กล้องวงจรปิดแบบซูม (Zoom Camera) .....	14
ภาพที่ 2.6 กล้องวงจรปิดแบบไอพี (IP Camera) .....	14
ภาพที่ 2.7 ตัวอย่างเลนส์ Fix lens .....	15
ภาพที่ 2.8 ตัวอย่างเลนส์ Auto Iris lens .....	15
ภาพที่ 2.9 ระยะเลนส์ .....	17
ภาพที่ 2.10 เกษตรอัจฉริยะ (Smart farming) .....	22
ภาพที่ 2.11 โดเมนต่าง ๆ ที่เกี่ยวข้องกับอินเทอร์เน็ตของทุกสรรพสิ่ง .....	24
ภาพที่ 2.12 แผนภาพเขตความสัมพันธ์สำหรับแนวคิดของอินเทอร์เน็ตของสรรพสิ่ง .....	25
ภาพที่ 2.13 การสร้างข้อมูล IoT ในระดับต่างๆและแบบจำลองการเรียนรู้เชิงลึก .....	26
ภาพที่ 2.14 กระบวนการทำงานของการประยุกต์ใช้อินเทอร์เน็ตทุกสรรพสิ่ง .....	28
ภาพที่ 2.15 ระบบการทำงานฟาร์มอัจฉริยะ (Smart farming) .....	31
ภาพที่ 2.16 ขั้นตอนทั่วไปที่ใช้ในการระบุโรคพืช .....	36
ภาพที่ 2.17 ปริภูมิสี RGB .....	38
ภาพที่ 2.18 ปริภูมิสี HSV .....	38
ภาพที่ 2.19 ปริภูมิสี HSV แทนค่าด้วยเวกเตอร์ 3 มิติ .....	38
ภาพที่ 2.20 ระบบสี HSL .....	39
ภาพที่ 2.21 HSL Color Wheel .....	39
ภาพที่ 2.22 ตัวอย่างค่า Saturation ระดับค่าต่าง ๆ .....	40
ภาพที่ 2.23 ตัวอย่าง Lightness ระดับค่าต่าง ๆ .....	40
ภาพที่ 2.24 ไดอะแกรมสัมพันธ์สี $a^*, b^*$ .....	41
ภาพที่ 2.25 ภาพ Binary .....	41
ภาพที่ 2.26 ภาพ Grayscale .....	42
ภาพที่ 2.27 ภาพ Indexed color .....	42
ภาพที่ 2.28 เปรียบเทียบความสำคัญและพัฒนาการการเรียนรู้เชิงลึก .....	44
ภาพที่ 2.29 กระบวนการทำงานของการเรียนรู้ด้วยเครื่อง (Machine learning) .....	45
ภาพที่ 2.30 เปรียบเทียบโครงข่ายประสาท .....	46
ภาพที่ 2.31 กระบวนการทำงานของการเรียนรู้เชิงลึก (Deep learning) .....	46
ภาพที่ 2.32 การเรียนรู้เชิงลึกสำหรับการเรียนรู้จดจำใบหน้า .....	46

ภาพที่ 2.33	โครงสร้างการทำงานของโครงข่ายประสาทเทียม.....	48
ภาพที่ 2.34	แบบจำลองแนวคิดของ CNN .....	52
ภาพที่ 2.35	สถาปัตยกรรม CNN .....	53
ภาพที่ 2.36	สถาปัตยกรรม DensNet และ ResNet.....	54
ภาพที่ 2.37	สถาปัตยกรรม ResNet50.....	54
ภาพที่ 2.38	สถาปัตยกรรม Inception.....	55
ภาพที่ 2.39	สถาปัตยกรรม VGG19 network model.....	55
ภาพที่ 2.40	ตัวอย่างขนาดของเคอร์เนล 2x2 Kernel.....	56
ภาพที่ 2.41	ตัวอย่างภาพ RGB .....	56
ภาพที่ 2.42	ภาพสี่เหลี่ยมขนาด 4 x 4 และขนาดของเคอร์เนล ขนาด 2 x 2 .....	57
ภาพที่ 2.43	ตัวอย่างขั้นตอนในการทำ Convolution .....	57
ภาพที่ 2.44	ตารางคุณลักษณะผลลัพธ์ที่ได้หลังจากการดำเนินการ Convolution สมบูรณ์ .....	57
ภาพที่ 2.45	ตัวอย่างการทำ Pooling .....	59
ภาพที่ 2.46	การจำแนกค่าตอบด้วย Fully connected layer .....	59
ภาพที่ 2.47	โมเดล Mask R-CNN.....	61
ภาพที่ 2.48	Faster R-CNN.....	62
ภาพที่ 2.49	region proposal network.....	63
ภาพที่ 2.50	การแบ่งส่วนภาพด้วย Fully convolution Netowors.....	64
ภาพที่ 2.51	ROI Pool.....	64
ภาพที่ 2.52	RoI Align.....	65
ภาพที่ 2.53	Mask Head.....	65
ภาพที่ 2.54	Final mask.....	66
ภาพที่ 2.55	ตัวอย่างพื้นที่จุดตัดและทับซ้อนของภาพ.....	68
ภาพที่ 2.56	ตัวอย่างระดับการทับซ้อนของภาพ.....	68
ภาพที่ 3.1	วิธีการดำเนินการวิจัย (Research methodology) .....	79
ภาพที่ 3.2	ระยะการเดินเชื้อเห็ด.....	82
ภาพที่ 3.3	ตัวอย่างการสร้างฟาร์มเห็ดอัญริยะ .....	83
ภาพที่ 3.4	การออกแบบชั้นวางก้อนเห็ด .....	84
ภาพที่ 3.5	ตัวอย่างชั้นวางก้อนเห็ด .....	85
ภาพที่ 3.6	ระยะห่างระหว่างชั้นวางก้อนเห็ด.....	85
ภาพที่ 3.7	การเคลื่อนกล้องเพื่อทำการถ่ายภาพ.....	86
ภาพที่ 3.8	การส่งภาพถ่ายผ่าน IP กล้อง CCTV.....	86
ภาพที่ 3.9	ภาพรวมการออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือน .....	87
ภาพที่ 3.10	ภาพรวมการออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือน (ต่อ).....	87
ภาพที่ 3.11	รายละเอียดชุดอุปกรณ์สำหรับการสร้างระบบราง .....	88
ภาพที่ 3.12	กรอบการทำงานที่เสนอสำหรับการตรวจจับและแจ้งเตือนสำหรับระบบฟาร์มอัญริยะ ...	90

ภาพที่ 3.13	โครงสร้างฟาร์มอัจฉริยะสำหรับการเพาะเห็ด .....	91
ภาพที่ 3.14	ภาพรวมของหุ่นยนต์ถ่ายภาพ (IBOT) และการกำหนดพารามิเตอร์.....	92
ภาพที่ 3.15	ตัวอย่างภาพเห็ดต้นฉบับและภาพที่มีคำอธิบายประกอบ.....	92
ภาพที่ 3.16	ภาพตัวอย่างการแบ่งข้อมูลภาพสำหรับการทำ Mask R-CNN.....	93
ภาพที่ 3.17	กระบวนการทำ Mask R-CNN .....	93
ภาพที่ 3.18	ตัวอย่างตำแหน่งสำหรับครอบตัด .....	94
ภาพที่ 3.19	กล่องขอบเขตสำหรับการตรวจจับ.....	94
ภาพที่ 3.20	ตัวอย่างภาพที่ได้หลังจากการครอบตัด.....	95
ภาพที่ 3.21	ตัวอย่างภาพที่เป็นโรค (Disease).....	95
ภาพที่ 3.22	ภาพตัวอย่างที่ไม่เป็นโรค (No-disease).....	95
ภาพที่ 3.23	ภาพตัวอย่างการใช้เทคนิค Augmentation.....	96
ภาพที่ 3.24	การแบ่งข้อมูลสำหรับการเรียนรู้และการทดสอบ .....	97
ภาพที่ 3.25	การวิเคราะห์โรคเชื้อราแบบอัตโนมัติ.....	99
ภาพที่ 4.1	ส่วนประกอบชุดควบคุมการเคลื่อนที่ด้านหน้า-ด้านหลัง.....	102
ภาพที่ 4.2	การวางและติดตั้งกล้องสำหรับถ่ายภาพ .....	102
ภาพที่ 4.3	ตัวอย่างการทับซ้อนของชุดข้อมูล .....	103
ภาพที่ 4.4	กราฟแสดงค่าเฉลี่ยการทับซ้อนของข้อมูลภาพ .....	104
ภาพที่ 4.5	เปรียบเทียบค่าความถูกต้องการเรียนรู้โมเดล CNN โดยแบ่งแสดงผลด้วยการใช้เทคนิค Augmentation.....	105
ภาพที่ 4.6	Confusion matrix.....	108



# บทที่ 1

## บทนำ

### 1.1 หลักการและเหตุผล

เห็ดนางฟ้า หรือเห็ดนางรมอินเดียน [1-3] (Mushroom) เป็นเห็ดในตระกูลเห็ดนางรม [3] ที่สามารถเจริญเติบโตได้ดีในประเทศไทย ทั้งนี้เห็ดนางฟ้าเป็นพืชเศรษฐกิจของประเทศที่อุดมไปด้วยสารอาหารจำนวนมาก [4] และปัจจุบันนี้ได้มีงานวิจัยด้านการแพทย์ที่ระบุว่าเห็ดสามารถช่วยรักษาโรคมะเร็งได้ [5] ด้วยเหตุนี้ทำให้ประชากรในประเทศไทยนิยมบริโภคเห็ดเพิ่มขึ้นเนื่องจากเห็นถึงคุณประโยชน์ต่าง ๆ ของเห็ด และด้วยเห็ดนางฟ้านั้นสามารถเพาะได้ง่าย มีเวลาในการเพาะสั้น ดอกเห็ดออกจำนวนมาก ดอกเห็ดให้เนื้อนุ่ม ซึ่งถือว่าเป็นเห็ดที่มีความนิยมในการนำมาปรุงอาหารเพื่อบริโภคในหลากหลายรูปแบบ เช่น เป็นส่วนประกอบในการทำอาหารประเภทต้มยำ อาหารประเภททอด หรือแม้แต่อาหารประเภทหนึ่ง เป็นต้น สำหรับการเพาะเห็ดนางฟ้านั้นใช้เวลาในการเจริญเติบโตน้อยและสามารถเก็บเกี่ยวผลผลิตได้อย่างรวดเร็ว [4] ในการปลูกเห็ดนางฟ้าใช้ต้นทุนในการผลิตที่สูงเนื่องจากจะต้องมีการจัดทำโรงเรือน และซื้อก้อนเห็ดสำหรับนำมาใช้ในการเพาะปลูกภายในโรงเรือน และการเพาะปลูกเห็ดนางฟ้านั้นสามารถให้ผลตอบแทนที่สูงและรวดเร็ว การเพาะปลูกเห็ดนางฟ้าในโรงเรือนยังมีความเสี่ยงอย่างมากในเรื่องของโรคราที่เกิดขึ้น ซึ่งราที่พบมากที่สุดในการเพาะปลูกเห็ดนางฟ้า คือ ราเขียว [6] เนื่องจากเกิดขึ้นมาตั้งแต่กระบวนการผลิตก้อนเห็ดที่ไม่สะอาดและขาดการควบคุมที่ดีจะเป็นสาเหตุหลักในการเกิดโรคราเขียว ซึ่งพบมากตั้งแต่การเริ่มเปิดก้อนเห็ด ซึ่งหากไม่มีการเปิดก้อนเห็ดและไม่สังเกตก้อนเห็ดหลังจากเปิดก้อนแล้ว เกษตรกรจะไม่รู้เลยว่าชุดก้อนเห็ดที่ซื้อมานั้นมีภาวะเสี่ยงหรือเกิดการลุกลามของโรคราเขียวในก้อนเห็ดภายในโรงเรือนแล้ว บางครั้งเกษตรกรพบหลังจากเปิดก้อนเห็ดประมาณ 1-2 สัปดาห์ ซึ่งมี 2 ปัจจัย คือ ภาวะความชื้นที่เกินกว่า 90% และอุณหภูมิเกิน 35 องศาเซลเซียส [6] ซึ่งหากเมื่อเกิดการลุกลามภายใน 1-3 คืน นั้นหมายความว่าเกษตรกรจะรู้ว่าเกิดการลุกลามแล้วไปหลายสิบก้อน และนี่คือสาเหตุที่จะทำให้เกษตรกรขาดทุนได้ เนื่องจากจำเป็นต้องนำก้อนเห็ดที่เป็นโรคราเขียวออกจากโรงเรือนและกำจัดทันทีที่พบเพื่อไม่ให้เกิดการลุกลามไปทั้งโรงเรือนด้วย สาเหตุนี้จึงทำให้เกษตรกรที่พบปัญหานี้เกิดการขาดทุนได้นั่นเอง

สิ่งสำคัญในการเพาะปลูกเห็ดนางฟ้า คือ การสร้างโรงเรือนที่เหมาะสมต่อการเจริญเติบโตของเห็ด [1, 7] เช่น ต้องมิดชิด แสงสว่างน้อย ไม่อับชื้น อากาศถ่ายเทได้สะดวก เป็นต้น สำหรับการเจริญเติบโตของเห็ดนางฟ้าหรือการให้ผลผลิตที่ดีนั้น ต้องอาศัยปัจจัยในเรื่องของ อุณหภูมิ ความชื้น แสง ที่จะส่งผลต่อการออกดอกเห็ดนางฟ้า โดยพื้นฐานของการสร้างโรงเรือนเพาะเห็ดนางฟ้าที่ดีควรมีขนาดที่พอดีกับการเก็บเกี่ยว เนื่องจากหากเกิดโรคหรือมีแมลงศัตรูเห็ดเกิดขึ้นจะระบาดและทำให้เกิดการสูญเสียได้ง่ายทั่วทั้งโรงเรือน ซึ่งเกษตรกรควรแบ่งช่วงล็อกให้พอเหมาะพอดี ชั้นวางก้อนเห็ดมีระยะห่างกัน 1 - 1.5 เมตร มีชั้นวางก้อนเห็ด 5 - 6 ชั้น แต่ละชั้นให้ห่างกัน 45 เซนติเมตร ส่วนชั้นล่างสุดห่างจากพื้นประมาณ 30 เซนติเมตร ทำชั้นตามความยาวของโรงเรือน โดยมี 2 แถว และมีทางเดินรอบชั้นวาง [7] หลังจากทราบถึงความสำคัญในการเพาะเห็ดนางฟ้าแล้ว สิ่งสำคัญที่ควรใส่ใจ



เป็นอย่างยิ่ง คือ สุขภาพของเกษตรกร เนื่องจากการเจริญเติบโตของเห็ดนางฟ้าเมื่อมีการออกดอก และปล่อยสปอร์ออกมาในปริมาณมาก เนื่องจากเห็ดเป็นสิ่งมีชีวิตจำพวกราซึ่งไม่สามารถสร้างอาหารเองได้เนื่องจากเห็ดไม่มีสารสีเขียวที่เรียกว่า คลอโรฟิลล์ จึงต้องอาศัยการย่อยสลายอินทรีย์วัตถุเป็นอาหารในการดำรงชีวิต เห็ดส่วนใหญ่แพร่พันธุ์ด้วยวิธีการสร้างสปอร์ ซึ่งสปอร์ของเห็ดเปรียบเสมือน เมล็ดของพืชซึ่งมีขนาดเล็กมากมองด้วยตาเปล่าไม่เห็น ส่วนที่เรียกว่าดอกเห็ดเป็นส่วนที่สร้างสปอร์ โดยสปอร์ที่มีลักษณะคล้ายฝุ่นจะอยู่ในริ้วหรือครีบใต้ส่วนหัวที่คล้ายหมวกพร้อมที่จะฟุ้งกระจายออกไปจากรูเปิดหรือผิวเปลือกแตกเมื่อดอกแก่ เมื่อสปอร์ไปตกลงในสภาพแวดล้อมที่เหมาะสมมีความชื้น และอาหารอย่างเพียงพอจะงอกขึ้นมาเป็นเส้นใยและเจริญเติบโตไปเป็นดอกเห็ดหมุนเวียนอย่างนี้ไปเรื่อย ๆ ถึงแม้ว่าอย่างไรก็ตามสปอร์เป็นสิ่งสำคัญสำหรับเห็ด แต่เป็นอันตรายต่อสุขภาพสำหรับเกษตรกรที่มีการสูดดมเข้าไปสูร่างกายในปริมาณที่มากและต่อเนื่องจะทำให้เกษตรกรมีภาวะโรคภูมิแพ้ โรคปอดหรือฝีในปอด เป็นต้น [8] ซึ่งอันตรายนี้จะทำให้เกิดการสูญเสียแก่ชีวิตของเกษตรกรได้ เนื่องจากเกษตรกรจำเป็นที่จะต้องเข้าโรงเรือนเพาะปลูกโดยเฉลี่ยเป็นระยะเวลา 1-2 ชั่วโมงต่อวัน และต่อเนื่องเป็นระยะเวลาหนึ่งสัปดาห์ในแต่ละรอบการออกผลผลิตของเห็ด ทั้งนี้ขึ้นอยู่กับปริมาณของเห็ดที่ต้องการเก็บโดยอายุของเห็ดต่อ 1 รอบการผลิตเท่ากับ 3 เดือน ส่งผลให้เกษตรกรมีความเสี่ยงที่จะเกิดโรคดังที่กล่าวมาแล้วได้มากกว่าเกษตรกรที่ปลูกพืชชนิดอื่น ๆ ดังนั้นเกษตรกรจึงต้องให้ความสำคัญทั้งสุขภาพของตนเอง และการระแวดระวังการเกิดโรคของเห็ดในโรงเรือนไปพร้อมกัน เนื่องจากสภาพอากาศภายในโรงเรือนเพาะเห็ดจะมีทั้งความชื้นสูง ก๊าซคาร์บอนไดออกไซด์ [9-11] และสปอร์เป็นจำนวนมากจึงไม่เหมาะกับมนุษย์เมื่อเข้าไปสัมผัสเป็นระยะเวลานาน การเข้าโรงเรือนเพาะปลูกเห็ดเพื่อตรวจสอบการเจริญเติบโตและตรวจสอบโรคเห็ดภายในโรงเรือนบ่อย ๆ จึงไม่เป็นการเหมาะสมอย่างยิ่ง

จากปัญหาที่กล่าวมาแล้วข้างต้น จะเห็นได้ว่ากระบวนการเพาะปลูกเห็ดเพิ่มปัจจัยเสี่ยงต่อปัญหาสุขภาพของเกษตรกรอย่างมาก รวมถึงโรคเห็ดนั้นก็ส่งผลให้เกษตรกรขาดทุนได้เมื่อเห็ดเกิดโรคเพียงครั้งเดียว ดังนั้นหากสามารถเฝ้าระวังปัญหาต่าง ๆ เหล่านี้ได้จะช่วยชีวิตเกษตรกรและโรงเรือนเพาะเห็ดนางฟ้ามีความปลอดภัยและลดปัญหาการขาดทุนได้ ซึ่งในงานวิจัยนี้จะนำเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง (Internet of Thing) เข้ามาใช้ในการควบคุมโรงเรือนและเฝ้าระวังสภาพแวดล้อมในโรงเรือนเพาะเห็ดนางฟ้าให้มีความเหมาะสมในการเจริญเติบโต เช่น อุณหภูมิ ความชื้น ความร้อน ก๊าซคาร์บอนไดออกไซด์ แสง [9-11] และการใช้การประมวลผลภาพเชิงลึก (Deep learning image processing) ในการวิเคราะห์โอกาสการเกิดโรคราเขียวของเห็ดนางฟ้าภายในโรงเรือนเพาะปลูก เพื่อช่วยให้เกษตรกรมีสุขภาพที่ดีและทำให้เห็ดนางฟ้าสามารถสร้างผลผลิตเพิ่มรายได้ให้กับเกษตรกรได้ตลอดทั้งปี

## 1.2 วัตถุประสงค์ของการวิจัย

เพื่อวิเคราะห์โรคเชื้อราเขียวของเห็ดนางฟ้าสำหรับเกษตรกรอัจฉริยะ

### 1.3 ความสำคัญของการวิจัย

ปัญหาแรกของการเพาะปลูกเห็ด คือ เกษตรกรผู้เพาะปลูกไม่สามารถควบคุมสภาพแวดล้อมที่เหมาะสมในการเพาะปลูกแบบดั้งเดิมได้อย่างสมบูรณ์ซึ่งส่งผลต่อคุณภาพและปริมาณการผลิตของเห็ด ปัญหาที่สองซึ่งมีความสำคัญที่ต้องได้รับการแก้ไขอย่างเร่งด่วนและปัจจุบันยังไม่มีวิธีแก้ปัญหาที่มีประสิทธิภาพ คือ โรคเห็ด หากเกษตรกรตรวจพบโรคซ้ำจะส่งผลกับภาวะการขาดทุนได้อย่างรวดเร็ว และปัญหาสุดท้ายคือ สภาพแวดล้อมในการเพาะปลูกเห็ดมีผลโดยตรงต่อสุขภาพของเกษตรกรผู้เพาะปลูกอย่างร้ายแรง ด้วยสาระสำคัญตามที่กล่าวมาแล้วข้างต้น งานวิจัยนี้จึงได้เสนอวิธีการที่แก้ปัญหาตามที่กล่าวมาให้หมดไป โดยการประยุกต์นำเอาเทคโนโลยีไอโอทีกับปัญญาประดิษฐ์เข้ามาแก้ปัญหาดังกล่าว

### 1.4 ขอบเขตของการวิจัย

ขอบเขตของงานวิจัยประกอบด้วย 3 ส่วน ดังนี้

#### 1. โรงเรือนที่ใช้เพาะปลูกเห็ดนางฟ้า

1.1 โรงเรือนเป็นระบบปิดที่สามารถควบคุมอุณหภูมิที่แตกต่างกันระหว่างภายในและภายนอกได้ดี

1.2 มีชั้นวางเห็ดภายในโรงเรือนในแนวนอน

1.3 มีพัดลมสำหรับการระบายอากาศ

1.4 โรงเรือนสามารถทำความสะอาดได้

1.5 โรงเรือนมีระบบทำความชื้นด้วยหมอก เพื่อลดภาวะการเกิดโรค

1.6 มีระบบไฟฟ้าให้แสงสว่าง

#### 2. ระบบควบคุมสภาพแวดล้อมในการเพาะปลูกด้วยไอโอที

2.1 มีเซ็นเซอร์วัดอุณหภูมิ

2.2 มีเซ็นเซอร์วัดความชื้นในอากาศ

2.3 มีเซ็นเซอร์วัดความชื้นในถุงเพาะปลูก

2.4 มีเซ็นเซอร์วัดแก๊สในโรงเรือน

2.5 มีเซ็นเซอร์วัดแสงภายในโรงเรือน

2.6 ควบคุมการพ่นหมอกเมื่อความชื้นต่ำ

2.7 ควบคุมพัดลมเพื่อดึงความชื้นออกจากโรงเรือน

2.8 ควบคุมการเปิด-ปิดแสงสว่าง

2.9 มีระบบกล้องวงจรปิดเพื่อถ่ายภาพโรคเห็ดในสภาพแวดล้อมที่แสงน้อย

2.10 เชื่อมต่อระบบเครือข่ายอินเทอร์เน็ตเพื่อรับส่งและแจ้งเตือนเมื่อระบบขัดข้องหรือเมื่อค้นพบโรคเห็ด

#### 3. ระบบวิเคราะห์โรคเชื้อราเขียวของเห็ดนางฟ้า

3.1 ออกแบบวิธีการวางกล้องสำหรับถ่ายภาพก่อนเห็ดนางฟ้าในเกษตรอัจฉริยะ

3.2 วิเคราะห์โรคเห็ดจากภาพถ่ายที่มีแสงน้อย

- 3.3 วิเคราะห์การเกิดโรคราเขียวในเห็ดนางฟ้าด้วยการประมวลผลภาพ
- 3.4 ปรับปรุงคุณภาพของภาพที่ถ่ายในที่มืดแสงน้อย
- 3.5 แฉ่งเตือนไปยังเกษตรกรเมื่อพบเจอโรคเชื้อราเขียวเห็ดนางฟ้า
- 3.6 ตรวจสอบโรคเชื้อราของเห็ดนางฟ้าภายใน 12 ชั่วโมง

### 1.5 นิยามศัพท์เฉพาะ

1. เห็ดนางฟ้า หมายถึง เชื้อราชนิดหนึ่งที่สามารถเพาะปลูกได้ ใช้เวลาในการเพาะสั้น ดอกเห็ดมีจำนวนมาก ให้เนื้อนุ่ม และสามารถนำไปประกอบอาหารได้หลากหลายชนิด ซึ่งจัดเป็นผักในโลกรอาหารชนิดหนึ่ง
2. สปอร์ หมายถึง เซลล์สืบพันธุ์ของพืชบางชนิดซึ่งจะงอกเป็นต้นใหม่ เช่น เพิน เห็ด มอสส์ เป็นต้น
3. โรคราเขียว หมายถึง เชื้อโรคประเภทฉาบฉวยคือจะคอยแย่งอาหารกับเชื้อเห็ดและกินก้อนเห็ดจนก้อนเห็ดไม่สามารถเกิดเห็ดนางฟ้าได้หรือหากเกิดดอกเห็นก็จะไม่มีความสมบูรณ์
4. การประมวลผลด้วยภาพ หมายถึง เทคนิควิธีการทางปัญญาประดิษฐ์ ที่สามารถวิเคราะห์ข้อมูลได้ด้วยภาพถ่าย
5. การเรียนรู้เชิงลึก หมายถึง การเรียนรู้ของเครื่องคอมพิวเตอร์ ซึ่งเป็นการฝึกฝนคอมพิวเตอร์ให้สามารถทำงานได้เหมือนมนุษย์ เช่น การจดจำคำพูด การระบุภาพ หรือการคาดการณ์ การเรียนรู้เชิงลึกจะกำหนดค่าพารามิเตอร์พื้นฐานเกี่ยวกับข้อมูลและฝึกให้คอมพิวเตอร์เรียนรู้ด้วยตัวเองโดยการจดจำรูปแบบด้วยการประมวลผลหลายชั้น
6. สมาร์ทฟาร์ม หมายถึง การทำการเกษตรอัจฉริยะที่นำเทคโนโลยีเข้ามาบริหารจัดการระบบการเพาะปลูกในทุก ๆ ขั้นตอน และสามารถควบคุมทุกอย่างได้ด้วยเทคโนโลยี เพื่อทำการตรวจสอบ เก็บข้อมูล วิเคราะห์ และแก้ปัญหาการเพาะปลูกได้แบบ Real-Time พร้อมกับสามารถแสดงผลข้อมูลการเจริญเติบโตและคาดการณ์ผลผลิตได้อย่างแม่นยำ

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้เป็น การอธิบายถึงแนวคิด ทฤษฎี เทคนิค วิธีการ และงานวิจัยที่เกี่ยวข้องสอดคล้องกับงานวิจัยมีรายละเอียดดังนี้

#### 2.1 เห็ดนางฟ้า

เห็ด (Mushroom) หรือ รา (fungi) [1, 4, 6, 12] เป็นพืชชั้นต่ำที่มีคุณสมบัติสูง การเจริญเติบโตของเห็ดนั้นไม่สามารถสังเคราะห์แสงได้เอง และในปัจจุบันพบว่าหลายประเทศหันมาให้ความสนใจและร่วมมือกันในการวิจัยและค้นคว้า ทดลอง คัดเลือก และปรับปรุงพันธุ์เห็ดให้มีจำนวนมากขึ้น และพัฒนาเทคนิควิธีการเพาะเลี้ยงและขยายพันธุ์เพื่อเพิ่มปริมาณผลผลิตให้เพียงพอกับความต้องการของผู้บริโภค

ประเทศไทยเป็นประเทศที่เหมาะสมต่อการเพาะเห็ดอย่างมาก เพราะมีวัสดุเหลือใช้จากพืชเศรษฐกิจสามารถนำมาตัดแปลงเพาะเห็ดได้เป็นอย่างดี ประกอบกับมีสภาพดินฟ้าอากาศที่เหมาะสมต่อการเจริญเติบโตของเห็ดเกือบทุกชนิด ดังนั้นจึงควรส่งเสริมให้เกษตรกรหันมาเพาะเห็ดกันอย่างมากและทำให้เกษตรกรมีรายได้เพิ่มขึ้น

##### 1. ประโยชน์ของเห็ด

ประเทศไทยและต่างประเทศได้มีการศึกษาถึงประโยชน์ต่าง ๆ ของเห็ดแต่ละชนิด เพื่อหาคุณสมบัติของเห็ดแต่ละชนิดที่เป็นประโยชน์ต่อมนุษย์ ประโยชน์ในการรักษาโรค ไม่ว่าจะเป็นคุณค่าทางอาหาร ทางยา เป็นต้น [5, 13-15] มีรายละเอียดดังนี้

1.1 คุณค่าทางอาหารของเห็ดจากการค้นคว้าเกี่ยวกับคุณค่าทางอาหารของเห็ด โดยกรมวิทยาศาสตร์ พบว่า เห็ดที่มีจำหน่ายในท้องตลาด เช่น เห็ดฟาง เห็ดหูหนู เห็ดนางรม เห็ดเป๋าฮื้อ และเห็ดนางฟ้า เมื่อนำมาวิเคราะห์พบว่าประกอบด้วยสารอาหาร พวกคาร์โบไฮเดรต โปรตีน ไขมัน แร่ธาตุต่าง ๆ และวิตามิน ที่แตกต่างกัน จากชนิดสารอาหารที่พบในเห็ดดังกล่าว ย่อมพิสูจน์ได้ว่าเห็ดเป็นอาหารที่มีคุณค่าเทียบเท่าเนื้อสัตว์จริง

1.2 สรรพคุณทางยาของเห็ดในการบริโภคอาหารควรเลือกบริโภคพืชผักที่มีคุณค่าทางอาหารทดแทนเนื้อสัตว์บ้างโดยเฉพาะพืชที่ประเภทเห็ดจะไม่มีสารคอเรสเตอรอลที่เป็นอันตรายต่อระบบไหลเวียนโลหิต ประกอบกับเห็ดมีปริมาณธาตุโซเดียมค่อนข้างต่ำ จึงจัดเป็นอาหารที่เหมาะสมสำหรับผู้ป่วยที่เป็นโรคไตโรคหัวใจ และความดันโลหิตสูง

1.3 สร้างรายได้แก่ครอบครัวและประเทศชาติประเทศไทยมีสภาพภูมิอากาศเหมาะสมจึงสามารถเพาะเห็ดได้ตลอดทั้งปี ทั้งเพื่อใช้บริโภคภายในประเทศและส่งออกจำหน่ายต่างประเทศ

## 2. ปัจจัยที่มีผลต่อการเจริญเติบโตของเห็ด

การที่เห็ดจะเจริญเติบโตได้ดีนั้นต้องมีปัจจัยที่เอื้ออำนวยต่อการเจริญเติบโตของเห็ด [2, 3] ซึ่งฤดูฝนนั้นจะเป็นฤดูการที่พบการออกผลผลิตของดอกเห็ดมากที่สุด ปัจจัยที่มีผลต่อการเจริญเติบโตของเห็ดจึงสามารถสรุปได้ 2 ปัจจัยหลัก ดังนี้

2.1 ปัจจัยทางพันธุกรรม คือ ปัจจัยทางสายพันธุ์เห็ด ก่อนการเพาะเห็ดจะต้องมีการคัดเลือกสายพันธุ์เห็ดที่ให้ผลผลิตสูงและมีลักษณะตามที่ต้องการ เช่น มีความแข็งแรงทนทานปราศจากศัตรูเห็ดมีลักษณะดอกเห็ดตามที่ต้องการเจริญเติบโตได้ดีในสภาพแวดล้อมฤดูกาล และท้องถิ่นที่เพาะปลูก เช่น เห็ดหลินจือ เห็ดนางรมสีเทาที่เหมาะสมจะเพาะปลูกในช่วงฤดูหนาว เป็นต้น

2.2 ปัจจัยทางสิ่งแวดล้อม นอกจากปัจจัยทางพันธุกรรมแล้วเห็ดจะให้ผลผลิตออกดอกเห็ดสูงจำเป็นต้องอยู่ในสภาวะแวดล้อมที่เหมาะสมต่อเห็ดชนิดนั้น ๆ แบ่งสิ่งแวดล้อมที่เกี่ยวข้องกับการเพาะเห็ด 2 ประเภท คือ

### 1) สิ่งแวดล้อมที่ไม่มีชีวิต

เห็ดเป็นพืชชั้นต่ำจำพวกราไม่สามารถสังเคราะห์แสงได้แบบพืชสีเขียวอาหารของเห็ดได้จากการย่อยสลายอินทรีย์วัตถุที่ผู้เพาะอาหารที่เห็ดย่อยได้ง่าย คือ กลูโคส เห็ดหลายชนิดเจริญเติบโตบนอาหารที่มีโครงสร้างซับซ้อน เช่น แป้ง เซลลูโลส ลิกนิน เป็นต้น แต่เห็ดบางชนิดย่อยไม้มูลสัตว์และปุ๋ยหมักได้มีรายละเอียดดังนี้

1.1 อุณหภูมิ มีความสำคัญต่อการเจริญเติบโตของเห็ดมากทั้งระยะการเจริญเติบโตของเส้นใยระยะออกดอก และการปล่อยสปอร์ของเห็ด ปกติอุณหภูมิที่เหมาะสมต่อการเจริญเติบโตของเส้นใยจะสูงกว่าช่วงออกดอก 3-5 องศาเซลเซียส เห็ดแต่ละชนิดต้องการอุณหภูมิแตกต่างกัน

1.2 ความชื้นธรรมชาติเห็ดจะเจริญเติบโตได้ดีในสภาพความชื้นสูงแบ่งเป็น 2 ประเภท คือ 1). ความชื้นในวัสดุเพาะ (Moisture) คือ ความชื้นในปุ๋ยหมักเพาะเห็ดและในกองฟางที่เหมาะสมคือ 60-65 เปอร์เซ็นต์ ถ้ามากเกินไปเส้นใยจะขาดออกซิเจนทำให้เส้นใยอ่อนแอเชื้อราและแบคทีเรียจะเจริญได้ดีทำให้เส้นใยเห็ดเกิดความเสียหายหรืออาจเป็นโรคเห็ดได้ 2). ความชื้นในอากาศ (Humidity) คือ ความชื้นรอบก้อนเชื้อเห็ดหรือในกองเห็ดฟาง ถ้าน้อยเกินไปทำให้ดอกเห็ดแห้งเป็นสีเหลือง ชะงักการเจริญเติบโต ถ้ามากเกินไปดอกเห็ดจะฉ่ำน้ำ คุณภาพต่ำ

1.3 ความเป็นกรด - ด่าง (pH) เห็ดเจริญได้ดีในอาหารเป็นกลาง หรือกรดเล็กน้อย (pH 6.5 - 7) ถ้าอาหารเป็นกรดเห็ดจะเจริญเป็นเส้นใยแต่จะไม่ออกดอกสภาพความเป็นกรด - ด่าง ของอาหารที่เหมาะสมต่อการเจริญเติบโตของเห็ดจะแตกต่างกันตามชนิดของเห็ด ซึ่งค่า pH ของน้ำที่ใช้รดเห็ดนั้นจะเหมาะสมต่อการออกดอก คือ ค่า pH จะต้องเป็นกลาง (pH 7) น้ำต้องสะอาดปราศจากสารเคมี เช่น น้ำคลอง น้ำฝน น้ำบ่ หรือสระจะดีกว่าน้ำบ่บาดาล

1.4 การถ่ายเทอากาศเห็ดต้องการก๊าซออกซิเจนทุกระยะแต่ระยะออกดอกต้องการออกซิเจนมากกว่าระยะของเส้นใยส่วนก๊าซคาร์บอนไดออกไซด์จะทำให้เส้นใยเจริญดี แต่ถ้าระยะออกดอกโรงเรือนที่การถ่ายเทอากาศไม่ดีทำให้ดอกเห็ดไม่บานดอกเล็กก้านดอกยาวผิดปกติ

1.5 แสงมีผลต่อการเจริญเติบโตของเส้นใยสูงอาหารที่มีสภาพเป็นกลางทำให้เกิดการบูดเน่าเกิดความร้อน และกลิ่นแอมโมเนียปล่อยสารปฏิชีวนะยับยั้งการเจริญเติบโตของเส้นใยเห็ด

2) ราเมือก (Slime Mold) เป็นราที่มีการเจริญเติบโตของเส้นใยเป็นร่างแหสีเหลืองมีกลิ่นเหม็นคาวจัดมักเกิดกับก้อนเชื้อเห็ดที่ใกล้หมดอายุในสภาพความชื้นสูงโรงเรียนสกปรกการถ่ายเทอากาศไม่ดี ราเมือกจะกินเส้นใยเห็ดและดอกเห็ดทำให้ก้อนเชื้อเห็ดหมดอายุเร็วกว่าปกติป้องกันได้โดยการรักษาโรงเรียนให้สะอาดพักโรงเรือนแต่ละรุ่นอย่างน้อย 15 วันขึ้นไป

3. ไวรัส (Virus) เป็นศัตรูเห็ดที่มีขนาดเล็กที่สุด มีทั้งประโยชน์และโทษ ประโยชน์คือทำให้เกิดเห็นพันธุ์ใหม่ โทษคือ ทำให้เห็ดมีลักษณะผิดปกติ ดอกเห็ดมีลักษณะคดงอ ดอกไม่บานเป็นพุ่มหรือเรียกว่า โรคหงอนไก่

ทั้งนี้ในการเพาะเห็ดให้ได้ผลผลิตปริมาณที่มาก ทางสมาคมนักวิจัยและเพาะเห็ดแห่งประเทศไทย [12] ได้ทำการศึกษาและพบว่า สภาพแวดล้อมที่เหมาะสมในการเจริญเติบโตของเห็ดแต่ละชนิดนั้น มีความแตกต่างกันโดยยกตัวอย่างชนิดเห็ดบางชนิดดังตารางที่ 2.1 **ผิดพลาด! ไม่พบแหล่งอ้างอิง**

ตารางที่ 2.1 สภาพแวดล้อมในการเจริญเติบโตของเห็ด

ชนิดเห็ด	ระยะบ่ม		ระยะเกิดดอก		การเปิดก่อน	เงื่อนไขการเกิดดอก			ระยะห่างรุ่น (วัน)
	°C	วัน	°C	วัน		ความชื้น	แสง	การถ่ายเท	
เห็ดนางรม เห็ดนางฟ้า เห็ดขอนขาว	28-38	25-40	25-35	90	ตั้งสำลื้ออก ถอดคอขวด	70-90%	น้อย	ดี	10-15
เห็ดหอม	24-32	60-70	24-30	90	ปาดเหลือ กัน	70-80%	ปานกลาง	ดี	15-20
เห็ดฟาง	35-38	7-9	30-35	3-5	-	80-90%	น้อย	ดี	5

## 2.2 โรคราเขียว

ราเขียวเป็นปัญหาที่ฟาร์มเห็ดทุกฟาร์มจะต้องเจอ ไม่ว่าจะเป็นฟาร์มใหญ่มีชื่อเสียง ประสบการณ์มาช้านาน หรือฟาร์มรุ่นใหม่ขนาดกลางและขนาดเล็ก ต้องมีปัญหาเชื้อรากับทุกฟาร์ม ซึ่งโรคราเขียว เป็นเชื้อราที่อาศัยอยู่ในดินหรืออยู่ในอากาศก็ได้ เมื่อดินหรือวัสดุเพาะมีความชื้นเชื้อราจะเริ่มเจริญเติบโตขึ้นที่ดินไปถึงขี้ฟ้ายหรือข้าวฟ่าง ทั้งนี้ยังมีบางชนิดอาจติดมากับขี้ฟ้ายหรือใส่ปูนก่อนแล้ว ราเขียวเป็นราประเภทสร้างสปอร์มากและมีขนาดเล็กปลิวได้ในอากาศ และเจริญเติบโตเร็วมากเมื่อบริเวณดังกล่าวมีอุณหภูมิและความชื้นเหมาะสมที่จะเจริญเติบโตขยายพันธุ์ โดยที่เชื้อราเขียว

นั้นเป็นเชื้อราแข่งขันหรือราคู่แข่งกับเชื้อราเห็ดทำให้เห็ดเจริญเติบโตไม่ทันในบริเวณที่มีราเชื้อวกล่าวคือ ราเชื้อวทำแทรกซึมเข้าไปทำลายการเจริญเติบโตของเชื้อราเห็ดและกินเชื้อราเห็ดเป็นอาหาร จึงทำให้เชื้อราเห็ดไม่สามารถเจริญเติบโตได้ นอกจากนี้ราเชื้อวยังทำลายดอกเห็ดอ่อน ๆ ด้วยเส้นใยของราเชื้อวขณะอ่อนจะมีสีขาวค่อนข้างบาง เมื่ออายุครบ 3 วันขึ้นไปแล้วเชื้อราจะเริ่มสร้างสปอร์ที่มีสีเขียวยทำให้เกิดการระบาดได้ ทั้งนี้ราเชื้อวที่พบมี 3 ชนิด [12] คือ ราเชื้อว *Trichoderma sp.* และ *Gliocladium sp.* จะมีสีเขียวอ่อนหรือเขียวเข้ม ราเชื้อว *Penicillium sp.* จะมีสีเขียวอมเทาปัจจัยเสี่ยงในการเกิดราเชื้อวมีอยู่หลากหลายปัจจัยจากสามารถสรุปรายละเอียดได้ดังนี้

1. มาตรฐานความสะอาดไม่ดีพอ ความสะอาดถือเป็นเรื่องที่สำคัญมากในการทำฟาร์มเห็ดที่เจ้าของฟาร์มขาดการเอาใจใส่ที่ดีพอ มักจะเกิดปัญหาเชื้อราที่เป็นปรปักษ์ต่อเชื้อเห็ดได้ง่าย เช่น บางฟาร์มเก็บดอกเห็ด โดยปล่อยเศษดอกเห็ดตกและมักหมกที่พื้นโรงเรือนโดยไม่ทำความสะอาด หรือบางฟาร์มจะทิ้งก้อนเห็ดที่เป็นเชื้อราติดแบคทีเรียไว้ในบริเวณฟาร์ม โดยไม่ได้ทำลายหรือมีระบบจัดการที่ไม่ดี สปอร์ของราเชื้อวที่อยู่ในก้อนเห็ดเก่าก็อาจจะฟุ้งกระจายไปทั่วฟาร์มได้

2. ทิศทางของฟาร์มเห็ดไม่ถูกต้องทิศทางของฟาร์มเห็ดก็มีส่วนสำคัญที่ทำให้การแพร่กระจายของเชื้อราทำได้ง่าย ฟาร์มเห็ดที่ดีจึงควรตั้งขวางทิศทางลม เพื่อลดโอกาสเสี่ยงในการแพร่กระจายของเชื้อรา

3. การรดน้ำที่ไม่ถูกวิธีการให้ความชื้นที่เกินพอดี โรงเรือนอับและที่บิ่นเกินไป

4. รดน้ำมากเกินไปหรือน้ำเข้าไปข้างหน้าก้อนทำให้หน้าก้อนเน่ามีโอกาสดูดเชื้อราได้

5. ใช้ช้อนเขี่ยทำความสะอาดหน้าก้อนเห็ดโดยที่ไม่ใช้แอลกอฮอล์ทำความสะอาดเลยหากก้อนเห็ดก้อนใดมีเชื้อราเชื้อวปนเปื้อนอยู่ โอกาสจะแพร่กระจายจากก้อนหนึ่งไปสู่อีกก้อนหนึ่งได้ง่าย

6. ฟาร์มไม่สะอาดไม่มีการทำลายซากก้อนเชื้อเห็ดเก่าไม่มีการฆ่าเชื้อโรงเรือน พักโรงเอาสแลนขึ้นให้อากาศถ่ายเท 10-14 วัน ทำให้สปอร์ของราเชื้อวเลยฟุ้งกระจายไปยังเชื้อที่อยู่ในโรงบ่ม และ โรงเพาะเห็ดได้

7. แมลงระบาดในโรงเรือน เช่น แมลงวัน แมลงปีกแข็ง ไรแมลง เมื่อไปเกาะก้อนเชื้อเห็ดที่เห็นเชื้อรา และไปตอมก้อนอื่น ๆ ทำให้ก้อนอื่น ๆ สามารถติดเชื้อราได้

8. ระบาดโดยคนเป็นพาหะนำเชื้อรา เชื้อราเชื้อวระบาดจากการติดจากคนเก็บดอกเห็ดเก็บในโรงที่ราเชื้อวระบาดแล้วไปเก็บในโรงอื่น ๆ ทำให้ราเชื้อวระบาดไปทั่วฟาร์ม


ปัจจัยอื่น ๆ เช่น หนูอาจเป็นพาหะแพร่กระจายเชื้อราเชื้อวได้ หนูอาจจะเข้ามาแตะก้อนเชื้อเห็ด สปอร์ติดมากับพิน เท้าหนู อาจทำให้เกิดราเชื้อวได้ ทั้งนี้มีป้องกันการแก้ไขราเชื้อวในก้อนเห็ด หลายวิธี เช่น 1) พยายามหลีกเลี่ยงปัจจัยเสี่ยงที่กล่าวไว้ข้างต้น 2) หมั่นคอยสังเกตก้อนเห็ดและเปิดดอก หากพบก้อนเห็ดปนเปื้อนราเชื้อวให้รีบแยกออกจากโรงเรือน และใช้ยาแก้รารักษาหากราเชื้อวเกิดแล้ว ให้ลองวิธีแก้ไข คือ คัดแยกก้อนที่เป็นเชื้อราออกนอกโรงเรือน ชูดเอาส่วนที่ปนเปื้อนราเชื้อวออกใช้ยาแก้รารักษาก่อนที่จะรวมเป็นไปมาก เมื่อเชื้อราตายหรือไม่ขยายตัวค่อยนำเข้าโรงเรือน





ภาพที่ 2.1 ตัวอย่างก้อนเห็ดที่เป็นราเขียว



การเกิดเชื้อราเขียวนั้นจะต้องอาศัยความชื้นอยู่ที่ 90% ขึ้นไป และมีอุณหภูมิตั้งแต่ 35 องศาขึ้นไป ซึ่งข้อมูลจากตารางที่ 2.2 นี้เป็นตัวอย่างการเจริญเติบโตของราเขียว เมื่อราเขียวได้กินเชื้อเห็ดไปแล้วเชื้อเห็ดจะตายและไม่สามารถเติบโตภายในถุงเห็ดได้

ตารางที่ 2.2 ตัวอย่างลักษณะการเจริญเติบโตของราเขียว

ระยะ	ตัวอย่าง	รายละเอียด
1		ลักษณะของการเริ่มเกิดราเขียว ซึ่งจะเกิดบริเวณปากก้อนเห็ด เนื่องจากบริเวณปากก้อนเห็ดนั้นมีโอกาสที่จะได้รับน้ำและความชื้นได้โดยตรง รวมถึงอากาศที่เหมาะสมจึงสามารถเกิดราเขียวได้ง่าย และเป็นจุดเริ่มต้นในการเกิดโรคราเขียว : แสดงการเริ่มต้นของโรคเชื้อราในช่วง 1-6 ชั่วโมง ในถุงปลูก (หน้าก้อนเห็ด)



ระยะ	ตัวอย่าง	รายละเอียด
2		<p>เมื่อราเขียวเกิดขึ้นจะค่อย ๆ กินเชื้อของเห็ดไปเรื่อย ๆ ในระยะนี้เชื้อเห็ดก็ยังมีเจริญเติบโตและเชื้อเห็ดยังเดินปกติ</p> <p>: เริ่มแพร่กระจายไปยังพื้นที่ใกล้เคียงประมาณ 6-12 ชั่วโมง</p>
3		<p>จากนั้นเชื้อราเขียวจะค่อย ๆ ขยายและเพิ่มพื้นที่ในการเดินเชื้อราเขียวด้วยวิธีการกินเชื้อของเห็ดเป็นอาหาร</p> <p>: กระจายเกือบทั้งพื้นที่ประมาณ 12-18 ชั่วโมง</p>
4		<p>ในระยะนี้เชื้อราเห็ดเริ่มมีปฏิกิริยา คือ เชื้อเห็ดยังเริ่มเดินไม่เต็มที่เนื่องจากโดนราเขียวกินและเพิ่มปริมาณเพิ่มมากขึ้น</p> <p>: กระจายไปทั่วพื้นที่ถุงปลูกประมาณ 18-24 ชั่วโมง</p>
5		<p>สังเกตจากภาพเชื้อเห็ดเริ่มเปลี่ยนจากสีขาวเป็นสีเขียวออกน้ำตาลและเชื้อราเขียวเริ่มกินเชื้อเห็ดจนปากก้อนเห็ดเริ่มจะเป็นสีเขียว</p> <p>: เริ่มลามไปยังบริเวณอื่นภายในถุงปลูกประมาณ 24-30 ชั่วโมง</p>

ระยะ	ตัวอย่าง	รายละเอียด
6		เมื่อเริ่มกินเชื้อเห็ดจนเต็มหน้าปากถุงเชื้อเห็ดจะหยุดการเจริญเติบโต เนื่องจากราเขียวกินเชื้อเห็ดจนหมด : กระจายตัวประมาณหนึ่งในสามของถุงปลูกประมาณ 30-36 ชั่วโมง
7		หน้าปากถุงเห็ดจะเป็นสีเขียวออกน้ำตาลเข้มและราเขียวเริ่มกินเข้าไปภายในถุงก้อนเห็ดโดยแผ่วงกว้าง ทำให้เชื้อเห็ดไม่เดินและตายไป ทำให้ถุงก้อนเห็ดกลายเป็นสีน้ำตาลหรือสีแกลบ หากเชื้อเห็ดเดินเต็มก้อนถุงก้อนเห็ดจะเป็นสีขาวและขาวขึ้นไปเรื่อย ๆ และแกลบจะกลายเป็นอาหารของเชื้อเห็ด จากภาพสุดท้ายนี้เชื้อราเขียวได้กินเชื้อเห็ดจนหมดและเริ่มกินแกลบเป็นอาหาร : ในที่สุดก็กระจายไปทั่วถุงปลูก นานกว่า 36 ชั่วโมง

### 2.3 กล้องวงจรปิด

กล้องวงจรปิด หรือ CCTV ย่อมาจากคำว่า Closed Circuit Television หรือ เรียกอีกอย่างว่า Video Surveillance System คือระบบการบันทึกภาพจากกล้องที่เป็นระบบรักษาความปลอดภัย หรือที่ใช้เพื่อการสอดส่องดูแลเหตุการณ์ สถานการณ์ต่าง ๆ ที่เกิดขึ้น ระบบกล้องวงจรปิด (CCTV) เกิดขึ้นครั้งแรกที่ประเทศเยอรมนี ใน ค.ศ.1942 เป็นสิ่งที่จำเป็นสำหรับสถานที่ต่าง ๆ เช่น โรงเรียน โรงพยาบาล อาคาร สำนักงาน หรือสถานที่ราชการ อื่น ๆ เมื่อสมัยก่อนกล้องวงจรปิดมีไว้เพื่อจับผิด ผู้ร้ายวัง สอดส่องดูแล แต่สมัยนี้บทบาทของกล้องวงจรปิดมีมากกว่าที่กล่าวมาข้างต้น และยังสามารถติดตั้งกล้องวงจรปิดทำงานแทนมนุษย์และยังสามารถดูการทำงานของพนักงานได้ และสะดวกในการบริหารจัดการ ปัจจุบันนี้มีอินเทอร์เน็ตที่สามารถเชื่อมต่อกับกล้องวงจรปิดได้ทั้งหมด

ในส่วนของตัวเองกล้องวงจรปิดยังถูกแบ่งแยกประเภทตามชนิดของการส่งสัญญาณเป็น 2 แบบหลัก ๆ คือ 1) กล้องวงจรปิดที่ส่งสัญญาณแบบอนาล็อก (Analog CCTV Camera) เป็นกล้องวงจรปิดที่นิยมใช้ทั่วไป ราคาถูก ความคมชัดสูง 2) กล้องวงจรปิดที่ส่งสัญญาณแบบดิจิทัล (IP Camera) เป็นกล้องวงจรปิดสมัยใหม่ นิยมใช้เฉพาะกลุ่ม มีฟังก์ชันหลากหลาย ราคาไม่สูงมาก และเริ่มเป็นที่นิยมมากขึ้นในปัจจุบัน

## 1. โครงสร้างพื้นฐานของระบบกล้องวงจรปิด

การทำงานของกล้องวงจรปิด เริ่มจากตัวกล้องที่เป็นตัวรับสัญญาณภาพซึ่งจะรับภาพได้นั้นจะต้องมีแสงส่องไปยังวัตถุที่ต้องการและแสงนั้นจะตกกระทบวัตถุแล้วจึงสะท้อนกลับออกมา (ประสิทธิภาพกล้องนั้นขึ้นอยู่กับความไวแสง ซึ่งจะส่งผลให้คุณภาพของการทำงานแตกต่างกันออกไป) และภายในนั้นจะมีตัวที่แปลงสัญญาณภาพเป็นสัญญาณไฟฟ้า เพื่อส่งต่อสัญญาณตามสายที่เชื่อมจากกล้อง ไปสู่เครื่องรับสัญญาณภาพ (DVR) แล้วส่งต่อไปยังจอรับภาพ (Monitor) เพื่อแสดงภาพที่ได้จากตัวกล้อง โดยปกติแล้วนั้นตัวกล้องและจอภาพจะอยู่ต่างสถานที่กัน ซึ่งหลักการทำงานของระบบกล้องวงจรปิดจะไม่ซับซ้อนมาก ถ้าต้องการให้ภาพออกมาดีต้องประกอบด้วย องค์ประกอบหลายอย่าง

ส่วนประกอบของระบบกล้องวงจรปิดแบ่งออกเป็น 3 ส่วน คือ 1) ส่วนที่ใช้ส่งสัญญาณภาพ ประกอบด้วยกล้อง (Camera), เลนส์ (Lens) 2) ส่วนที่ใช้เชื่อมต่อ ประกอบด้วยสายเคเบิลทำหน้าที่เชื่อมต่อสัญญาณภาพระหว่างกล้องกับจอภาพ และเครื่องบันทึก DVR ทำหน้าที่เก็บข้อมูลและส่งสัญญาณข้อมูลที่บันทึกไปยังส่วนแสดงผล 3) ส่วนที่ใช้รับส่งสัญญาณภาพ เป็นจอมอนิเตอร์ซึ่งทำหน้าที่เป็นตัวแสดงผล

## 2. ประเภทของระบบกล้องวงจรปิด

### 1) กล้องวงจรปิดแบบมาตรฐาน (Standard Camera)

กล้องวงจรปิดแบบมาตรฐานเป็นกล้องชนิดที่มีราคาไม่แพง ขึ้นอยู่กับรุ่นและความคมชัดของกล้องมีจุดเด่นคือ ความสามารถเปลี่ยนเลนส์ เพื่อปรับมุมมองของภาพ เหมาะสำหรับพื้นที่ ๆ มีแสงสว่าง มีทั้งแบบใช้ในอาคาร Housing Indoor และแบบใช้นอกอาคาร Housing Outdoor กล้องวงจรปิดแบบมาตรฐานติดตั้งได้ง่าย ค่าบำรุงรักษาต่ำ มีความแข็งแรงและทนทานสูง และในบางรุ่นมีไมโครโฟนสำหรับบันทึกเสียง



ภาพที่ 2.2 กล้องวงจรปิดแบบมาตรฐาน (Standard Camera)

ที่มา : <http://www.soundcctvdd.com>

### 2) กล้องวงจรปิดแบบอินฟราเรด (Inferred Camera)

กล้องวงจรปิดแบบอินฟราเรดเป็นกล้องที่ทำจากวัสดุที่ทนทานสามารถใช้งานได้ทั้งกลางวันและกลางคืน มีคุณสมบัติในการจับภาพในที่มืดสนิทได้ ตัวกล้องจะแสดงภาพเป็นภาพสีในตอนกลางวันและเปลี่ยนไปแสดงภาพ ขาว - ดำ อัตโนมัติในตอนกลางคืน การเลือกกล้องวงจรปิดแบบ

อินฟราเรดควรเลือกตามระยะอินฟราเรดที่จำเป็นต้องใช้ เช่น 10 เมตร 20 เมตร 30 เมตร และกล้องวงจรปิดแบบอินฟราเรดจะมีหลอด LED อินฟราเรดที่จะส่งแสงสว่างอัตโนมัติในตอนกลางคืน เหมาะกับการใช้งานในสถานที่ ๆ ค่อนข้างมืด



ภาพที่ 2.3 กล้องวงจรปิดแบบอินฟราเรด (Infrared Camera)

ที่มา : <http://www.soundcctvdd.com>

### 3) กล้องวงจรปิดแบบโดม (Dome Camera)

กล้องวงจรปิดแบบโดม เป็นกล้องที่ถูกออกแบบมาให้มีขนาดเล็กกะทัดรัด สวยงาม เรียบร้อย ไม่สะดุดตา กลมกลืนเข้ากับเพดาน มีให้เลือกหลากหลาย เช่น แบบปกติ แบบมองย้อนแสง แบบใช้ในที่มีแสงสว่างน้อยได้ดี หรือแบบสามารถมองเห็นในที่มืดได้ ซึ่งอย่างหลังจะเป็นกล้องที่มี Infrared ติดตั้งภายในตัวกล้องวงจรปิด สามารถหมุนปรับมุมกล้องได้ 360 องศา กล้องชนิดนี้เหมาะสำหรับพื้นที่ ๆ มีแสงสว่างตลอดเวลา รูปลักษณะครึ่งวงกลมคล้ายโดมสามารถป้องกันการโยนผ้าปิดหน้ากล้องได้เป็นอย่างดี กล้องชนิดนี้ไม่เหมาะสำหรับติดตั้งนอกอาคาร เพราะตัวกล้องวงจรปิดรุ่นนี้ไม่ได้ออกแบบมาให้กันน้ำสถานที่ ๆ นิยมใช้งาน คือ โรงแรม คอนโด อาคารสำนักงาน ธนาคาร ฯลฯ เป็นต้น



ภาพที่ 2.4 กล้องวงจรปิดแบบโดม (Dome Camera)

ที่มา : <http://www.soundcctvdd.com>

### 4) กล้องวงจรปิดแบบซูม (Zoom Camera)

มีความสามารถในการหมุนรอบตัวเองได้ (Pan / Tilt / Zoom) ทั้งก้ม เงย หรือซูมภาพ มีทั้งที่เป็นแบบติดตั้งภายนอกอาคาร และติดตั้งภายในอาคาร เหมาะสำหรับติดตั้งเพื่อตรวจตราบริเวณโดยรอบของพื้นที่ การสั่งการหรือควบคุมกล้อง Speed Dome ต้องสั่งโดยเครื่องบันทึก หรือ

สั่งจากรีโมทควบคุม สามารถติดตั้งได้ดีทั้งในอาคารและนอกอาคาร โดยส่วนใหญ่มักติดตั้งด้านนอกอาคารระดับสูงจากพื้นดินเพื่อเพิ่มระยะการมองเห็นที่ดีขึ้น การติดตั้งกล้องวงจรปิดแบบสปีดโดมภายนอกอาคาร ต้องใช้ Housing หรือตัว Body ที่สามารถทนต่อสภาพอากาศและน้ำฝนได้ดี เพื่อป้องกันความเสียหายที่จะเกิดกับตัวกล้องวงจรปิด



ภาพที่ 2.5 กล้องวงจรปิดแบบซูม (Zoom Camera)

ที่มา : <http://www.soundcctvdd.com>

#### 5) กล้องวงจรปิดแบบไอพี (IP Camera)

กล้องวงจรปิดแบบไอพีสามารถควบคุมผ่านคอมพิวเตอร์หรือสมาร์ทโฟนได้โดยตรง สามารถทำการบันทึกภาพที่คอมพิวเตอร์หรือสมาร์ทโฟนเครื่องใดก็ได้ที่ต่ออยู่ในวงแลน (LAN) หรือ WAN กล้องวงจรปิดแบบไอพีมี LAN Card อยู่ในตัวกล้องและเป็น Web Server ในตัวมีทั้งแบบใช้สาย (Wired) และไร้สาย (Wireless) บางรุ่นมีคุณสมบัติในการซูม หมุนรอบตัวเอง ก้มเงยได้เช่นเดียวกับ Speed Dom กล้องวงจรปิดแบบไอพีบางรุ่นยังสามารถนำมาทำ Video Conference ได้เลย



ภาพที่ 2.6 กล้องวงจรปิดแบบไอพี (IP Camera)

ที่มา : <https://www.siamdropship.com>

### 3. เลนส์ (Lens)

เลนส์หลัก ๆ ในกล้องวงจรปิดแบ่งออกได้เป็น 3 ประเภท ประกอบด้วย Fix lens Auto iris lens และ Vari-Focal lens และแต่ละเลนส์จะมีคุณสมบัติแตกต่างกันดังต่อไปนี้

Fix lens มีระยะตายตัว ไม่สามารถปรับมุมมองภาพและระยะโฟกัสของภาพได้ ซึ่งกล้องวงจรปิดแต่ละประเภทจะใช้ Fix lens ที่แตกต่างกัน เช่นกล้องวงจรปิดแบบโดมจะใช้ Boras lens จัดเป็น Fix Lens ชนิดหนึ่ง มีขนาดเล็ก รูปทรงออกทางแบน ด้วยมีมิติทางกว้างมากกว่าขนาดลำตัวกล้องวงจรปิดแบบล็อกจะใช้ C-Mount lens จะมีความยาวช่วงทำยเลนส์ ถึงหน้าตัวรับภาพ 17.5 มม. และ CS-Mount lens จะมีความยาวช่วงทำยเลนส์ ถึงหน้าตัวรับภาพ 12.5 มม.



ภาพที่ 2.7 ตัวอย่างเลนส์ Fix lens

ที่มา : <http://www.cctvpool.com/index.php>

Auto iris lens เลนส์นี้สามารถปรับระยะและโฟกัสของภาพได้ ซึ่งการปรับขนาดรูรับแสงจะทำงานร่วมกับกล้องวงจรปิด ด้วยกล้องวงจรปิดจะจ่ายไฟกระแสตรง หรือ DC Type ให้กับเลนส์ เพื่อให้ตัวเลนส์สามารถปรับขนาดรูรับแสงตามสภาวะของแสงได้อัตโนมัติ ส่งผลให้ภาพที่ได้มีความคมชัดมากขึ้น



ภาพที่ 2.8 ตัวอย่างเลนส์ Auto iris lens

ที่มา : <http://www.cctvpool.com/index.php>

Vari – Focal lens เป็นเลนส์ที่ปรับระยะโฟกัสได้ด้วยตนเองเพื่อให้ได้ภาพในจุดที่ต้องการชัดจนที่สุด เช่น เมื่อมีการเปลี่ยนสถานที่ติดตั้งบริเวณรั้วบ้านเข้ามาไว้ภายในบ้านก็จะสามารถปรับเปลี่ยนระยะการจับภาพได้

การเลือกใช้เลนส์ของกล้อง CCTV ควรคำนึงถึงพื้นที่ที่ต้องการเฝ้าระวังก่อน จากนั้นจึงลงลึกที่ตัวเลนส์ ทั้งในเรื่องความยาวโฟกัส (Focal Length) และมุมมองภาพ (Angle of View) โดยความยาวโฟกัสควรสัมพันธ์กับมุมมองภาพ เพื่อให้ได้ประสิทธิภาพการทำงานที่เหมาะสม ขนาดของเลนส์ที่นิยมในปัจจุบัน มีหน่วยวัดเป็นมิลลิเมตร เริ่มตั้งแต่ขนาด 2.8, 3.6, 4, 6, 8, 12, 16 จนถึง 25 มิลลิเมตร ซึ่งความสามารถของเลนส์แต่ละขนาด คือ

- 1) เลนส์ 2.8 มิลลิเมตร เป็นเลนส์มุมกว้างมาก (เกิน 100 องศา) ให้ภาพกว้างและชัดใกล้ (ราว 2 เมตร) อาทิ ภายในลิฟต์
- 2) เลนส์ 3.6 และ 4 มิลลิเมตร เหมาะกับพื้นที่กว้างที่ไม่ไกลนัก ระยะราว 3 ถึง 4 เมตร อาทิ พื้นที่สำนักงาน
- 3) เลนส์ 6 และ 8 มิลลิเมตร เป็นเลนส์มุมแคบราว 30 ถึง 45 องศา เหมาะกับพื้นที่ไม่กว้างแต่มีระยะทาง อาทิ ทางเดินภายในโรงแรม
- 4) เลนส์ 12 มิลลิเมตร หรือสูงกว่า เหมาะกับการมองระยะไกล หรือเน้นความชัดจนในจุดที่ห่างออกไปนับสิบกเมตร

เลนส์กล้องวงจรปิดจัดเป็นอุปกรณ์อิเล็กทรอนิกส์อย่างหนึ่ง ภายในตัวกล้องฯจึงต้องมีวงจรเพื่อจ่ายไฟให้กับเลนส์ ซึ่งมี 2 รูปแบบ คือ DC Type และ Video Type

เลนส์แบบไฟตรง (DC Type) ตัวกล้องวงจรปิด CCTV มีวงจรจ่ายไฟกระแสตรง (DC) ให้กับเลนส์ เพื่อให้อุปกรณ์ขนาดเล็กมาก ลักษณะคล้ายมอเตอร์ (กัลวานอมิเตอร์, GalvanoMeter) ทำงาน ทำให้มันแสงเปิดหรือปิด ตามการเปลี่ยนแปลงของแสง

เลนส์แบบสัญญาณภาพ (Video Type) ตัวกล้องฯจ่ายไฟให้กับเลนส์ด้วยสัญญาณภาพ โดยมีความเข้มของสัญญาณภาพแตกต่างกันตามการเปลี่ยนแปลงของแสง เลนส์ที่รองรับการจ่ายไฟแบบนี้ ต้องมีแผงวงจรช่วยแปลงค่าของสัญญาณภาพให้เป็นสัญญาณไฟฟ้า เพื่อให้กัลวานอมิเตอร์ทำงาน (ผู้ผลิตบางรายอาจเรียกชื่ออื่นแทน กัลวานอมิเตอร์ แต่หลักการทำงานเหมือนกัน คือ เพื่อให้มันแสงเปิดหรือปิดตามการเปลี่ยนแปลงของแสง)

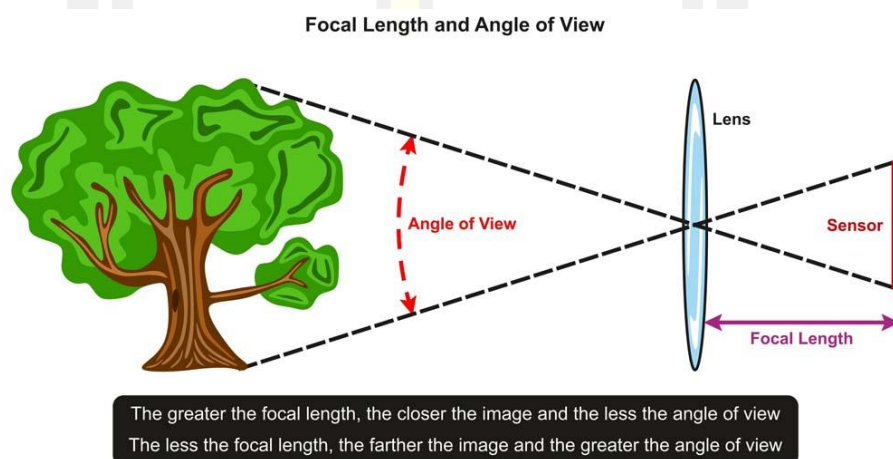
เลนส์ต่าง ๆ รวมถึงเลนส์กล้อง CCTV ล้วนมีข้อจำกัด อาทิ เลนส์ขนาดต่ำ ๆ ให้ความชัดจนระยะใกล้ แต่ระยะไกลความคมชัดลดลง หากเลือกใช้เลนส์ขนาดสูงขึ้น ก็ได้ผลตรงกันข้าม คือ ภาพระยะใกล้มักไม่ชัด แต่ระยะไกลชัดจน กล้อง CCTV วงจรปิดส่วนใหญ่สามารถเปลี่ยนเลนส์ได้ตามวัตถุประสงค์ใช้งาน ที่นิยมทั่วไปมักเลือกใช้เลนส์ 3.6 และ 4 มิลลิเมตร ซึ่งเป็นขนาดกลาง ๆ ที่รองรับการทำงานได้หลายรูปแบบการเฝ้ามองและป้องกันภัย

#### 4. การพิจารณามุมมองของภาพ

สำหรับการพิจารณามุมมองของภาพจะมีความแตกต่างกันของเลนส์มี 3 แบบ คือ Fix lens Auto iris lens และ Vari – Focal lens ซึ่งแต่ละเลนส์จะให้มุมมองของภาพที่แตกต่างกันจะอธิบายแต่ละเลนส์ดังตารางที่ 2.3

#### 5. ระยะเลนส์

ระยะเลนส์หรือทางยาวโฟกัส (Focal length) ทางยาวโฟกัสมักแสดงเป็นตัวเลขที่มีหน่วยเป็นมิลลิเมตร (mm) เป็นการคำนวณระยะที่เกิดขึ้นจากการเกิดภาพบนเซ็นเซอร์จากระยะทางของวัตถุที่ระยะหนึ่งหรือที่ระยะอนันต์ที่ผ่านจุดศูนย์กลางเลนส์และให้ภาพปรากฏอย่างพอดีบนระนาบเซ็นเซอร์ในกล้อง



ภาพที่ 2.9 ระยะเลนส์





ที่มา : <https://www.photoschoolthailand.com/what-is-focal-length>

ซึ่งระยะเลนส์จะบอกได้ถึงมุมรับภาพ ความกว้างหรือแคบของมุมมองภาพที่จะได้ ระยะเลนส์ที่มีตัวเลขมาก ยิ่งเป็นเลนส์ที่มีระยะโฟกัสยาว ยาวมุมมองภาพก็จะแคบลงและกำลังขยายก็จะยิ่งสูงขึ้น และเลนส์ที่มีระยะเลนส์ที่มีตัวเลขน้อย ทางยาวโฟกัสโฟกัสสั้นมุมรับภาพก็จะกว้างขึ้นและกำลังขยายจะลดลง คือถ้าจะให้จำง่าย ๆ คือ เลนส์เลขน้อย mm = มุมรับภาพกว้างและเลนส์ที่มีเลขมาก mm = มุมรับภาพแคบ

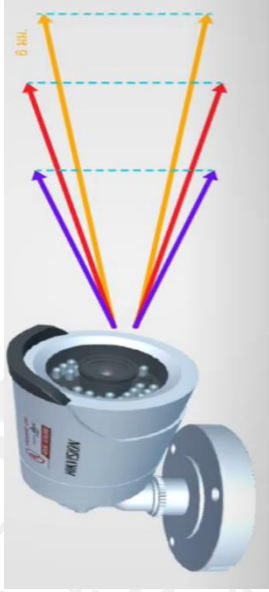


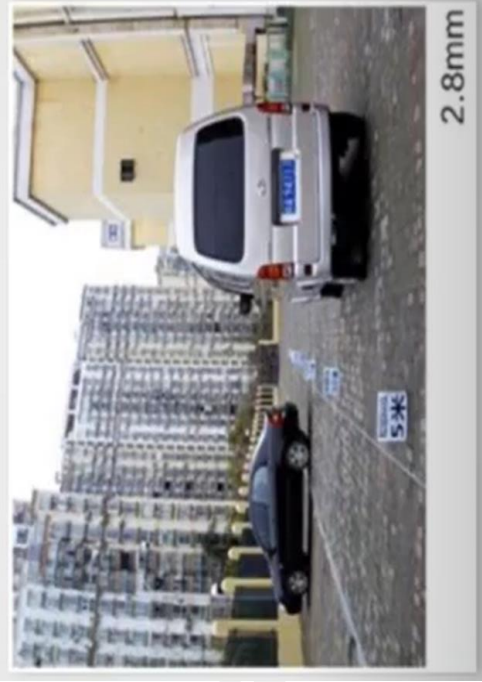
สำหรับระยะเลนส์ของกล้อง CCTV และกล้องถ่ายภาพทั่วไปจะมีความแตกต่างกันทั้งในเรื่องของเลนส์และระยะโฟกัสดังจะอธิบายในตารางที่ 2.3




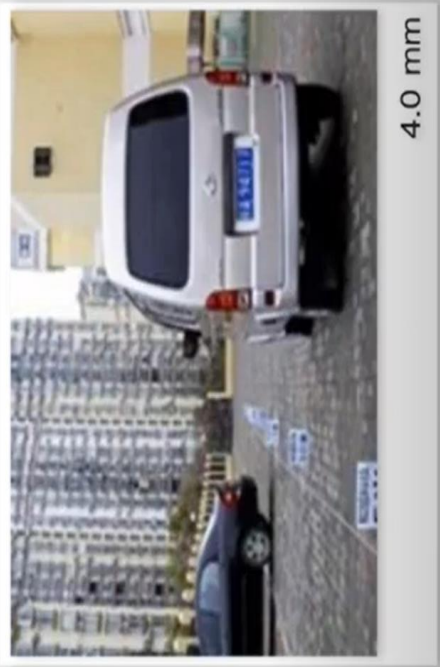
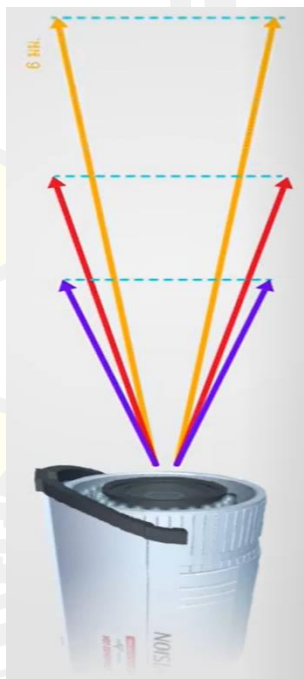

ตารางที่ 2.3 มุมกล้องและตัวอย่างภาพ

ลำดับ	เลนส์	มุมมอง	ตัวอย่างภาพ
1	Fix lens	 <p>ขนาดเลนส์ 2.8 mm มุมมองภาพ 105 องศา ระยะโฟกัส 1-4 เมตร</p>	
2	Fix lens	 <p>ขนาดเลนส์ 3.6 mm และ 4 mm มุมมองภาพ 90 องศา ระยะโฟกัส 4-8 เมตร</p>	

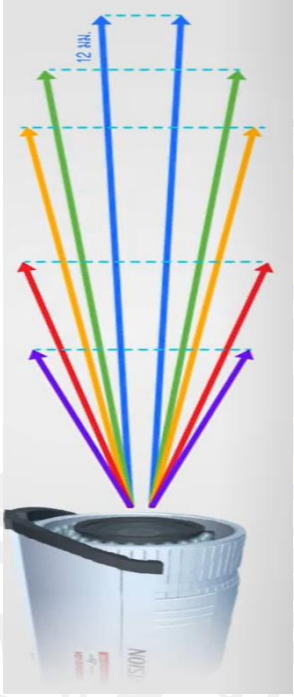

ตารางที่ 2.3 มุมกล้องและตัวอย่างภาพ (ต่อ)

ลำดับ	เลนส์	มุมมอง	ตัวอย่างภาพ
3	เลนส์	 <p>ขนาดเลนส์ 6 mm มุมมองภาพ 60 องศา ระยะโฟกัส 6-12 เมตร</p>	
4	Vari-Focal lens	 <p>ขนาดเลนส์ 2.8 mm มุมมองภาพ 105 องศา ระยะโฟกัส 1-4 เมตร</p>	

ตารางที่ 2.3 มุมกล้องและตัวอย่างภาพ (ต่อ)

ลำดับ	เลนส์	มุมมอง	ตัวอย่างภาพ
5	เลนส์	 <p>ขนาดเลนส์ 4 mm มุมมองภาพ 90 องศา ระยะโฟกัส 4-6 เมตร</p>	 <p>4.0 mm</p>
6	เลนส์	 <p>ขนาดเลนส์ 6 mm มุมมองภาพ 75 องศา ระยะโฟกัส 6-8 เมตร</p>	 <p>6.0mm</p>

ตารางที่ 2.3 มุมกล้องและตัวอย่างภาพ (ต่อ)

ลำดับ	เลนส์	มุมมอง	ตัวอย่างภาพ
	เลนส์	 <p data-bbox="707 1431 837 1666">ขนาดเลนส์ 12 มม มุมมองภาพ 45 องศา ระยะโฟกัส 10-14 เมตร</p>	

ข้อมูลดังกล่าวนี้ได้มาจาก ดิจิตอล โฟกัส ที่มา : <https://www.youtube.com/watch?v=DYVaF2jrLew> เป็นตัวอย่างในการทำความเข้าใจของขนาดเลนส์ มุมมองภาพ และระยะโฟกัสของภาพ ทั้งนี้ในการเลือกใช้กล้อง CCTV นั้นขึ้นอยู่กับความต้องการของผู้ใช้ว่าจะเลือกใช้ขนาดเลนส์เท่าไร และโดยส่วนมากผู้ใช้งานกล้อง CCTV จะนิยมใช้ Fix lens และมีขนาดเลนส์ 3.6 มม และ 4 มม จะพบมากตามท้องตลาดทั่วไป

## 2.4 เกษตรอัจฉริยะ

เกษตรอัจฉริยะหรือเกษตรอัจฉริยะ [16, 17] เป็นรูปแบบการทำเกษตรแบบใหม่ที่จะทำให้การทำไร่ทำนาที่มีภูมิคุ้มกันต่อสภาพภูมิอากาศที่เปลี่ยนไป โดยการนำเอาข้อมูลภูมิอากาศ อุณหภูมิ ความชื้น ฯลฯ เพื่อนำข้อมูลเหล่านี้มาใช้ในการวิเคราะห์และบริหารจัดการ ดูแลพื้นที่เพาะปลูกให้มีความสอดคล้องกับสภาพอากาศที่เกิดขึ้น รวมถึงการเตรียมความพร้อมรับมือกับสภาพอากาศที่จะเปลี่ยนแปลงไปในอนาคต ซึ่งการทำงานของเกษตรอัจฉริยะนั้นจะบูรณาการข้อมูลจากเครือข่ายเซ็นเซอร์ไร้สาย (Wireless sensor networks) ที่ติดตั้งตามจุดต่าง ๆ ภายในฟาร์มหรือไร่นา เช่น เซ็นเซอร์อุณหภูมิ ความชื้นในดินและในอากาศ แสง ลม และน้ำ เป็นต้น จากนั้นนำเสนอข้อมูลต่าง ๆ ต่อเกษตรกร เจ้าของไร่ ผ่านทางเว็บไซต์หรือมือถือ โดยจะมีการเก็บข้อมูลเป็นฐานข้อมูลของฟาร์มหรือไร่นา เพื่อนำมาใช้ในการตัดสินใจดำเนินกิจกรรมต่าง ๆ วางแผนการเพาะปลูก การให้น้ำ การให้ปุ๋ย หรือ การเฝ้าระวังโรคต่าง ๆ ของพืช เป็นต้น ซึ่งถือได้ว่าเป็นการตัดสินใจบนพื้นฐานของข้อมูลที่เป็นจริง ดังนั้นความผิดพลาดก็อาจจะน้อยลงได้ และถ้าเกิดมีความเปลี่ยนแปลงที่ผิดปกติ ก็สามารถรับรู้ได้อย่างรวดเร็วกว่าเดิมทำให้สามารถรับมือกับทุกปัญหาได้ทันเหตุการณ์



ภาพที่ 2.10 เกษตรอัจฉริยะ (Smart farming)


ที่มา : <https://www.freepik.com/>

ทั้งนี้การที่เกษตรอัจฉริยะจะสามารถทำงานได้เต็มศักยภาพตามที่ได้อธิบายมานั้น จะต้องอาศัยเทคโนโลยีที่สามารถเชื่อมต่อและทำงานร่วมกันได้ระหว่างเซ็นเซอร์และมือถือ [17, 18] และด้วยเกษตรอัจฉริยะเป็นการนำเอาเทคโนโลยีเข้ามาใช้เพื่อให้ระบบอัจฉริยะทางด้านเกษตรเกิดขึ้น นั่นคือ อินเทอร์เน็ตในทุกสรรพสิ่ง (Internet of things :IoT) ซึ่งมีการทำงานในการเชื่อมต่ออุปกรณ์ต่อ

อุปกรณ์ต่าง ๆ เข้ากับเครือข่ายอินเทอร์เน็ต และสามารถสั่งงานที่ต้องการได้ พื้นฐานการทำงานของอินเทอร์เน็ตในทุกสรรพสิ่งจะทำงานอยู่บนระบบฝังตัว หรือสมองกลฝังตัว (Embedded system) เป็นระบบประมวลผลที่ใช้ชิปหรือไมโครโพรเซสเซอร์ที่ออกแบบมาโดยเฉพาะเป็นระบบคอมพิวเตอร์ขนาดเล็กที่ฝังไว้ในอุปกรณ์ เครื่องใช้ไฟฟ้า และเครื่องเล่นอิเล็กทรอนิกส์ต่าง ๆ ซึ่งต้องมีอินเทอร์เน็ตเป็นโครงสร้างพื้นฐาน จากความสามารถที่กล่าวมาของอินเทอร์เน็ตทุกสรรพสิ่งเกิดขึ้นในสังคมปัจจุบันเป็นจำนวนมาก โดยนำมาใช้ในการเชื่อมอุปกรณ์และเครื่องมือต่าง ๆ เช่น คอมพิวเตอร์ โทรศัพท์มือถือ รถยนต์ ตู้เย็น โทรทัศน์ และอื่น ๆ เข้าไว้ด้วยกัน โดยเครื่องมือต่าง ๆ จะสามารถเชื่อมโยงและสื่อสารกันได้โดยอ่านระบบอินเทอร์เน็ต ซึ่งอนาคตของผู้บริโภคทั่วไปจะเริ่มคุ้นเคยกับเทคโนโลยีที่ทำให้สามารถควบคุมสิ่งต่าง ๆ ทั้งจากในบ้าน สำนักงานหรือจากที่ใดก็ได้ เช่น การควบคุมอุณหภูมิภายในบ้าน การเปิดปิดไฟ ไปจนถึงการสั่งให้เครื่องรดน้ำต้นไม้ หรือแปลงเกษตรของตนเอง

### 1. เทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง (Internet of thing)

อินเทอร์เน็ตของสรรพสิ่ง (Internet of thing : IoT) [10, 18-20] แม้จะผ่านไปไม่กี่สัปดาห์ก็ไม่มีใครสามารถจินตนาการได้ว่าจะมีดีไอเอแฮกกับครอบครัวในทวีปอื่น ซึ่งถือได้ว่าเป็นเรื่องธรรมดาทั้งหมดนี้เกิดจากเทคโนโลยีที่ราคาถูกลงและอุปกรณ์ที่เกิดขึ้นมาใหม่พร้อมความสามารถใหม่ ๆ ที่ได้รับการปรับปรุง ผู้คนสามารถทำสิ่งต่าง ๆ ได้ด้วยการคลิกบนสมาร์ตโฟน ไม่ว่าจะเป็นการส่งอีเมล จ่ายบิลออนไลน์ หรือจองรถแท็กซี่ สิ่งที่มีมาเมื่อปี ค.ศ.1991 [19] คือ Internet of Computers (IoC) และ IoC นั้นค่อย ๆ มีขนาดใหญ่ขึ้นเรื่อย ๆ เมื่อผู้คนเริ่มใช้มากขึ้นเรื่อย ๆ ด้วยการเกิดขึ้นของโทรศัพท์แบบพกพาและอุปกรณ์เชื่อมต่ออินเทอร์เน็ตของอุปกรณ์ต่าง ๆ เริ่มต้นขึ้น และในที่สุดก็ขยายขึ้นเมื่อโทรศัพท์มือถือ คอมพิวเตอร์แล็ปท็อปและแท็บเล็ต มีราคาถูกลงและคนทั่วไปสามารถเข้าถึงได้มากขึ้น ในปี ค.ศ.2016 มีการเชื่อมต่อสิ่งใหม่ ๆ มากกว่า 5.5 ล้านรายการในทุกวัน จึงทำให้เกิดขอบเขตอันยิ่งใหญ่สำหรับ Internet of Things (IoT) [21] เนื่องจากสิ่งต่าง ๆ ที่เชื่อมต่อกันอย่างต่อเนื่องเพื่อสร้าง IoT จึงมีสาขาวิชาต่าง ๆ ที่เกี่ยวข้องกับ IoT เกิดขึ้น ดังนั้นจึงสามารถคิด IoT จากการรวมกันของโดเมนต่าง ๆ [19] ดังภาพที่ 3 ที่แสดงรายการตัวแทนของโดเมนบางโดเมน ซึ่งส่วนใหญ่ทับซ้อนกันในแง่ของแนวคิดและเทคนิคที่ประกอบเป็น IoT ที่เป็นเพียงระบบที่เชื่อมต่อกันของสิ่งมีชีวิต เช่น เครื่องใช้กับพีซี ไร้ สัตว์ ฯลฯ และมนุษย์ โดยที่มนุษย์เชื่อมต่อกับอุปกรณ์เหล่านี้โดยใช้วัตถุอัจฉริยะบางอย่างที่ติดอยู่ ที่สามารถส่ง รับและวิเคราะห์ข้อมูลได้ ซึ่งสมาร์ตออบเจกต์เหล่านี้แสดงถึงความสัมพันธ์ระหว่างมนุษย์หรือสิ่งของทางกายภาพได้



ภาพที่ 2.11 โดเมนต่าง ๆ ที่เกี่ยวข้องกับอินเทอร์เน็ตของทุกสรรพสิ่ง  
ที่มา : [19]

เมื่อพอเข้าใจในเรื่องของการนำอินเทอร์เน็ตของสรรพสิ่งแล้ว โดยปกติอาจจะมีคนที่เกิดความสับสนเกี่ยวกับแนวคิดของ Internet of Things และ Internet of Everything ตามที่ Cisco [20] กล่าวว่า “ Internet of Everything (IoE) คือการเชื่อมต่อที่ชาญฉลาดของผู้คนกระบวนการ ข้อมูลและสิ่งต่าง ๆ ” IoE เชื่อมต่อสิ่งที่มีอยู่จริงกับสิ่งต่าง ๆ ในโลกไซเบอร์เข้าด้วยกัน ไม่ใช่แค่การอนุญาตให้อุปกรณ์สามารถพูดคุยกันได้เท่านั้น แต่เป็นเรื่องของการอนุญาตให้ทุกสิ่ง ไม่ว่าจะเป็ นสิ่งมีชีวิตไม่มีชีวิตหรือวัตถุเสมือนใด ๆ ให้สามารถพูดคุยกันได้ ส่วนวัตถุเสมือนนี้หายไป ใน IoT อาจมี วัตถุอัจฉริยะติดอยู่กับสิ่งของทางกายภาพและมนุษย์และโครงสร้างพื้นฐานของอินเทอร์เน็ต แต่ไม่ได้ รวมถึงวัตถุหรือสิ่งของที่สนใจ (Entity) ที่ไม่ใช่ทางกายภาพที่ฉลาด สำหรับใน IoE การเชื่อมต่ออาจ เป็นมนุษย์กับมนุษย์หรือสิ่งที่มีอยู่จริงและสิ่งที่มีอยู่จริงในโลกไซเบอร์ แนวคิด IoT และ IoE มีความ ทับซ้อนกันมาก เพื่อให้ได้เห็นมุมมองที่ดีขึ้นของแนวคิดสามารถแสดงแผนภาพเขตความสัมพันธ์ใน ภาพที่ 2.12 โดยสามารถอธิบาย ความสัมพันธ์ได้ดังนี้ [19] ซึ่งสัญลักษณ์  $\cap$  หมายถึงการรวมกัน หรือเรียกว่าอินเทอร์เน็ตเซกชั้น

Things  $\cap$  Intelligence = Smart Objects (Devices)

Network  $\cap$  Intelligence = Smart Network

Things  $\cap$  Network = Networked Devices

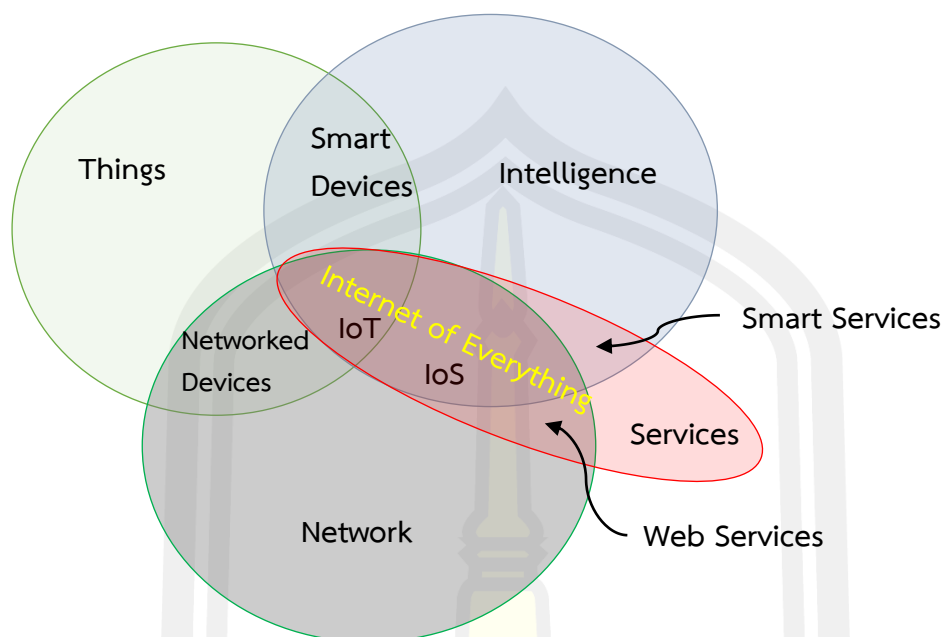
Services  $\cap$  Intelligence = Smart Services

Services  $\cap$  Network = Internet Services

Things  $\cap$  Intelligence  $\cap$  Network = Internet of Things (IoT)

Internet Services  $\cap$  Intelligence = Internet of Service (IoS)

Internet of Things  $\cup$  Internet of Services = Internet of Everything (IoE)




ภาพที่ 2.12 แผนภาพเขตความสัมพันธ์สำหรับแนวคิดของอินเทอร์เน็ตของสรรพสิ่ง  
อินเทอร์เน็ตของบริการ และอินเทอร์เน็ตของทุกสิ่ง  
ที่มา : [19]

ทั้งนี้ IoE ได้ใช้กันอย่างแพร่หลายซึ่งแสดงให้เห็นถึงการบูรณาการการเชื่อมต่อและความฉลาดเข้ากับทุกสิ่งทั้งทางกายภาพหรือเสมือน โดยมีเป้าหมายสุดท้ายที่เฉพาะเจาะจงเพื่อให้ได้ฟังก์ชันพิเศษ ตัวอย่างเช่นเว็บไซต์อัจฉริยะที่อาจมีระบบอัจฉริยะในตัว เพื่อระบุว่าเมื่อบุคคลใดบุคคลหนึ่งรู้สึกรำคาญจากโฆษณาที่ไม่จำเป็นหรือรู้สึกตื่นเต้นกับข้อเสนอที่ปรากฏขึ้นบนหน้าจอ ที่สามารถทำให้ผู้ใช้สามารถจินตนาการถึงเว็บไซต์เฉพาะผู้ใช้ ผู้ใช้ที่แตกต่างกันจะเห็นเค้าโครงหรือการนำเสนอเว็บไซต์เดียวกันที่แตกต่างกัน ในอนาคตอาจพัฒนาสิ่งอำนวยความสะดวกบนเว็บเพื่อที่จะให้แม้แต่ผู้พิการสามารถใช้อินเทอร์เน็ตเพื่อประโยชน์ได้ ซึ่งจะไม่ใช่เป็นการใช้อินเทอร์เน็ตสำหรับทุกคนทั่วไปแต่จะสามารถใช้สำหรับทุกคนและทุกสิ่ง ดังนั้นจึงจำเป็นต้องเข้าใจแนวคิดหลักที่สร้าง IoE และ IoT เหล่านี้

ในช่วงไม่กี่ปีที่ผ่านมาแอปพลิเคชัน IoT จำนวนมากเกิดขึ้นอย่างรวดเร็วและกว้างขวาง เช่น ใช้ในด้านสุขภาพ การขนส่ง สมาร์ทซิตี้ การเกษตร การศึกษา ฯลฯ องค์ประกอบหลักของแอปพลิเคชันเหล่านี้ส่วนใหญ่คือกลไกการเรียนรู้อัจฉริยะสำหรับการทำนาย เช่นการถดถอย การจัดหมวดหมู่ และการจัดกลุ่ม การชุดข้อมูลและการจัดรูปแบบหรือการวิเคราะห์ข้อมูลโดยทั่วไป ในบรรดาวิธีการเรียนรู้ของเครื่องหลาย ๆ เช่น วิธีการเรียนรู้เชิงลึก (Deep Learning :DL) ถูกนำไปใช้อย่างมากในแอปพลิเคชัน IoT ในช่วงไม่กี่ปีที่ผ่านมา เทคโนโลยีทั้งสองนี้ คือ DL และ IoT เป็นหนึ่งในสามอันดับแรกของแนวโน้มเทคโนโลยีเชิงกลยุทธ์สำหรับปี 2020 ที่มีการประกาศในงาน Analysts Explore Top Industry Trends at Gartner IT Symposium/Xpo 2019, October 20-24 in Orlando ที่ผ่านมา [22] สาเหตุของการประชาสัมพันธ์ที่น่าสนใจนี้ สำหรับ DL นี้หมายถึงความจริง



ที่ว่า วิธีการเรียนรู้ของเครื่องแบบเดิมไม่ได้ตอบสนองความต้องการด้านการวิเคราะห์ที่เกิดขึ้นใหม่ของระบบ IoT แต่ระบบ IoT ต้องการแนวทางการวิเคราะห์ข้อมูลที่ทันสมัย และวิธีการปัญญาประดิษฐ์ (Artificial Intelligence :AI) ที่แตกต่างกันตามลำดับชั้นของการสร้างและจัดการข้อมูล IoT ดังแสดงในภาพที่ 2.13



ภาพที่ 2.13 การสร้างข้อมูล IoT ในระดับต่างๆและแบบจำลองการเรียนรู้เชิงลึก เพื่อจัดการกับความรู้ที่เป็นนามธรรม  
ที่มา : [23]

อินเทอร์เน็ตของสรรพสิ่ง หรือ IoT และข้อมูลขนาดใหญ่มีความสัมพันธ์สองทาง คือ IoT เป็นผู้ผลิตหลักของข้อมูลขนาดใหญ่ และในทางกลับกัน IoT เป็นเป้าหมายสำคัญสำหรับการวิเคราะห์ข้อมูลขนาดใหญ่เพื่อปรับปรุงกระบวนการและบริการของ IoT [24] ยิ่งกว่านั้นการวิเคราะห์ข้อมูลขนาดใหญ่ของ IoT ได้พิสูจน์แล้วว่าสามารถนำคุณค่าน่าสนใจจากงานวิจัยของ Mohammadi และคณะ[25] ได้ทำ IoT และการเรียนรู้ของเครื่องมาใช้ในการตรวจสอบท่อที่ชำรุดและการซ่อมท่อ ซึ่งทำให้หน่วยบริหารสวนสาธารณะในโมอามีสามารถประหยัดค่าน้ำได้ประมาณหนึ่งล้านเหรียญสหรัฐ ข้อมูล IoT แตกต่างจากข้อมูลขนาดใหญ่ทั่วไป เพื่อให้เข้าใจถึงข้อกำหนดสำหรับการวิเคราะห์ข้อมูล IoT ได้ดีขึ้นจึงมีความจำเป็นต้องสำรวจคุณสมบัติของข้อมูล IoT ว่าแตกต่างจากข้อมูลขนาดใหญ่ทั่วไปอย่างไร ข้อมูล IoT แสดงลักษณะดังต่อไปนี้ [25]

1. ข้อมูลการสตรีมขนาดใหญ่ (Large-scale streaming data) อุปกรณ์จับข้อมูลจำนวนมากมักถูกแจกจ่ายและปรับใช้สำหรับแอปพลิเคชัน IoT และสร้างสตรีมข้อมูลอย่างต่อเนื่อง สิ่งนี้นำไปสู่ข้อมูลต่อเนื่องจำนวนมาก
2. ความแตกต่าง (Heterogeneity) อุปกรณ์เก็บข้อมูล IoT ต่าง ๆ รวบรวมข้อมูลที่แตกต่างกันทำให้เกิดความแตกต่างของข้อมูล

3. ความสัมพันธ์ของเวลาและพื้นที่ (Time and space correlation) ในแอปพลิเคชัน IoT ส่วนใหญ่อุปกรณ์เซ็นเซอร์จะเชื่อมต่อกับตำแหน่งเฉพาะ ดังนั้นจึงมีตำแหน่งและการบันทึกเวลาสำหรับแต่ละรายการข้อมูล

4. ข้อมูลเสียงรบกวนสูง (High noise data) เนื่องจากข้อมูลเพียงเล็กน้อยในแอปพลิเคชัน IoT ข้อมูลจำนวนมากอาจมีข้อผิดพลาดและเสียงรบกวนระหว่างการรับและส่งข้อมูล แม้ว่าการได้รับความรู้และข้อมูลที่ซ่อนอยู่จากข้อมูลขนาดใหญ่จะช่วยเพิ่มประสิทธิภาพได้ แต่ก็ไม่ใช่ว่าเรื่องง่ายและถูกต้องทั้งหมดสำหรับงานที่ซับซ้อนและท้าทายเช่นนี้ ซึ่งนอกเหนือไปจากความสามารถของการอนุมานและแนวทางการเรียนรู้แบบเดิม ๆ จำเป็นต้องใช้เทคโนโลยีใหม่ อัลกอริทึมและโครงสร้างพื้นฐาน [26] ทั้งนี้ความก้าวหน้าล่าสุดทั้งในการประมวลผลที่เร็วขึ้น และเทคนิคการเรียนรู้ของเครื่องขั้นสูงขึ้น ทำให้มีการวิเคราะห์ข้อมูลขนาดใหญ่และการดึงข้อมูลความรู้ที่เหมาะสมสำหรับการใช้งาน IoT

นอกเหนือจากการวิเคราะห์ข้อมูลขนาดใหญ่แล้วข้อมูล IoT แล้วนั้นยังมีการวิเคราะห์แบบใหม่อีกประเภทหนึ่งคือการวิเคราะห์ข้อมูลที่รวดเร็วและสตรีมมิ่งเพื่อรองรับแอปพลิเคชันที่มีสตรีมข้อมูลความเร็วสูงและต้องดำเนินการตามเวลา เช่น เรือลโหม่ เป็นต้น ซึ่งแท้จริงแล้วแอปพลิเคชัน เช่น การขับรถด้วยตนเอง การคาดเดาการเกิดเพลิงไหม้ การรับรู้ท่าทางของผู้ขับขี่ หรือผู้สูงอายุ รวมถึงจิตสำนึกและสภาวะสุขภาพ ต้องการการประมวลผลข้อมูลที่เข้ามาอย่างรวดเร็วเพื่อให้บรรลุเป้าหมาย นักวิจัยหลายคนได้เสนอแนวทางและกรอบการทำงานสำหรับการวิเคราะห์ข้อมูลสตรีมมิ่งที่รวดเร็ว ซึ่งใช้ประโยชน์จากความสามารถของโครงสร้างพื้นฐานและบริการระบบคลาวด์ (Cloud) [27], [28]


อย่างไรก็ตามสำหรับแอปพลิเคชัน IoT ที่กล่าวข้างต้นนั้น ต้องการการวิเคราะห์ที่รวดเร็วในระดับปฏิบัติการหลายรูปแบบ (Platform) ขนาดเล็ก หรือแม้กระทั่งบนอุปกรณ์ IoT ด้วยกันเอง ตัวอย่างเช่นรถยนต์ที่เป็นอิสระจำเป็นต้องตัดสินใจอย่างรวดเร็วเกี่ยวกับการขับขี่ เช่น การเปลี่ยนเลนหรือความเร็ว ซึ่งแท้จริงการตัดสินใจประเภทนี้ควรได้รับการสนับสนุนโดยการวิเคราะห์ที่รวดเร็วของการสตรีมข้อมูลแบบหลายรูปแบบจากหลายแหล่งรวมถึงเซ็นเซอร์ของยานพาหนะหลายตัว เช่น กล้องเรดาร์ LIDAR มาตราวัดความเร็วสัญญาณซาย ฯลฯ การสื่อสารจากยานพาหนะอื่น ๆ และหน่วยงานจราจร เช่น สัญญาณไฟจราจรสัญญาณจราจร ในกรณีนี้การถ่ายโอนข้อมูลไปยังเซิร์ฟเวอร์ระบบคลาวด์เพื่อการวิเคราะห์และส่งคืนการตอบกลับขึ้นอยู่กับเวลาที่อาจทำให้เกิดการละเมิดกฎจราจรหรืออุบัติเหตุ สถานการณ์ที่สำคัญ ยิ่งกว่านั้นคือ การตรวจจับคนเดินถนนโดยยานพาหนะ การจดจำที่แม่นยำควรดำเนินการแบบเรียลไทม์เพื่อป้องกันอุบัติเหตุที่ร้ายแรง สถานการณ์เหล่านี้บ่งบอกเป็นนัยว่าการวิเคราะห์ข้อมูลอย่างรวดเร็วสำหรับ IoT ต้องอยู่ใกล้หรืออยู่ที่แหล่งข้อมูลเพื่อลดความล่าช้าในการสื่อสารที่ไม่จำเป็น

การประยุกต์ใช้อินเทอร์เน็ตทุกสรรพสิ่ง ในการจัดการปลูกพืชโดยใช้เทคนิคควาโปนิคส์ (Aquaponics) หรือการปลูกพืชโดยควบคู่กับการเลี้ยงปลา โดยผ่านคอมพิวเตอร์ โทรศัพท์มือถือหรือสมาร์ตโฟน มีการเชื่อมต่อกับอินเทอร์เน็ตซึ่งสามารถเชื่อมต่อได้ทั้งแบบ Lan และ Wifi เพื่อเพิ่มความสะดวกในการใช้งานและการเข้าถึงอุปกรณ์ต่าง ๆ ที่จำเป็นต้องสั่งการต่อไป ในการเชื่อมต่อนั้นจะผ่านระบบ IoT Cloud : Cayenne IoT Ready™ [29] ซึ่งเป็น Server ที่ให้บริการจัดเก็บข้อมูลรวมถึงการดูแลและสั่งการต่าง ๆ ภายในระบบ ทั้งนี้ในการทำงานส่วนใหญ่จะมีศูนย์กลางหลักคือ

Raspberry pi เป็นบอร์ดคอมพิวเตอร์ขนาดเล็กที่สามารถเชื่อมต่อกับจอมอนิเตอร์ คีย์บอร์ด และเมาส์ได้ สามารถนำมาประยุกต์ใช้ในการทำโครงการด้านอิเล็กทรอนิกส์ การเขียนโปรแกรม หรือเป็นเครื่องคอมพิวเตอร์ตั้งโต๊ะขนาดเล็กไม่ว่าจะเป็นการทำงาน Spreadsheet word Processing ท่องอินเทอร์เน็ต ส่งอีเมลล์ หรือเล่นเกมสักก็ทั้งยังสามารถเล่นไฟล์วีดีโอความละเอียดสูง (High-Definition) ได้อีกด้วย บอร์ด Raspberry pi รองรับระบบปฏิบัติการลินุกซ์ (Linux operating system) ได้หลายระบบ เช่น Raspbian (Debian) Pidora (Fedora) และ Arch linux เป็นต้น โดยติดตั้งบน SD Card บอร์ด Raspberry pi ถูกออกแบบมาให้มี CPU GPU และ RAM อยู่ภายในชิปเดียวกัน สามารถเขียนโปรแกรมเพื่อสั่งงานให้อุปกรณ์อิเล็กทรอนิกส์ทำงานได้ เช่น สั่งงานให้ Relay ทำงานตามเวลาที่กำหนด หรือสั่ง ปิด - เปิด ปั้มน้ำ ตามเวลาที่ต้องการ เป็นต้น

ทั้งนี้ระบบ IoT Could : Cayenne lot readyTM สามารถสร้างเงื่อนไขให้การทำงานได้พร้อมกับการแจ้งเตือนผ่านระบบ SMS และ e-mail เช่น การตั้งเวลาควบคุมการทำงาน โดยกำหนดให้เวลา 06.00 น. สั่งการให้ปั้มน้ำทำงานเพื่อรดน้ำแปลงผัก เมื่อถึงเวลา 06.20 น. สั่งการให้ปั้มน้ำหยุดทำงาน และกำหนดให้ส่งข้อความแจ้งเตือนว่าปิดปั้มน้ำเรียบร้อยแล้วผ่านทาง SMS และ e-mail เป็นต้น นอกจากนี้ IoT Could : Cayenne lot readyTM สามารถเก็บค่าการทำงานต่างๆ ของอุปกรณ์ และนำมาทำเป็นกราฟเพื่อสังเกตการเปลี่ยนแปลงได้ หรือเป็นการดูความผิดปกติในการทำงาน เช่น การสังเกตความชื้นของดิน ถ้าหากความชื้นต่ำ สามารถสร้างเงื่อนไขการทำงานได้ โดยการสั่งการให้ปั้มน้ำทำงาน เมื่อดินมีความชื้นต่ำ ตามระดับที่กำหนดไว้ เป็นต้น

ในการทำงานของระบบ Aquaponics มีการใช้อุปกรณ์อิเล็กทรอนิกส์อยู่หลายจุด ซึ่งสามารถนำ IoT Could : Cayenne lot readyTM + Raspberry pi มาควบคุมการทำงาน เช่น การควบคุมการทำงานของปั้มน้ำ การให้อาหารปลา เป็นต้น สามารถสรุปกระบวนการทำงานได้ดังภาพที่ 2.14



ภาพที่ 2.14 กระบวนการทำงานของการประยุกต์ใช้อินเทอร์เน็ตทุกสรรพสิ่ง

## 2. แนวคิดการประยุกต์ใช้งานอินเทอร์เน็ตทุกสรรพสิ่ง

ปัจจุบันนี้ได้มีการนำเทคโนโลยีอินเทอร์เน็ตทุกสรรพสิ่ง (IoT) เข้ามาทำงานร่วมกับการเรียนรู้ด้วยคอมพิวเตอร์เพิ่มมากขึ้นเห็นได้จากงานของ Supriya Ghavate และ Joshi H.U [17] ที่ได้พัฒนาเทคโนโลยีอินเทอร์เน็ตทุกสรรพสิ่งและการเกษตรอัจฉริยะโดยใช้ระบบอัตโนมัติในการตรวจจับอุณหภูมิ ความชื้น ความชื้นในดิน และระดับน้ำในถังเก็บน้ำที่ใช้สำหรับรดน้ำภายในฟาร์ม รวมทั้งการใช้ภาพถ่ายโรคพืชเพื่อนำมาใช้ในการวิเคราะห์หาโรคพืชให้กับเกษตรกรสามารถนำไปใช้เป็นแนวทางในการแก้ไขต่อไป นอกจากนี้ยังมีงานที่นำเทคนิคการเรียนรู้เชิงลึกเข้ามาใช้งานร่วมกันการทำงานของเทคโนโลยี IoT ซึ่งเป็นงานของ Xue-Bo Jin และคณะ [30] โดยใช้ข้อมูลสภาพอากาศที่รวบรวมจากระบบอินเทอร์เน็ตทุกสรรพสิ่ง ทางเกษตรกรที่สามารถรับการเปลี่ยนแปลงของสภาพอากาศล่วงหน้าได้ ซึ่งเป็นวิธีที่มีประสิทธิภาพในการวางแผนและควบคุมการผลิตทางการเกษตรอย่างยั่งยืน อย่างไรก็ตามไม่ใช่เรื่องง่ายที่จะทำนายแนวโน้มในอนาคตได้อย่างแม่นยำ เนื่องจากข้อมูลมักมีความสัมพันธ์แบบไม่เป็นเชิงเส้นที่ความซับซ้อนกับหลายองค์ประกอบ เพื่อเพิ่มประสิทธิภาพการคาดการณ์ของข้อมูลสภาพอากาศในระบบ IoT เพื่อการเกษตรที่มีความแม่นยำ การศึกษานี้ใช้ตัวทำนายการเรียนรู้เชิงลึกที่มีโครงสร้างการสลายตัวสองระดับตามลำดับ ซึ่งข้อมูลสภาพอากาศจะถูกย่อยสลายออกเป็นสี่ส่วนตามลำดับจากนั้นหน่วยการเกิดซ้ำที่มีรั้วรอบขอบชิด (Gated recurrent unit : GRU ) เครื่องข่ายที่ได้รับการฝึกฝนให้เป็นตัวทำนายย่อยสำหรับแต่ละองค์ประกอบ สุดท้ายผลลัพธ์จาก GRUs ถูกรวมเข้าด้วยกันเพื่อให้ได้ผลการทำนายระยะกลางและระยะยาว การทดลองได้รับการตรวจสอบสำหรับแบบจำลองที่นำเสนอโดยอาศัยข้อมูลสภาพอากาศจากระบบ IoT ใน Ningxia ประเทศจีน สำหรับการปลูก Wolfberry ซึ่งผลการทำนายพบว่าตัวทำนายที่เสนอสามารถทำนายอุณหภูมิและความชื้นได้อย่างแม่นยำและตรงตามความต้องการของความแม่นยำการผลิตทางการเกษตร

กระบวนการในการนำนวัตกรรมมาใช้โดยเฉพาะอย่างยิ่งเกี่ยวกับการทำฟาร์มอัจฉริยะให้มีความแม่นยำ จะต้องมีการทดลองพัฒนาให้มีความสามารถที่จะให้เกษตรกรมีความยั่งยืนและเพิ่มผลผลิตเพิ่มมากขึ้น Vecchio, Y และคณะ [31] ทำการวิเคราะห์เชิงประจักษ์เกี่ยวกับผลลัพธ์เบื้องต้นของเกษตรกรชาวอิตาลีและพบว่าการเพิ่มความสำคัญในการใช้เครื่องมือเกษตรให้มีความแม่นยำนั้นมีความหมายมากและการวิจัยในอนาคตควรมุ่งเน้นไปที่นวัตกรรมและแนวทางแก้ไขที่นำเสนอความยั่งยืนด้านสิ่งแวดล้อม ในกระบวนการนี้การประยุกต์ใช้ระบบ IoT เป็นสิ่งที่สำคัญมาก ที่จะช่วยลดปริมาณข้อมูลที่เกษตรกรต้องการในฐานะผู้ที่มีอำนาจตัดสินใจและทำให้ระดับการเกษตรโดยรวมดีขึ้น นอกจากนี้สภาพอากาศที่รุนแรงยังส่งผลกระทบต่อการพัฒนาการเกษตร การวางแผนล่วงหน้าสามารถลดความสูญเสียได้อย่างมีประสิทธิภาพโดยการพยากรณ์อากาศในระยะกลางและระยะยาว ในขณะที่เดียวกันก็มีแนวทางสำคัญสำหรับการจัดการฟาร์มและการประกันภัยทางการเกษตร [32, 33]

เทคโนโลยีอินเทอร์เน็ตทุกสรรพสิ่ง (IoT) ช่วยให้เซ็นเซอร์สามารถรวบรวมข้อมูลและจัดหาเทคโนโลยีที่สำคัญสำหรับระบบอัจฉริยะที่หลากหลาย ระบบเกษตรกรรมแม่นยำเป็นระบบ IoT ที่สำคัญที่สุดระบบหนึ่งในช่วงไม่กี่ปีที่ผ่านมาโดยสามารถผลิตผลที่สูงขึ้นความสามารถในการทำกำไรที่ยั่งยืนและผลิตภัณฑ์ที่มีคุณภาพสูงขึ้นโดยอาศัยเทคโนโลยีสารสนเทศ [18, 34, 35] ซึ่งการเกษตรแบบแม่นยำนี้มีศักยภาพสูงและสามารถมีส่วนสนับสนุนอย่างมากต่อการผลิตอาหาร ความปลอดภัย

และความมั่นคง [36] ทิศทางการวิจัยที่สำคัญของระบบ IoT ในปัจจุบันนี้ให้ความสำคัญสำหรับการเกษตรแม่นยำเพิ่มขึ้นกล่าวคือการจัดเตรียมสภาพแวดล้อมเฉพาะสำหรับผลผลิตเพื่อตอบสนองต่อการเปลี่ยนแปลงของสภาพอากาศ เช่น อุณหภูมิและความชื้นเป็นต้น เพื่อเพิ่มประสิทธิภาพการใช้ทรัพยากรรวมทั้งพลังงานพื้นที่และแรงงานและเพื่อให้บรรลุผลสำเร็จ และทำให้การผลิตที่มีประสิทธิภาพมากขึ้น


การคาดการณ์สภาพอากาศในอนาคตในระยะกลางและระยะยาวที่แม่นยำสามารถช่วยเกษตรกรผู้จัดจำหน่ายและผู้กำหนดนโยบายในการตัดสินใจเพื่อการผลิตทางการเกษตรที่ยั่งยืนซึ่งส่งเสริมกิจกรรมที่เพิ่มประโยชน์ในการใช้ประโยชน์และการพัฒนาทรัพยากรอาหารสำหรับแต่ละบุคคลสังคม และวัตถุประสงค์ทางเศรษฐกิจ วิธีการวิเคราะห์และการสร้างแบบจำลองของสภาพอากาศในอนาคตสามารถช่วยในการคาดการณ์การจัดการการเกษตรในอนาคตที่เป็นไปได้ซึ่งจะช่วยและขึ้นำการจัดการการผลิตไปสู่การพัฒนาเกษตรกรรมอย่างยั่งยืน ซึ่งการคาดการณ์โดยอาศัยข้อมูลสภาพอากาศเป็นปัญหาที่ยากเนื่องจากข้อมูลที่รวบรวมจากเซ็นเซอร์มักจะมีความสัมพันธ์แบบไม่เป็นเชิงเส้นที่ซับซ้อนกับส่วนประกอบหลายส่วน ในทางกลับกันด้วยความถี่ในการสุ่มตัวอย่างที่สูง ข้อมูลขนาดใหญ่ จึงถูกรวบรวมและจัดเก็บไว้ในระบบ IoT ซึ่งทำให้สามารถวิเคราะห์ข้อมูลทางประสาทสัมผัสค้นพบข้อมูลใหม่และทำนายข้อมูลเชิงลึกในอนาคตได้ [23, 37]

ภาพรวมของ Internet of Things (IoT) และการวิเคราะห์ข้อมูลในการเกษตรประโยชน์และความท้าทายภาพรวมของ IoT และการวิเคราะห์ข้อมูลในการเกษตรได้ถูกนำเสนอในบทความนี้ มีการพูดถึงหลายประเด็นที่เกี่ยวข้องกับการปรับใช้ IoT ในการเกษตรโดยละเอียด การสำรวจวรรณกรรมแสดงให้เห็นว่ามีงานมากมายที่กำลังดำเนินการอยู่ในการพัฒนาเทคโนโลยี IoT ที่สามารถนำมาใช้เพื่อเพิ่มประสิทธิภาพการดำเนินงานและผลผลิตของพืชและปศุสัตว์ ประโยชน์ของ IoT และการวิเคราะห์ข้อมูลและความท้าทายแบบเปิดได้ถูกระบุและกล่าวถึงในเอกสารนี้ คาดว่า IoT จะให้ประโยชน์หลายประการแก่ภาคการเกษตร อย่างไรก็ตามยังมีปัญหาอีกหลายประการที่ต้องได้รับการแก้ไขเพื่อให้ราคาไม่แพงสำหรับเกษตรกรรายย่อยและขนาดกลาง ประเด็นสำคัญคือความปลอดภัยและค่าใช้จ่าย คาดว่าเมื่อการแข่งขันเพิ่มขึ้นในภาคการเกษตรและนโยบายที่เอื้ออำนวยกำลังถูกนำไปใช้อัตราการนำ IoT มาใช้ในการเกษตรจะเพิ่มขึ้นตามลำดับ ประเด็นสำคัญประการหนึ่งที่น่าจะดึงดูดความสนใจในการวิจัยคือการใช้เทคโนโลยีการสื่อสารในบริเวณกว้างที่ใช้พลังงานต่ำเพื่อวัตถุประสงค์ทางการเกษตร NB-IoT คาดว่าจะโดดเด่นท่ามกลางเทคโนโลยี LPWA นี้เป็นเพราะมาตรฐานเปิด 3GPP และการยอมรับโดย บริษัท โทรคมนาคม ระบบเกษตรอัจฉริยะที่ใช้ IoT สามารถพิสูจน์ได้ว่ามีประโยชน์มากสำหรับเกษตรกรเนื่องจากการชลประทานน้อยลงก็ไม่ดีต่อการเกษตร ค่าเกณฑ์สำหรับสภาพอากาศเช่นความชื้นอุณหภูมิความชื้นสามารถแก้ไขได้ตามสภาพแวดล้อมของภูมิภาคนั้น ๆ ระบบยังตรวจจับการบุกรุกของสัตว์ซึ่งเป็นสาเหตุหลักที่ทำให้พืชผลลดลง ระบบนี้สร้างตารางการชลประทานตามข้อมูลเรียลไทม์ที่ตรวจจับได้จากสนามและข้อมูลจากที่เก็บสภาพอากาศ ระบบนี้สามารถแนะนำเกษตรกรได้หรือไม่ว่ามีความจำเป็นในการชลประทานหรือไม่ การเชื่อมต่ออินเทอร์เน็ตอย่างต่อเนื่อง สิ่งนี้สามารถเอาชนะได้โดยการขยายระบบไปที่ ส่งข้อเสนอแนะทาง SMS ถึงเกษตรกรโดยตรงบนมือถือของเขาใช้โมดูล GSM แทนแอปพลิเคชันบนมือถือ

## 2.5 การสร้างฟาร์มอัจฉริยะ

การสร้างระบบฟาร์มอัจฉริยะหรือโรงเรือนอัจฉริยะนั้น [38, 39] เป็นวิธีการในการนำเทคโนโลยีอินเทอร์เน็ตทุกสรรพสิ่งทำงานร่วมกับตัวควบคุมการทำงานภายในโรงเรือนเพาะเห็ด เช่น ตัวควบคุมความชื้น อุณหภูมิ แสง การพ่นหมอก เป็นต้น ซึ่งอุปกรณ์ควบคุมเหล่านี้จะสามารถควบคุมให้สภาพแวดล้อมภายในโรงเรือนให้มีความเหมาะสมและสามารถให้ผลผลิตที่เพิ่มมากขึ้น และมีความแม่นยำในการควบคุมภายในโรงเรือน กล่าวคือ การทำเกษตรให้เข้ากับสภาพพื้นที่ เน้นประสิทธิภาพในการเพาะปลูก ตั้งแต่การวางระบบการออกแบบโรงเรือนจนถึงกระบวนการปลูกที่นำเอาเทคโนโลยีเข้ามาช่วยในการตรวจวัดเรื่องของสภาพดิน ความชื้นภายในโรงเรือน แสง อุณหภูมิภายในโรงเรือน เป็นต้น และสามารถควบคุมปัจจัยต่าง ๆ ได้อย่างเข้มงวดและมีประสิทธิภาพมากขึ้น [40]


องค์ประกอบที่สำคัญในการทำฟาร์มอัจฉริยะประกอบด้วย 3 ด้าน คือ 1) ด้านการระบุตำแหน่งพื้นที่เพาะปลูกที่เหมาะสม โดยอาศัยระบบสารสนเทศทางภูมิศาสตร์ 2) การแปรผลและการวิเคราะห์ข้อมูลที่ได้จากเซ็นเซอร์อย่างเหมาะสม เพื่อให้สอดคล้องกับระยะเวลาของการเพาะปลูก ซึ่งแปรผันไปตามสภาพอากาศ 3) การบริหารจัดการพื้นที่โดยใช้เทคโนโลยีที่เหมาะสม เพื่อลดการใช้ทรัพยากร และตอบสนองความต้องการเข้ากับการเพาะปลูกพืช ทั้งนี้ในการทำฟาร์มอัจฉริยะนั้นเป็นเรื่องของความแม่นยำสูง ดังนั้นเพื่อนำไปสู่การเพาะปลูกพื้นที่เข้ากับพื้นที่บริเวณนั้น ผ่านการตัดสินใจบนข้อมูลที่ถูกต้อง เช่น การควบคุมการให้น้ำที่แม่นยำ เพื่อให้ถูกต้องทั้งปริมาณ ระยะเวลา โดยการควบคุมผ่านอุปกรณ์สมัยใหม่ เช่น สมาร์ทโฟน และคอมพิวเตอร์ การนำอุปกรณ์เซ็นเซอร์มาช่วยในกระบวนการติดตามและขั้นตอนการควบคุม โดยการวัดอุณหภูมิ ความชื้นอากาศและความชื้นในดิน เพื่อช่วยในกระบวนการปล่อยน้ำจากหัวพ่นหมอกเพื่อปรับระดับอุณหภูมิภายในฟาร์มหรือโรงเรือน และควบคุมการให้น้ำสำหรับพืช และการนำอุปกรณ์เซ็นเซอร์ EC มาช่วยในการวัดค่าของปุ๋ยในน้ำ สำหรับการปลูกพืชแบบไฮโดรโปนิคส์ เพื่อการให้ปุ๋ยที่แม่นยำโดยผ่านระบบการให้น้ำของพืช เช่น การปลูกสลัด

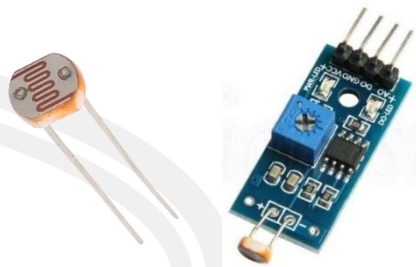



ภาพที่ 2.15 ระบบการทำงานฟาร์มอัจฉริยะ (Smart farming)

หลักการการทำงานของสมาร์ทฟาร์มจะรวบรวมข้อมูล Micro-climate เป็นเทคโนโลยีที่สามารถนำมาใช้ในการควบคุมและจัดการการเปิด ปิดระบบรน้ำสำหรับพืชได้ ซึ่งเป็นเซ็นเซอร์ตรวจสอบสภาพอากาศ ได้แก่ ข้อมูลอุณหภูมิในดินและในอากาศ ความชื้นในดินและในอากาศ ความเข้มแสง ความเร็วลม ความดันอากาศได้ และรวบรวมข้อมูล Meso-climate เป็นการบริหารจัดการ ดูแลพื้นที่เพาะปลูกเพื่อให้สอดคล้องกับสภาพอากาศที่เกิดขึ้น รวมถึงการเตรียมความพร้อมรับมือกับสภาพอากาศที่จะเปลี่ยนแปลงไปในอนาคต ซึ่งจากข้อมูลเหล่านี้จะเป็นการทำงานผ่านเครือข่ายเซ็นเซอร์ไร้สาย (Wireless Sensor Networks) ที่ติดตั้งตามจุดต่าง ๆ ภายในฟาร์มหรือโรงเรือน โดยการจัดเก็บข้อมูลจากเซ็นเซอร์ดังตารางที่ 2.4


ตารางที่ 2.4 เซ็นเซอร์ที่ใช้ในการทำงานในระบบฟาร์มอัจฉริยะ

ลำดับ	รายละเอียด	เซ็นเซอร์
1	เซ็นเซอร์วัดอุณหภูมิ ความชื้นในดินและอากาศ (Temperature sensor) คือ หัววัดอุณหภูมิทำหน้าที่เปลี่ยนอุณหภูมิที่ได้รับเป็นสัญญาณทางไฟฟ้า และส่งสัญญาณทางไฟฟ้าให้อยู่ในรูปแบบของแรงดันไฟฟ้า (Voltage) หรือ ความต้านทาน (Resistance)	 DHT22                      SHT10
2	เซ็นเซอร์วัดความชื้นในดิน (Humidity Sensor) คือ อุปกรณ์วัดค่าความชื้นสัมพัทธ์ (Relative Humidity หรือ RH) ซึ่งหมายถึงปริมาณไอน้ำที่มีอยู่จริงในอากาศต่อปริมาณไอน้ำที่จะทำให้อากาศอิ่มตัว ณ อุณหภูมิเดียวกันหรือความอิ่มไอน้ำที่มีอยู่จริงต่อความดันไอน้ำอิ่มตัว ซึ่งแสดงในรูปของร้อยละ (%) มีหน่วยเป็น %RH	 DHT11                      Soil Humidity

ลำดับ	รายละเอียด	เซ็นเซอร์
3	เซ็นเซอร์แสง (Optical Sensor) คือ อุปกรณ์อิเล็กทรอนิกส์ที่เปลี่ยนแปลงค่าความต้านทาน หรือการนำไฟฟ้า ที่ไหลผ่านเซ็นเซอร์ เมื่อมีแสงกระทบ	 <p>LDR light</p>
4	เซ็นเซอร์วัดค่าความหนาแน่นของก๊าซคาร์บอนไดออกไซด์ (Carbon monoxide alarm) เป็นเซ็นเซอร์วัดความหนาแน่นของก๊าซคาร์บอนไดออกไซด์ MQ-9 (หรือ H) ในอากาศ ส่งค่ากลับมาเป็น Analog และ Digital สามารถปรับความไวได้ ตรวจจับได้ระดับความเข้มข้นของก๊าซในช่วง 100 - 10,000 ppm	 <p>MQ-9</p>

จากตารางที่ 2.4 เป็นเซ็นเซอร์ที่จะนำมาใช้ในการสร้างระบบฟาร์มอัจฉริยะ โดยเซ็นเซอร์ที่กล่าวมานี้จะทำหน้าที่รวบรวมข้อมูลที่ได้จากการวัด เพื่อนำไปใช้ในการวิเคราะห์ข้อมูลต่อไป

ตารางที่ 2.5 ตัวควบคุมการทำงานที่สั่งการผ่านเซ็นเซอร์

ลำดับ	รายละเอียด	ตัวควบคุม
1	ตัวควบคุมแสงสว่าง เพื่อเพิ่มความสว่างให้กับพื้นที่ภายในฟาร์มหรือโรงเรือน	 <p>LED</p>



ลำดับ	รายละเอียด	ตัวควบคุม
2	พัดลมระบายอากาศ เพื่อทำให้อากาศภายในฟาร์มหรือโรงเรือนอากาศสามารถถ่ายเทได้สะดวก หรือระบายอากาศภายในโรงเรือน	Fan 
3	ปั้มน้ำสำหรับดูดน้ำเพื่อนำไปใช้ในการพ่นหมอกภายในฟาร์มหรือโรงเรือน	 Pump
4	หัวพ่นหมอก ใช้สำหรับเพิ่มความชื้นและอุณหภูมิให้ภายในฟาร์มหรือโรงเรือน มีอุณหภูมิลดลง หรือให้มีความชื้นเพิ่มขึ้น	 Fog

## 2.6 การประมวลผลภาพ

การประมวลผลด้วยภาพ (Image processing) [41] เป็นวิธีการในการนำภาพถ่ายแบบดิจิทัลมาใช้ในการวิเคราะห์ถึงความแตกต่างหรือองค์ประกอบต่าง ๆ ที่มีในภาพ ปรับปรุงข้อมูลรูปภาพเพื่อนำไปใช้ในการวิเคราะห์ เช่น ปรับภาพเบลอให้คมชัด ปรับภาพที่มีแสงรบกวนมากเกินไป และการกำจัดสัญญาณรบกวนออกจากภาพ เป็นต้น การประมวลผลภาพเป็นงานที่ได้รับความนิยมเป็นอย่างมากในปัจจุบัน เนื่องจากเป็นวิธีการดำเนินการบางอย่างกับรูปภาพ เพื่อให้ได้ภาพที่ปรับปรุงแล้ว หรือเพื่อดึงข้อมูลที่เป็นประโยชน์บางอย่างออกมา เป็นประเภทของการประมวลผลสัญญาณที่อินพุตเป็นภาพและเอาต์พุตอาจเป็นภาพหรือคุณลักษณะเด่น/คุณลักษณะเฉพาะที่เกี่ยวข้องกับภาพนั้น ปัจจุบันการประมวลผลภาพเป็นหนึ่งในเทคโนโลยีที่เติบโตอย่างรวดเร็ว การประมวลผลภาพโดยทั่วไปประกอบด้วยสามขั้นตอนต่อไปนี้

1. การนำเข้ารูปภาพผ่านเครื่องมือรับรูปภาพ
2. การวิเคราะห์และจัดการภาพ
3. เอาต์พุตซึ่งผลลัพธ์สามารถเปลี่ยนแปลงรูปภาพหรือรายงานที่ขึ้นอยู่กับการวิเคราะห์รูปภาพ

การประมวลผลภาพนั้นมี 2 ประเภท ได้แก่ การประมวลผลภาพอนาล็อกและภาพดิจิทัล ซึ่งโดยส่วนมากภาพที่นำมาใช้ในการประมวลผลภาพจะเป็นภาพดิจิทัล การประมวลผลภาพที่ได้รับการพิสูจน์แล้วว่าเป็นเครื่องมือที่มีประสิทธิภาพ [42] ซึ่งการนำเทคนิคการประมวลผลด้วยภาพนั้นได้มีการนำไปใช้งานในหลาย ๆ ด้าน เช่น ด้านการแพทย์ ด้านอุตสาหกรรม ด้านธุรกิจ และด้านเกษตร ซึ่ง

ในด้านเกษตรนั้นจะนำไปใช้ในการตรวจหาโรคของพืช เป็นกระบวนการในการตรวจจับอาการหรือการแสดงออกของพืช โดยการถ่ายภาพทั้งนี้ยังสามารถนำมาใช้ในการตัดสินใจในการดูแลและบำรุงรักษาต่อไป ทั้งนี้ได้มีงานวิจัยจำนวนมากเกี่ยวกับการใช้การประมวลผลภาพสำหรับการตรวจสอบโรคใบพืชในการใช้งานด้านการเกษตร การรับรู้ด้วยสายตาของโรคบนใบไม้ที่มีความแม่นยำน้อยกว่าและต้องการความรู้ที่มากขึ้น ซึ่งการตรวจสอบโรคพืชอัตโนมัติให้ประโยชน์ในพื้นที่เกษตรกรรม ดังนั้นจึงเป็นหัวข้อการวิจัยที่สำคัญหลายงานดังนี้

Sanjeev และคณะ[43] ได้เสนอวิธีการตรวจสอบและการจำแนกประเภทของโรคใบอ่อน โดยใช้โครงข่ายประสาทเทียม (Neural networks) โดยใช้ใบอ่อนที่เป็นโรคในการวิเคราะห์ มีการปรับใช้ Thresholding เพื่อปิดบังพิกเซลสีเขียว ใช้ Anisotropic diffusion เพื่อกำจัดสิ่งรบกวนภาพ จากนั้นใช้วิธี K-means ในการแบ่งกลุ่มโรคใบอ่อน จากนั้นใช้ Neural networks ในการจำแนกประเภทโรค

Pranjali และคณะ[44] ได้เสนอวิธีการตรวจจับและจำแนกโรคใบของอ่อนโดยใช้เทคนิคการจำแนกประเภท SVM (SVM classification technique) และใช้การแบ่งส่วนโดย K-means ในการจัดกลุ่มสี (Color) และคุณสมบัติพื้นผิว (Texture) จากนั้นใช้เทคนิคการจำแนกประเภทเพื่อตรวจหาชนิดของโรคใบ


Zarreen และคณะ [45] ได้เสนอการตรวจจับโรคพืชปอกกระเจาโดยใช้การประมวลผลภาพและการเรียนรู้ของเครื่อง โดยทำการตรวจสอบโรคที่เป็นต้นกำเนิดของพืชปอกกระเจาให้เป็นระบบอัตโนมัติที่สามารถใช้แอปพลิเคชัน (Application) Android ถูกพัฒนาให้สามารถนำมาใช้ในการถ่ายภาพโรคต้นปอกกระเจาและส่งภาพถ่ายไปยังฝั่งเซิร์ฟเวอร์เพื่อตรวจสอบผลกระทบบจากภาพ ซึ่งจะถูกแบ่งส่วนโดยใช้สูตรที่กำหนดค่าใหม่ตามการแบ่งส่วนที่ใช้สี ค่าคุณสมบัติที่จะถูกแยกออกจากส่วนที่แบ่งเป็นส่วนสำหรับการวิเคราะห์พื้นผิวโดยผู้วิธีการเกิดสี ค่าที่สกัด ถูกนำไปเปรียบเทียบกับค่าตัวอย่างที่เก็บไว้ในฐานข้อมูลที่กำหนดไว้ล่วงหน้า ซึ่งจะนำไปสู่การระบุและจำแนกโรคโดยใช้ตัวจำแนก Multi-SVM ซึ่งในขั้นตอนสุดท้ายผลลัพธ์การจำแนกประเภทพร้อมกบมาตรการควบคุมที่จำเป็นถูกส่งกลับมายังผู้ใช้หรือเกษตรกรภายใน 3 นาทีผ่านแอปพลิเคชันบนมือถือโทรศัพท์มือถือ

Pallavi และคณะ [46] ได้เสนอการประมวลผลภาพดิจิทัลสำหรับการตรวจหาโรคพืชและใช้ระบบ GSM เพื่อส่งข้อความไปยังโทรศัพท์มือถือทุกประเภท ซึ่งการสกัดคุณลักษณะ (Feature extraction) พิจารณาจากสี พื้นผิว (Texture) และโครงสร้างของวัตถุในภาพ (Morphology) สำหรับการตรวจสอบการเกิดโรค สำหรับการจำแนกโรคพืชนั้นใช้เทคนิค SVM (Support vector machine)

Gowthami และคณะ [47] ได้เสนอวิธีการตรวจหาโรคพืชต่าง ๆ โดยใช้การประมวลผลภาพดิจิทัล โดยใช้กระบวนการประมวลผลภาพในการเตรียมภาพ การแบ่งส่วนภาพใช้วิธี HIS สำหรับการแบ่งส่วนภาพ และใช้เทคนิค K-means สำหรับการจำแนกคุณสมบัติของสี และลักษณะพื้นผิวโรคพืชชนิดต่าง ๆ จากนั้นทำการจัดกลุ่มโดยใช้ ANN ในการจัดกลุ่มของโรคพืชชนิดต่าง ๆ

Velamakanni และคณะ [48] ได้เสนอวิธีการในการคัดเลือกใบพืชเพื่อตรวจหาโรครยะต่าง ๆ เช่น โรคใบเหลือง โรคใบดำ โรคใบจุด และโรคราแป้ง เป็นต้น โดยนำภาพใบไม้ที่ได้ผ่านกระบวนการประมวลผลภาพ การเตรียมภาพ การแบ่งส่วนคุณสมบัติ การจำแนกคุณสมบัติ และการจัดประเภทใบพืชที่มีสุขภาพดีหรือสุขภาพไม่ดี โดยการจัดกลุ่มนั้นจะได้วิธี K-means สำหรับการแบ่งส่วนและใช้สำหรับการจัดหมวดหมู่จะได้ SVM และ ANN (Artificial neural networks) และใช้ PCA (Principal component analysis) เพื่อลดชุดคุณสมบัติ (Feature set)

Kumari และคณะ [49] ได้เสนอวิธีการระบุจุดถ่ายภาพโดยใช้เทคนิคการประมวลผลภาพซึ่งในงานวิจัยนี้ได้ทำการตรวจสอบโรคตามกระบวนการประมวลผลภาพพื้นฐาน คือ การได้มาของภาพ การแบ่งส่วนภาพ การสกัดคุณลักษณะและการจำแนกสำหรับการแบ่งส่วนภาพ ซึ่งใช้วิธีการ K-means สำหรับการจัดกลุ่มและคุณสมบัติที่คำนวณได้จากกลุ่มที่ได้รับผลกระทบจากโรค เช่น Contrast, Correlation, Energy, Homogeneity, Mean Standard Deviation และ Variance are extracted ซึ่งการสกัดคุณสมบัติจากกลุ่มโรคพืชนั้น ใช้เทคนิคโครงข่ายประสาทเทียม (Neural network) โดยสามารถแยกโรคพืชใบจุดของใบฝ้าย โรคใบจุดของมะเขือเทศ โรคใบจุดเชพโตเรีย และราใบจากงานวิจัยทั้งหมดนี้ ทำให้เห็นว่าได้มีการนำเทคนิคการประมวลผลภาพเข้ามาใช้ในการวิเคราะห์เพื่อหาโรคพืชชนิดต่าง ๆ เนื่องจากพืชนั้นมีความสำคัญต่อเกษตรกรและการเพาะปลูกเป็นอย่างมาก จึงได้มีงานวิจัยหลาย ๆ งานที่จะสร้างความสามารถและวิธีการที่จะช่วยให้เกษตรกรสร้างรายได้และเพิ่มผลผลิต โดยใช้วิธีการขั้นตอนทั่วไปในการประมวลผลภาพเพื่อที่จะนำมาใช้ในการระบุโรคพืช เริ่มต้นด้วยขั้นตอนการรับภาพ (Image acquisition) ซึ่งใช้อุปกรณ์ดิจิทัลที่แตกต่างกันเพื่อจับภาพพืชที่แข็งแรงและติดเชื้อ จากนั้นจึงทำการวิเคราะห์เพิ่มเติม (Image processing) เพื่อแก้ไขภาพและเตรียมพร้อมสำหรับการรักษาโรคพืชภายหลัง เช่น การปรับปรุงภาพการแบ่งส่วนการเปลี่ยนพื้นที่สี โดยเฉพาะอย่างยิ่งวิธีการแบ่งส่วนภาพ เช่น การกำหนดค่าใหม่ที่ใช้ในการตรวจจับของเขตในภาพ [50] สามารถแสดงตัวอย่างขั้นตอนการทำงานดังภาพที่ 2.16



ภาพที่ 2.16 ขั้นตอนทั่วไปที่ใช้ในการระบุโรคพืช  
ที่มา : [50]

ในขั้นตอนการดึงข้อมูลคุณสมบัติ (Feature extraction) คือ การดึงคุณสมบัติของสี รูปร่าง และพื้นผิวที่จะนำมาใช้ในการคำนวณ ขั้นตอนสุดท้ายการจำแนก (Recognition and classification) จะเป็นขั้นตอนที่จะทำการนำอัลกอริทึมประเภทต่าง ๆ มาใช้ในการจำแนก เช่น โครงข่ายประสาทเทียม (Neural network) [43] support vector machine และ rule based

classification [51, 52] ซึ่งเป็นวิธีที่นิยมในการนำมาใช้ในงานการวิเคราะห์โรคพืชด้วยภาพ ซึ่งจะอธิบายรายละเอียดทั้งหมดในหัวข้อถัดไป


### 1. ทฤษฎีของสี

ทฤษฎีของสี [53] นั้นมีความสำคัญกับการประมวลผลภาพ เนื่องจากการประมวลผลภาพนั้นจำเป็นที่จะต้องมีการแทนค่าของสีที่ปรากฏในภาพ เพราะภาพหนึ่งภาพเกิดจากการผสมสีขึ้น และแสดงผลออกมาตามภาพที่ถ่าย อีกทั้งยังเป็นส่วนที่สำคัญในการนำภาพไปใช้งานเพื่อการวิเคราะห์ภาพ หากมีที่ได้มีสีผิดเพี้ยนหรือขาดหาย จะส่งผลให้การนำไปประมวลผลนั้นไม่มีความถูกต้องเกิดขึ้นได้ และโดยปกติแล้วสีนั้นจะมีได้หลายจำนวน จำนวนสูงสุดที่เป็นไปได้ของแต่ละจุดภาพขึ้นอยู่กับจำนวนบิตที่ใช้ เมื่อมีการกำหนดให้ขนาดของบิตต่อจุดมากขึ้น จะทำให้จำนวนของสีมากขึ้นด้วย เช่น 1 บิต =  $2^1 = 2$  สี ถ้า 2 บิต =  $2^2 = 4$  สี , 4 บิต , 8 บิต และ 16 บิต =  $2^{16} = 65536$  สี เป็นต้น สำหรับการแสดงข้อมูลภาพที่มีขนาด 1 บิต และ 8 บิต นั้นจะมีการทำงานได้ใกล้เคียงกันเนื่องจากหน่วยประมวลผลจะไม่สามารถจัดการกับข้อมูลที่เป็นบิตเดี่ยว ๆ ได้ ดังนั้นในการแสดงผลข้อมูลออกมาทางจอภาพ โปรเซสเซอร์ (Processor) จะทำการก๊อปปี้ (Copy) ข้อมูลทั้ง 8 บิต (1 Byte) ส่งให้กับจอภาพซึ่งในกรณีทีพิกเซล (Pixel) มีขนาด 1 บิต เมื่อโปรเซสเซอร์จะทำงานกับบิตแรกที่ต้องการแล้ว จะทำการก๊อปปี้ข้อมูลชุดใหม่ทันทีโดยไม่เกี่ยวข้องกับข้อมูลอีก 7 บิตที่เหลือ ส่วนในกรณีพิกเซลที่มีขนาด 8 บิต โปรเซสเซอร์จะทำการก๊อปปี้ข้อมูลชุดใหม่ก็ต่อเมื่อโปรเซสเซอร์ทำงานกับทุกบิตแล้ว เช่น สำหรับระบบที่มีความละเอียดเท่ากับ  $800 \times 600$  และมีขนาด 16 บิตต่อพิกเซล จะสามารถแสดงสีได้ทั้งหมด 65536 ระดับ และต้องใช้เนื้อที่ในการเก็บเท่ากับ  $800 \times 600 \times 16$  บิต

ทั้งนี้หากจะทำการคำนวณหาขนาดของสีในแต่ละภาพจะต้องเข้าใจในส่วนของมาตรฐานของสีที่ใช้อยู่ในปัจจุบันมีอยู่หลายระบบด้วยกัน ทั้งนี้ขึ้นอยู่กับนำไปใช้ แต่โดยทั่วไปทุกมาตรฐานจะมีแนวคิดเดียวกันคือ การแทนจุดสีด้วยจุดที่อยู่ภายในสเปส 3 มิติ โดยจะมีแกนอ้างอิงสำหรับสีจุดสีนั้นในสเปสซึ่งแต่ละแกนจะมีความเป็นอิสระต่อกัน เช่น ในระบบ RGB จะมีแกนสีคือ แกนสีแดง แกนสีเขียว และแกนสีน้ำเงิน ในระบบ HLS จะมีแกนเป็นค่าสี (Hue) ความสว่าง (Lightness) และความบริสุทธิ์ของสี (Saturation) ซึ่งมีรายละเอียดของระบบสีดังนี้

#### 1.1 ปริภูมิสี RGB และปริภูมิสี HSV (RGB Color space and HSV Color space)


ปริภูมิสี RGB เป็นปริภูมิสีที่ใช้กันแพร่หลายในระบบภาพดิจิทัลคอมพิวเตอร์ โดยแทนค่าสีของจุดภาพแต่ละจุดภาพด้วยเวกเตอร์สามมิติ ซึ่งแทนค่าสีปฐมภูมิได้แก่ สีแดง สีเขียวและสีน้ำเงิน โดยมีช่วงของค่าสีระหว่าง 0-255 ซึ่งปริภูมิสี RGB จะมีลักษณะเป็นรูปแบบลูกบาศก์ ดังภาพที่ 2.17



ภาพที่ 2.17 ปริภูมิสี RGB


ที่มา : <http://staff.cs.psu.ac.th/sathit/DigitalImage/Lab5.pdf>

ปริภูมิสี HSV ใช้หลักการแยกความสว่างออกจากเนื้อสีของจุดภาพ โดยปริภูมิสี HSV นั้นแทนค่าด้วยเวกเตอร์ 3 มิติ ซึ่งประกอบด้วย H แทนค่าเนื้อสี (Hue), S แทนค่าความอิ่มตัวของสี (Saturation) และ V แทนค่าความสว่างของแสง (Value) ซึ่งปริภูมิสี HSV จะมีลักษณะเป็นรูปกรวย



ภาพที่ 2.18 ปริภูมิสี HSV

ที่มา : [https://medium.com/@loved\\_pastel\\_alpaca\\_906/image-processing-445f856d62cc](https://medium.com/@loved_pastel_alpaca_906/image-processing-445f856d62cc)




ภาพที่ 2.19 ปริภูมิสี HSV แทนค่าด้วยเวกเตอร์ 3 มิติ

ที่มา : <https://ichi.pro/th/colorimetry-laea-kar-tha-phaenthi-khxng-si-71876096384010>

## 1.2 ปริภูมิสี HSL (HSL Color)

ปริภูมิสี HSL เป็นระบบสีที่มนุษย์เข้าใจได้ง่าย เพราะไม่ได้นิยามสีจากการผสมสี แต่เป็นการสร้างสีขึ้นจาก Hue (เนื้อสี), Saturation (ความอิ่ม) และ Lightness (ความสว่าง)


HSL Color Wheel



ภาพที่ 2.20 ระบบสี HSL

ที่มา : [https://medium.com/@kouyo\\_machi/hsl-a-better-way-to-define-the-color-3512d0610186](https://medium.com/@kouyo_machi/hsl-a-better-way-to-define-the-color-3512d0610186)

Hue คือ เนื้อสี มีค่าได้ 360 ค่า ตั้งแต่ 0 ถึง 359 ซึ่ง Hue ใช้การกำหนดค่าในแบบของ Color Wheel โดยแต่ละค่าของ Hue คือแต่ละ Degree บน Color Wheel กล่าวคือ ถ้ากำหนดค่า Hue เป็น 0, 360 หรือ 720 จะได้เนื้อสีเดียวกัน เพราะคือจุดเดียวกันบน Color Wheel



ภาพที่ 2.21 HSL Color Wheel

ที่มา : <https://wrmf.ca/posts/the-hsl-color-model/>

โดยที่ Color Wheel จะมีลักษณะคล้าย ๆ สายรุ้งที่มีการม้วนเป็นวงกลม โดยสีแดงจะอยู่ที่ 0 องศา, สีเขียว อยู่ที่ 120 องศา และสีน้ำเงินอยู่ที่ 240 องศา

Saturation คือ ความอิ่มของสี มีหน่วยเป็นเปอร์เซ็นต์ ตั้งแต่ค่า 0% ถึง 100% ซึ่งการเพิ่มลดค่า Saturation เหมือนการเพิ่มลดเนื้อสีโดยเพิ่มสีมากหรือน้อย โดยที่ 0% จะมั่วค่าสีที่ไม่ได้มีการเจือจางสีลงไป ซึ่งผลลัพธ์ที่ได้จะเป็นสีเทา (Grayscale) ตัวอย่างดังภาพที่ 2.22

- ● hsl(240, 100%, 50%)
- ● hsl(240, 60%, 50%)
- ● hsl(240, 30%, 50%)
- ● hsl(240, 10%, 50%)
- ● hsl(240, 0%, 50%)

ภาพที่ 2.22 ตัวอย่างค่า Saturation ระดับค่าต่าง ๆ  
ที่มา : <https://wrmf.ca/posts/the-hsl-color-model/>

Lightness คือ ความสว่างของสี มีหน่วยเป็นเปอร์เซ็นต์ (%) โดยมีค่าตั้งแต่ 0% ถึง 100% การเพิ่มลด Lightness เหมือนการนำสีขาวหรือสีดำผสมไปที่ Hue ที่ 50% คือค่าตั้งต้นจะมีสีเป็นสีเทา โดยที่ค่าที่มากกว่า 50% จะมีความขาวมากขึ้น หรือเรียกว่า tints และค่าที่ต่ำกว่า 50% จะมีความดำมากขึ้น เรียกว่า shades ตัวอย่างดังภาพที่ 2.23


- ○ hsl(240, 100%, 100%)
- ● hsl(240, 100%, 80%)
- ● hsl(240, 100%, 50%)
- ● hsl(240, 100%, 20%)
- ● hsl(240, 100%, 0%)

ภาพที่ 2.23 ตัวอย่าง Lightness ระดับค่าต่าง ๆ  
ที่มา : <https://wrmf.ca/posts/the-hsl-color-model/>

### 1.3 หน่วยสีระบบ (L\*a\*b\* color space)

ระบบสี L\*a\*b\* บางครั้งเรียก CIELAB เป็นอีกระบบที่มีความนิยมอย่างมากในการนำมาใช้ในการวัดค่าสีและใช้กันอย่างแพร่หลายในหลาย ๆ วงการ โดยหน่วยสีเป็นประเภทที่มีสเกลสม่ำเสมอ (Uniform) ซึ่งได้ถูกกำหนดโดย CIE ในปี 1976 เพื่อแก้ปัญหาการแปลค่าสีที่เกิดขึ้นในระบบ Y<sub>xy</sub> เนื่องจากพบว่า ระยะห่างระหว่าง x กับ y บนไดอะแกรมสีจะไม่สอดคล้องกับความแตกต่างของสีที่เกิดจากการมองเห็นจริง ในระบบสี L\*a\*b\* มีค่า L\* หมายถึงความสว่าง สำหรับ a\* และ b\* เป็นค่าสัมประสิทธิ์ ดังภาพที่ 2.24 กล่าวคือ a\* และ b\* จะบอกถึงทิศทางของสี เช่น +a\* หมายถึงอยู่ในทิศทางของสีแดง -a\* หมายถึงอยู่ในทิศทางของสีเขียว +b\* หมายถึงอยู่ในทิศทางของสีเหลือง และ -b\* หมายถึงอยู่ในทิศทางของสีน้ำเงิน พื้นที่ตรงกลางจะไม่สามารถแยกสีได้

(Achromatic) เมื่อค่า  $a^*$  และ  $b^*$  เพิ่มขึ้นและจุดดังกล่าวเคลื่อนที่ออกจากจุดศูนย์กลางความมืดตัวของสีก็จะเพิ่มขึ้น ซึ่งแสดงให้เห็นค่าสีต่าง ๆ ของหน่วยสี  $L^*a^*b^*$  อย่างชัดเจน ภาพที่ 2.24 เป็นภาพที่ตัดตากว้างโดยค่าความสว่าง ( $L^*$ ) มีค่าคงที่



ภาพที่ 2.24 โคอะแกรมสัมประสิทธิ์  $a^*, b^*$


ที่มา : <http://thecolormeasurement.com/color-space/>

2. ประเภทของภาพดิจิทัล

ประเภทของภาพดิจิทัล [41, 53] นั้นสามารถพิจารณาและแบ่งประเภทพื้นฐานได้ทั้งหมด

3 ประเภท [41] ดังนี้

2.1 Binary แต่ละพิกเซล (Pixel) เป็นเพียงสีดำหรือสีขาว เนื่องจากมีค่าที่เป็นไปได้เพียงแค่สองค่า สำหรับแต่ละพิกเซลต้องการเพียง 1 บิตต่อพิกเซล ซึ่งจึงจะมีประสิทธิภาพมากในการจัดเก็บรูปภาพที่เป็นลักษณะของข้อความ ตัวอักษร(พิมพ์หรือเขียนด้วยลายมือ)



ภาพที่ 2.25 ภาพ Binary

2.2 Grayscale ระดับสีเทา แต่ละพิกเซลมีเฉดสีเทา โดยปกติจาก 0 (ดำ) ถึง 255 (ขาว) ซึ่งหมายความว่าแต่ละพิกเซลสามารถแสดงด้วย 8 บิตหรือ 1 ไบต์ เป็นเฉดสีที่มีความเหมาะสมสำหรับการนำรูปภาพไปจัดการในขั้นตอนอื่น ๆ ได้ และโดยทั่วไปการแสดงระดับสีเทานั้นจะ



นำมาใช้ในงานพิมพ์ภาพ X-rays ซึ่งสามารถนำไปใช้ในการวิเคราะห์หาภาพวัตถุ การเกิดระดับสีเทานั้น เกิดจากค่าของแม่สี (RGB) มีค่าเท่ากัน เช่น 0.4,0.4,0.4 ทั้งหมดจะได้เป็นสีเทา เป็นต้นได้ดีที่สุด ดังภาพตัวอย่างภาพที่ 2.26



ภาพที่ 2.26 ภาพ Grayscale

2.3 Indexed color ดัชนีสี ภาพแต่ละภาพจะมีพิกเซลจำนวนหลาย ๆ พิกเซลรวมกัน โดยที่แต่ละพิกเซลจะมีสีเฉพาะ ซึ่งแต่ละพิกเซลจะมีสีเฉพาะที่มีการผสมกันของสีจากแม่สี คือ สีแดง สีเขียว และสีน้ำเงิน (RGB) โดยที่แต่ละพิกเซลจะมีค่าความเข้มของแม่สีระหว่าง 0 – 1 ในแต่ละ 1 พิกเซล เท่ากับจุดสี 3 สีย่อยรวมกันซึ่งค่า 3 สีย่อยจะไม่เท่ากัน เนื่องจากเกิดจากการผสมสี จึงทำให้เกิดสีในภาพ ดังตัวอย่าง ภาพที่ 2.27



ภาพที่ 2.27 ภาพ Indexed color

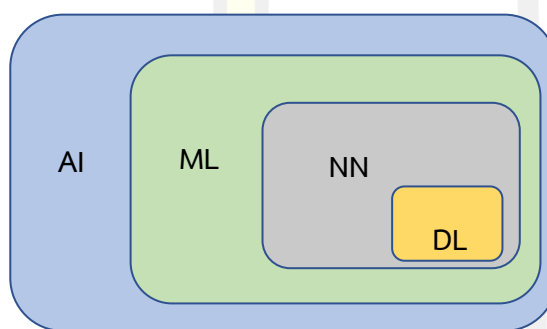
## 2.7 การเรียนรู้เชิงลึก

การเรียนรู้เชิงลึก (Deep learning) [23, 30, 54-57] เป็นส่วนหนึ่งของวิธีการเรียนรู้ของเครื่อง (Machine learning) บนพื้นฐานของโครงข่ายประสาทเทียม และการเรียนรู้เชิงคุณลักษณะ ซึ่งความเป็นมาของการเรียนรู้เชิงลึกนั้นย้อนไปเมื่อปี ค.ศ.1940 [58] ความตั้งใจที่เคยตั้งเป้าหมายไว้คือจำลองระบบสมองของมนุษย์เพื่อแก้ปัญหาการเรียนรู้ที่ซับซ้อนหรือเรียนแบบมนุษย์ ต่อมาในปี ค.ศ.1980 และ ปี ค.ศ.1990 เป็นต้นมาได้กลับมาได้รับความนิยมด้วยการเสนอความสามารถของอัลกอริทึมที่มีความสามารถในการเรียนรู้และตอบกลับข้อมูลได้โดย Rumelhart และคณะ [59] ซึ่งการเรียนรู้เชิงลึกได้รับความนิยมเพิ่มขึ้นอย่างมากตั้งแต่ปี ค.ศ.2006 [59] ด้วยความก้าวหน้าในการรู้จำเสียง [55] และก่อนที่จะเกิดการเรียนรู้เชิงลึก และเป็นการพัฒนาจากระบบปัญญาประดิษฐ์ (Artificial Intelligence) คือ การพัฒนาให้เครื่องจักรสามารถเรียนรู้และทำนายหรือสร้างองค์ความรู้ได้ ด้วยเหตุนี้จึงเป็นที่มาของการเรียนรู้ของเครื่อง (Machine learning) โดยที่การเรียนรู้ของเครื่องนั้นมีกระบวนการดังมี 1) นำเข้าชุดข้อมูล 2) สร้างโมเดลของชุดข้อมูล 3) ใช้โมเดลในการทำนายข้อมูลชุดใหม่ ซึ่งเป็นการสอนให้เครื่องคอมพิวเตอร์สามารถเรียนรู้และเข้าใจได้มีเทคนิคต่าง ๆ มากมาย เช่น Supervised learning , Unsupervised learning, Reinforcement learning หรือ Artificial neuron networks เป็นต้น ทั้งนี้การเรียนรู้ของเครื่องสามารถถูกทำการสอน (Train) อย่างอัตโนมัติซึ่งสามารถทำได้อย่างครบถ้วนหรือเป็นไปได้สำหรับที่มนุษย์จะทำ และยังมีช่องโหว่ที่ชัดเจนจากการวิเคราะห์ที่สามารถตัดสินใจได้ด้วยการแทรกแซงจากมนุษย์เพียงเล็กน้อย จึงได้นำวิธีการเรียนรู้เชิงลึกมาใช้ในการแก้ปัญหาดังกล่าว จึงเกิดเป็นวิธีการเรียนรู้เชิงลึกที่เลียนแบบให้เหมือนกับโครงข่ายประสาทในสมองมนุษย์

ทั้งนี้การเรียนรู้เชิงลึกเป็นการเรียนรู้ที่สามารถเป็นได้ทั้งแบบการเรียนรู้แบบมีผู้สอน การเรียนรู้แบบกึ่งมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน คำว่า “ลึก” ในความหมายมาจากการที่มีชั้นของโครงข่ายหลายชั้นที่มีประสิทธิภาพมากขึ้น การเรียนที่สะดวก และการเข้าใจในโครงสร้างที่ชัดเจนขึ้น พื้นฐานของการเรียนรู้เชิงลึก [54] คือ อัลกอริทึมที่พยายามสร้างแบบจำลองเพื่อแทนความหมายของข้อมูลในระดับสูงโดยการสร้างสถาปัตยกรรมข้อมูลขึ้นมาที่ประกอบไปด้วยโครงข่ายย่อย ๆ หลายอัน และแต่ละอันนั้นได้มาจากการแปลงที่เป็นเชิงเส้น การเรียนรู้เชิงลึกอาจมองได้ว่าเป็นวิธีการหนึ่งของการเรียนรู้ของเครื่องที่พยายามเรียนรู้วิธีการแทนข้อมูลอย่างมีประสิทธิภาพ เช่น รูปภาพหนึ่งภาพ สามารถแทนได้เป็นเวกเตอร์ของความสว่างต่อจุดพิกเซล หรือมองในระดับสูงขึ้นเป็นเซตของขอบวัตถุต่าง ๆ หรือมองว่าเป็นพื้นที่ของรูปร่างใด ๆ ก็ได้ การแทนความหมายดังกล่าวจะทำให้การเรียนรู้ที่จะทำงานต่าง ๆ ทำได้ง่ายขึ้น ไม่ว่าจะเป็นการรู้จำใบหน้าหรือการรู้จำการแสดงออกทางสีหน้า การเรียนรู้เชิงลึกถือว่าเป็นวิธีการที่มีศักยภาพสูงในการจัดการกับพีเออร์สำหรับการเรียนรู้แบบไม่มีผู้สอนหรือการเรียนรู้แบบกึ่งมีผู้สอน [56]

การเรียนรู้เชิงลึกนี้ใช้ทฤษฎี 2 แนวทาง [56] คือ การใช้ทฤษฎีประมาณค่าสากล (Universal approximation theorem) และใช้การอนุมานความน่าจะเป็น (Probabilistic inference) ซึ่งทฤษฎีประมาณค่าสากล สนใจความสามารถของโครงข่ายประสาทแบบป้อนไปข้างหน้า (Feedforward neural networks) ที่มี Hidden layer เพียงชั้นเดียวและมีขนาดจำกัดเพื่อประมาณ

ค่าของฟังก์ชันต่อเนื่อง โดย George cybenko [60] ได้พิสูจน์การเรียนรู้เชิงลึกด้วยทฤษฎีนี้ โดยใช้ฟังก์ชันซิกมอยด์ (Sigmoid) ในปี 1989 และต่อมา Hornik [61] นำไปพิสูจน์ต่อสำหรับ Feedforward neural networks ที่มีหลาย ๆ ชั้น ในปี 1991 สำหรับการอนุมานความน่าจะเป็นนั้น มีแนวคิดมาจากการเรียนรู้ของเครื่อง เสนอขึ้นครั้งแรกโดย Jeffrey Hinton และคณะ [62] เป็นกลุ่มนักวิทยาศาสตร์ผู้บุกเบิกสาขาการเรียนรู้เชิงลึกยุคใหม่ แนวคิดนี้จะเน้นการปรับโครงสร้างการเรียนรู้เชิงลึกด้วยการหาโมเดลค่าที่ดีที่สุด (Optimization) สำหรับข้อมูลการสอน (Training) และข้อมูลการทดสอบ (Testing) ทั้งนี้ การอนุมานด้วยค่าที่น่าจะเป็นนั้นจะมองว่าการเปิดใช้งานความไม่เป็นเชิงเส้น (Activation nonlinearity) เป็นฟังก์ชันการกระจายแบบสะสม (Cumulative distribution function) ทำให้เกิดเทคนิคการใช้ Dropout เป็นตัวควบคุม (Regularize) สำหรับโครงข่ายประสาทเทียม



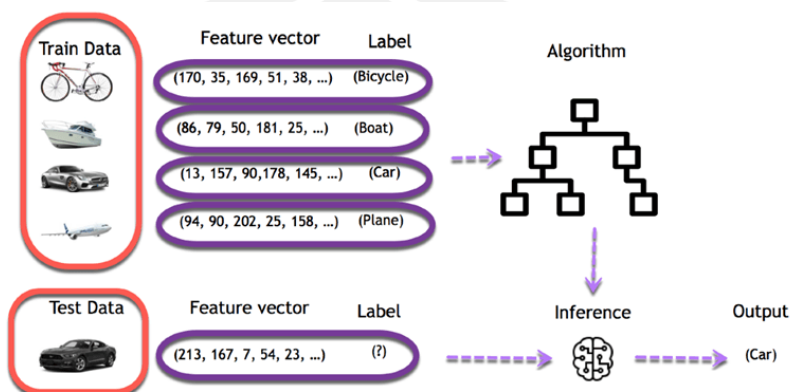
ภาพที่ 2.28 เปรียบเทียบความสำคัญและพัฒนาการการเรียนรู้เชิงลึก

ที่มา : <https://developer.ibm.com/articles/an-introduction-to-deep-learning/>

### 1. กระบวนการทำงานของการเรียนรู้ของเครื่อง (Machine Learning)

กระบวนการทำงานของการเรียนรู้ของเครื่องนั้นจะขอยกตัวอย่างอธิบายเพื่อให้เกิดความเข้าใจดังนี้ หากต้องการสร้างโปรแกรมที่มีการจดจำวัตถุขึ้นมาเพื่อที่จะฝึก (Train) รูปแบบ (Model) นั้น จะต้องใช้ตัวแบ่งประเภท (Classifier) ใช้คุณลักษณะ (Feature) ของวัตถุเพื่อพยายามหาประเภทของวัตถุนั้น ซึ่งในตัวอย่างการแบ่งประเภทจะถูกฝึกเพื่อตรวจจับถ้ามีรูปจักรยาน เรือ รถยนต์ และเครื่องบิน 4 วัตถุนี้คือประเภทของวัตถุที่แตกต่างกันการแบ่งประเภทของวัตถุที่แตกต่างกันจำเป็นต้องจดจำ เพื่อที่จะสร้างการแบ่งประเภทขึ้น หากจำเป็นต้องมีข้อมูลจำนวนหนึ่งเป็นข้อมูลขาเข้าและกำหนดให้ว่าข้อมูลแต่ละอันเป็นประเภทอะไร อัลกอริทึม (Algorithm) นี้จะนำข้อมูลที่ไดหารูปแบบ (Pattern) แล้วแบ่งประเภทของข้อมูลตามประเภทต่าง ๆ ซึ่งกระบวนการดังกล่าวนี้เป็นรูปแบบการเรียนรู้แบบมีผู้สอน (Supervised learning) สำหรับข้อมูลการฝึก (Training data) จะต้องส่งต่อไปยังอัลกอริทึมที่พร้อมกับการทำสัญลักษณ์เพื่อบอกผลลัพธ์ไว้ ซึ่งกระบวนการฝึกนั้นมีกระบวนการที่จำเป็นต้องทำดังนี้ 1) เก็บข้อมูล 2) ฝึกการแบ่งประเภท 3) ทำนายผล ขั้นตอนแรกนั้นมีความจำเป็นอย่างมาก เนื่องจากการเลือกข้อมูลที่ถูกต้องจะนำมาซึ่งอัลกอริทึมที่ประสบความสำเร็จหรือล้มเหลว ข้อมูลที่ทำการเลือกมาเพื่อทำการฝึกจะถูกเรียกว่า คุณลักษณะ (Feature) ในตัวอย่างของวัตถุ ซึ่งคุณลักษณะนั้นคือพิกเซล (Pixel) ของรูปภาพ แต่ละแถวของรูปภาพจะใช้พิกเซลเป็น

ข้อมูล เช่น หากรูปภาพมีขนาด  $28 \times 28$  ชุดข้อมูลจะมีขนาด 784 แฉว ซึ่งแต่ละรูปจะแปลงเป็นเวกเตอร์ของคุณลักษณะ (Feature vector) การทำสัญลักษณ์ไว้ (Label) เป็นการบอกให้คอมพิวเตอร์ได้รู้ว่ามื่อะไรอยู่ในรูปภาพนั้น




ภาพที่ 2.29 กระบวนการทำงานของการเรียนรู้ด้วยเครื่อง (Machine learning)

ที่มา : <https://www.thaiprogrammer.org>

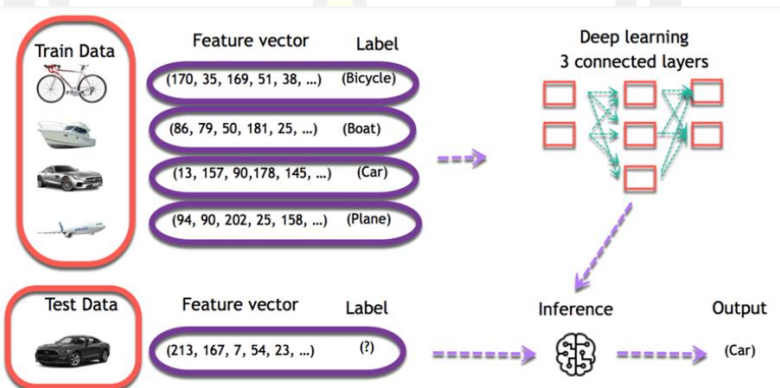
วัตถุประสงค์หลักจะเป็นการใช้การฝึกข้อมูล (Training data) เพื่อแบ่งประเภทของชนิดวัตถุ ในขั้นตอนแรกประกอบไปด้วย 1) การสร้างคุณลักษณะ 2) การเลือกอัลกอริทึมเพื่อการฝึกหรือการเรียนรู้ (Train model) นั้นหากทำการฝึกเสร็จแล้วรูปแบบ (Model) นั้นจะทำนายได้ว่าสิ่งใดอยู่ในรูปภาพบ้าง จากนั้นนำรูปแบบที่ได้ไปทำนายรูปภาพอื่น ๆ ต่อไป สำหรับนำรูปภาพใหม่ ๆ เข้าสู่รูปแบบนั้น การเรียนรู้ของเครื่องจะทำนายว่าวัตถุอยู่น้อยประเภทใด

## 2. กระบวนการทำงานของการเรียนรู้เชิงลึก (Deep learning)

การทำงานของกรเรียนรู้เชิงลึกจะเหมาะกับการทำสิ่งที่ซับซ้อนมาก ๆ มีข้อมูลจำนวนมากที่ต้องคิดหรือเรียนรู้ เช่น การทำ Object recognition, ระบบรู้จำใบหน้า ไปถึงการทำ Artificial neural networks (ANN) ซึ่งเป็นระบบประสาทจำลองที่คอมพิวเตอร์เลียนแบบมนุษย์หรือเรียกว่า Neural Networks โดยเป็นลักษณะการทำงานของกรเรียนรู้เชิงลึก ระบบโครงข่ายประสาทนี้จะถูกแบ่งออกเป็น 3 ชั้น (Layers) ได้แก่ ชั้นนำเข้า (Input layer) ชั้นประเมนชุดข้อมูล (Hidden layer) และชั้นนำเสนหรือแทนองค์ความรู้นั้น (Output layer) ในแต่ละชั้นจะมีสิ่งที่เรียกว่า Node ใน Hidden layer จะเป็นชั้นที่สำคัญที่สุด เนื่องจากการประมวลผลจากการใช้ค่าน้ำหนัก (Weight) และ Activation functions




ภาพที่ 2.30 เปรียบเทียบโครงข่ายประสาท  
ที่มา : <https://www.thaiprogrammer.org>



ภาพที่ 2.31 กระบวนการทำงานของการเรียนรู้เชิงลึก (Deep learning)  
ที่มา : <https://www.thaiprogrammer.org>

ทั้งนี้การเรียนรู้เชิงลึกมีการนำมาประยุกต์ใช้ในงานต่าง ๆ มากมาย เช่น การแยกแยะใบหน้าคน การติดแท็กรูปภาพเพื่อในเฟสบุ๊ค (Facebook) หรือการแยกแยะวัตถุที่ไม่ใช่คน เป็นต้น

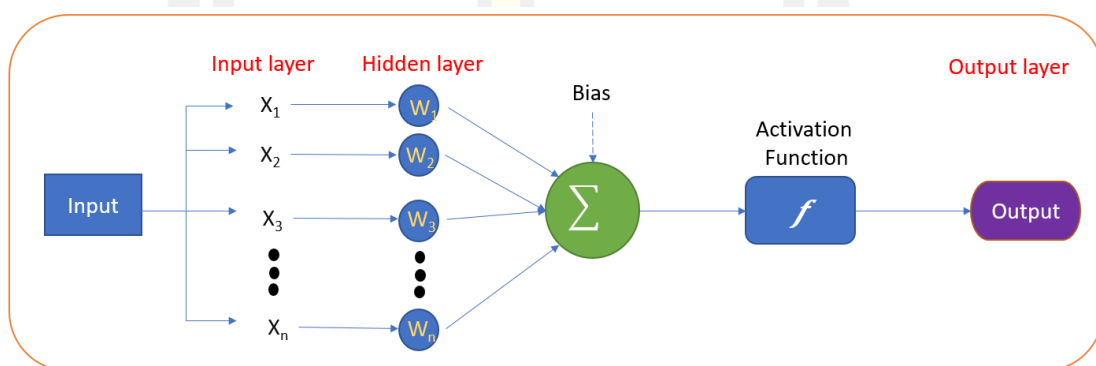


ภาพที่ 2.32 การเรียนรู้เชิงลึกสำหรับการเรียนรู้จดจำใบหน้า  
ที่มา : <https://medium.com>

## 2.8 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial neural network) หรือ ANN คือรูปแบบหนึ่งของการเรียนรู้ของเครื่อง ซึ่งเป็นแบบจำลองทางสถิติที่จำลองการทำงานของเซลล์ประสาท สามารถระบุรูปแบบและแยกออกเป็นเส้นตรงโดยการกำหนดค่าน้ำหนักที่เป็นตัวเลขให้กับอินพุตแต่ละรายการ และปรับพวกมันในขณะที่สุ่มตัวอย่างข้อมูล การเรียนรู้มีประสิทธิภาพ ทางออกที่ดีที่สุด ซึ่ง ANN จะใช้โครงข่ายของ Multi-Layer Perceptron (MLP) ด้วยอัลกอริทึม back-propagation (BP) โดยจะทำการจัดระเบียบในหลาย ๆ ชั้น แต่ละชั้นมีองค์ประกอบการประมวลผลทางคณิตศาสตร์จำนวนหนึ่ง ขึ้นอยู่กับความซับซ้อนของปัญหา และอัลกอริทึม BP มีหน้าที่ป้อนข้อผิดพลาดกลับเข้าไปในแบบจำลอง ทำให้สามารถปรับน้ำหนักการเรียนรู้ได้ตามลำดับ และหยุดการปรับน้ำหนักเมื่อพบค่าที่ดีที่สุดหรือต่ำที่สุด หลักการทำงานของ ANN พัฒนาโดย Lancashire และคณะ [63] นำมาใช้ในการระบุหรือชุดของยีนที่มีการทำนายที่ดีที่สุดมีประสิทธิภาพในการจำแนกกลุ่มได้ตามประเภทของข้อมูล หลักการทำงานของ ANN นั้นจะทำการคำนวณหาค่าน้ำหนักของข้อมูล ตัวอย่างเช่น การคำนวณค่าน้ำหนักจากภาพถ่ายดิจิทัล เนื่องจากภาพในคอมพิวเตอร์เกิดจากจุดของสีเล็ก ๆ ที่มารวมกันจนเกิดเป็นภาพขึ้นมา ซึ่งจุดเล็ก ๆ ที่เรียกนั้นเรียกว่า “Pixel” ซึ่งจุดแต่ละจุดในภาพมีขนาดเท่าไหรันั้นขึ้นอยู่กับขนาดของภาพ แต่ละพิกเซลของภาพนั้นเกิดจากการผสมของสี คือ สีแดง สีเขียว สีน้ำเงิน โดยที่แต่ละพิกเซลจะมีค่าความเข้มของแม่สีระหว่าง 0 – 1 ในแต่ละ 1 พิกเซล เท่ากับจุดสี 3 สีย่อยรวมกันซึ่งค่า 3 สีย่อยจะไม่เท่ากัน เนื่องจากเกิดจากการผสมสี จึงทำให้เกิดสีในภาพ ดังนั้นจึงทำให้สามารถทราบจำนวนเซลล์ประสาท (Neuron) ที่จะส่งค่าเข้าไปยัง โหนด (Node) เมื่อได้จำนวนโหนดแล้วจะทำการส่งค่าไปยังชั้นที่ซ่อนอยู่ (Hidden Layer) เพื่อคำนวณหาค่าน้ำหนักของโหนด ซึ่งวิธีการคำนวณหาค่าน้ำหนักนี้มีวิธีคิด คือ ขนาดของแต่ละเซลล์  $\times$  ข้อมูลก่อนหน้า (Feature map)  $\times$  ขนาดทั้งหมด ก็จะได้ค่าน้ำหนัก (Weight) จากนั้นนำผลคูณของโหนดแต่ละตัวมารวมกันก็จะได้ค่าผลรวม (Sum) ซึ่งน้ำหนักในแต่ละเซลล์ประสาท จะถูกปรับโดยเทียบกับข้อผิดพลาด (Error) ทั้งหมด กระบวนการนี้จะทำซ้ำจนกว่า Error จะลดลงจนถึงจุดที่สามารถยอมรับได้ สำหรับค่าอคติ (Bias) เป็นค่าคงที่ (Constant) ที่มาพร้อมกับเซลล์ประสาท และจะนำไปบวกกับค่าน้ำหนักของ ค่านำเข้า (Input) ก่อนที่จะนำไปเข้าฟังก์ชันการเปิดใช้งาน (Activation Function) ซึ่งจะช่วยปรับค่า เช่น ถ้าค่า Input ไม่มีคุณลักษณะเฉพาะ (Feature) เลยแล้วผลที่ได้ (Output) ควรจะมีค่าเป็น 0 หรือไม่ ซึ่งเป็นปัญหาที่ว่าในบางกรณี ค่าบางค่าของ Feature จะมีผลกระทบ ดังนั้น Bias จะใช้คู่กับ Weight ในการปรับค่าโดยสามารถเรียนรู้และปรับค่าไปเรื่อย ๆ โดยที่สองตัวนี้เป็นตัวแปรที่เปลี่ยนแปลงค่าตัวเองไปเรื่อย ๆ ระหว่างการทดลอง (Train) เพื่อให้เข้ากับข้อมูล (Data) และคอยปรับค่า Input สำหรับตอนเริ่มต้นของการทดลอง Weight และ Bias จะสุ่มค่ามาก่อน เมื่อได้ค่า Weight แล้วจะส่งค่าไปยัง Activation function ซึ่งจะทำหน้าที่แปลงค่า (Transform) ค่าทุกค่าที่ได้รับจากทุก ๆ โหนด เพื่อส่งค่าไปยังชั้น (Neuron Layer) ต่อไป ซึ่ง Activation function มีหลาย ฟังก์ชัน เช่น Sigmoid function, Tanh function, ReLU function, Leaky ReLU function และ ELU function เป็นต้น สำหรับ Activation function นั้นมีความเหมาะสมสำหรับการทำการเรียนรู้เชิงลึก (Deep learning) เนื่องจากเป็นสมการที่ไม่ใช่เส้นตรง

(Linear regression) ที่สามารถนำมาใช้กับ Neural network ได้ โดย Activation function ที่นิยมใช้ในปัจจุบันนั้น คือ Sigmoid function ซึ่งผลลัพธ์มีค่าระหว่าง 0-1 จึงเหมาะที่จะถูกใช้ในงานที่ต้องการผลลัพธ์เป็นความน่าจะเป็น (Probability) หรือใช้กับผลลัพธ์ 1 = Yes, 0 = No และ ReLU function หากค่านำเข้าเป็นค่าติดลบ ค่าผลลัพธ์จะเป็น 0 เสมอ เมื่อผ่านขั้นตอนการทำ Activation function ต่อไปจะเป็นการตรวจสอบค่าคำตอบที่ถูกต้องที่เกิดจากการปรับค่า Weight แต่ละตัวและคาดหวังว่าจะได้คำตอบที่ถูกต้อง โดยการปรับค่า Weight และค่า Bias ดังนั้นหากต้องการตรวจสอบความถูกต้องของการปรับค่าต่าง ๆ ที่กล่าวมานั้นจะต้องมีฟังก์ชัน (Function) ที่เรียกว่า “Error cost function” กล่าวคือ หาก Neuron ส่งค่าผลลัพธ์ผิด ค่าจำนวนการสูญเสีย (Loss) จะมีค่ามาก และหาก Neuron ส่งค่าผลลัพธ์ถูก ค่า Loss จะมีค่าน้อย



ภาพที่ 2.33 โครงสร้างการทำงานของโครงข่ายประสาทเทียม  
ที่มา : <https://devskrol.com/2020/11/22/388/>

Loss function [64] คือ ฟังก์ชันเป็นเสมือนการตั้งเป้าหมายให้กับ Neural network ที่จะเรียนรู้โดยมีเป้าหมายอะไรให้เป็นไปตามเป้าหมายที่ตั้งไว้ได้มากที่สุด ซึ่ง Loss function มีหลายแบบหลายประเภท ตามความเหมาะสมของงานโดยทั่วไปแต่จะขอกกล่าวถึง 2 แบบ คือ 1.) Cross-entropy loss จะนิยมใช้กับงานแยกประเภทที่มีจำนวนประเภทที่แน่นอน ตัวอย่างเช่น หากนำภาพสุนัขไปให้คน 100 คน และบอกว่าเป็นภาพอะไร คนทั้ง 100 คนจะบอกว่าเป็นสุนัข ฉะนั้นเครือข่าย (Network) ควรที่จะบอกว่าเป็นภาพสุนัขด้วยความน่าจะเป็นเท่ากับ 1 หรือตอบว่าสุนัข 100% ด้วยในความจริงแล้วเครือข่ายจะไม่สามารถตอบคำตอบได้ตรง 100% เนื่องจากจะมีความไม่แน่ใจในสิ่งที่ได้เรียนรู้เกิดขึ้น ดังนั้นจึงได้ตอบไปยังคำตอบอื่น ๆ ซึ่งจะดูที่เปอร์เซ็นต์ คำตอบที่มากที่สุดเป็นคำตอบ หลังจากที่เราทราบถึงค่า Loss function แล้วจะเข้าสู่หาจุดต่ำสุด (Gradient) กล่าวคือ Gradient จะช่วยปรับค่า Weight ในแบบจำลอง (Model) ให้ค่า Loss function ลดต่ำลงไปที่จุดต่ำสุดที่เป็นไปได้ซึ่งจุดที่ต่ำที่สุดมี 2 แบบ คือ 1.) Global minimum (จุดที่ต่ำที่สุดจริง ๆ) และ 2.) Local minimum (จุดที่ต่ำที่สุดในระแวกนั้น ๆ) ซึ่ง Gradient เป็นการกำหนดทิศทางที่จะมีความชันสูงขึ้น แต่สำหรับการใช้งานการเรียนรู้เชิงลึกนั้นจะเป็นการหาทิศทางที่ต่ำที่สุด เช่น ถ้ามองเป็นเวกเตอร์ (Vector) จะชี้ไปในทิศทางที่มีความชันสูงกว่าจึงต้องกลับด้านด้วยการลบ เพื่อให้ชี้ไปทิศทาง

ที่มีความชันต่ำกว่า ถ้าเปรียบอัตราการเรียนรู้ (Learning rate) กับการเดินทางเช่น ถ้าออกเดินทางแล้วแวะหลาย ๆ ที่ Learning rate จะมีค่าต่ำ และจะใช้เวลาในการเดินทางมาก แต่ก็อาจจะเจอสิ่งที่ต้องการจากการเดินทางได้ แต่หากออกเดินทางแล้วแวะไม่กี่ที่ Learning rate จะมีค่าสูง และใช้เวลาในการเดินทางน้อยแต่ก็อาจจะเจอหรือไม่เจอสิ่งที่ต้องการจากการเดินทางก็ได้เช่นกัน ซึ่งกล่าวโดยสรุปคือ Gradient descent จะใช้กับ Loss function เพื่อหาค่าของ Weight และ Bias ที่ทำให้ค่า Loss อยู่ที่จะต่ำที่สุดของ Loss function หรือเรียกอีกอย่างคือ การทำ Optimization ซึ่งมีอัลกอริทึม (Algorithm) ดังนี้ [65]

1. Stochastic Gradient Descent (SGD) เป็นอัลกอริทึมที่เปลี่ยนแปลง (Update) ค่า Weight ในทุก ๆ ชุดข้อมูลฝึกฝน (Train) เป็นอัลกอริทึมที่ไว้อัพเดทแค่หนึ่งครั้งต่อการ Train 1 รอบ โดยในทุก ๆ ครั้งที่มีการเปลี่ยนแปลง ค่า Weight จะมีค่าความแปรปรวนสูงและส่งผลกับค่า Loss function แปรผันไปตาม different intensities โดยขั้นตอนเหล่านี้เป็นสิ่งที่ดีเนื่องจากจะช่วยให้สามารถค้นพบค่าที่น้อยที่สุดได้ แต่วิธีนี้มีปัญหาคือยิ่งลู่ลงต่ำเท่าไรค่าที่ได้ก็จะยิ่งแปรปรวนและซับซ้อนมากยิ่งขึ้น

2. Mini Batch Gradient Descent ถูกพัฒนาขึ้นเพื่อหนีปัญหาของ Gradient Descent โดยการนำข้อดีของ Gradient Descent และ Stochastic Gradient Descent มารวมกัน และสำหรับอัลกอริทึมนี้จะเปลี่ยนแปลงค่าเป็น “ชุด” โดยภายในชุดจะประกอบด้วยข้อมูลจำนวน  $n$  ข้อมูล

3. Momentum ในการปรับค่าในแต่ละครั้งของ SGD จะสร้างความแปรปรวนเกิดขึ้นมาก ทำให้ยากที่ลู่เข้าจุดที่ต่ำสุดได้ (Best optimize) จึงได้มีอัลกอริทึมที่ชื่อว่า “Momentum” เกิดขึ้น ถูกคิดค้นเพื่อเร่งความเร็วในการ optimize ของ SGD โดยการให้ความสำคัญในการพุ่งไปยังทิศทางที่ใกล้จุดกึ่งกลางมากที่สุดก่อน จากนั้นทำให้ทิศทางที่ไม่เกี่ยวข้องหรือไม่มีความสำคัญลดลงทำให้เกิดทิศทางที่ “ถูกต้อง” เกิดขึ้น

4. Adagrad เป็น Optimize ที่สามารถปรับค่าค่า Learning Rate ให้เหมาะสมกับพารามิเตอร์ได้ โดยจะมีการอัปเดตจำนวนมากสำหรับค่าพารามิเตอร์ที่มีจำนวนน้อย และอัปเดตไม่มากนักถ้าค่าพารามิเตอร์มีจำนวนมากและด้วยเหตุนี้ Optimizer ตัวนี้จึงเป็นที่นิยมสำหรับ Sparse data (ข้อมูลที่กระจัดกระจาย) โดยค่า Learning Rate จะถูกเปลี่ยนทุก ๆ ครั้งสำหรับพารามิเตอร์  $\theta$  (ทิศทางในการเคลื่อนที่) โดยอ้างอิงจากทิศทางที่ผ่านมาที่ผ่านการคำนวณจาก Gradient descent มาแล้ว

5. AdaDelta เป็นตัวต่อยอดมาจาก AdaGrad โดยสามารถลบปัญหา อัตราการเรียนรู้ที่สูญหาย (Decaying learning rate) ที่เกิดขึ้นใน AdaGrad ได้ โดยการเก็บสะสมการคำนวณทั้งหมดที่ผ่านมาของ Gradient แต่ AdaDelta จะถูกจำกัดการสะสมค่าการคำนวณของ Gradient ได้นั้นเพื่อแก้ขนาดค่าของ Weight ที่จะเกิดขึ้น หากเก็บค่า Weight ที่ได้รับการอัปเดตมาก่อนหน้านี้ที่ยังไม่ได้พอ จึงได้เปลี่ยนเป็นการหาผลรวมของ Gradients โดยการทำให้แบบช้า ๆ ไปเรื่อย ๆ เพื่อการแก้ปัญหา Decaying learning rate ของ Gradients ที่ผ่านมาทั้งหมด



6. Adam หรือเรียกว่า Adaptive Moment Estimation เป็น optimizer ที่สามารถปรับ learning rates สำหรับพารามิเตอร์ในแต่ละครั้งได้และยังสามารถแก้ปัญหา Decaying ของ Gradients ในแต่ละสแต็ปที่ผ่านมาได้เหมือนกับ AdaDelta อีกทั้งยังอธิบายการเกิด Decaying average ของ Gradients ที่ผ่านมาได้และเหมือนกับ Momentum Adam เป็น Optimizer ที่เป็นที่ยอมรับมากที่สุดเนื่องจากรวมจุดเด่นของแต่ละ Optimizer และลบจุดด้อยต่าง ๆ ออกไปทั้งการ Decaying learning rate ของ Adagrad ช่วยให้แบบจำลองไม่หยุดเรียนรู้ได้ อีกทั้งยังมีความเร็วกว่า Gradient descent และลดปัญหาการแกว่งของพารามิเตอร์ได้

## 2.9 โครงข่ายประสาทเทียมแบบสังวัตนาการ

โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) เป็นโครงข่ายประสาทเทียมระดับลึก ซึ่งส่วนใหญ่จะใช้กับการวิเคราะห์ภาพที่มองเห็น [66] แนวคิดในการใช้โครงข่ายประสาทเทียมสำหรับการประมวลผลภาพถูกเสนอในงานของ Lecun และคณะ [67] ในปี ค.ศ.1998 เพื่อแก้ปัญหาคำจำกัดจำตัวเลข ตัวอักษรที่เขียนด้วยลายมือโดยอัตโนมัติ ได้เสนอสถาปัตยกรรมที่เรียกว่า Convolutional Neural Network (CNN) ขึ้น ด้วยความสามารถของ CNN นั้นเป็นอัลกอริทึมที่ได้รับความนิยมเป็นอย่างมากในปัจจุบัน ซึ่งสามารถทำให้เครื่องคอมพิวเตอร์ได้เรียนรู้เชิงลึก (Deep learning) เป็นวิธีการหนึ่งสำหรับการเรียนรู้ของเครื่องคอมพิวเตอร์ (Machine learning) ทำการนำโมเดลการเรียนรู้ไปใช้เพื่อการจำแนกรูปภาพ วีดีโอ ข้อความหรือเสียง เป็นต้น CNN นั้นมีความสามารถและประโยชน์อย่างยิ่งสำหรับการค้นหารูปแบบหรือคุณลักษณะเด่นของภาพ (Patterns ,Features) เพื่อการจดจำหรือรู้จำภาพต่าง ๆ ได้ เช่น ใบหน้าคน (Faces) ภาพวัตถุ (Objects) ฉากหลัง (Scenes) เป็นต้น ซึ่ง CNN นั้นจะเรียนรู้จากภาพที่ผู้ใช้งานเตรียมไว้ เรียกว่า ชุดข้อมูลรูปภาพ (Images dataset) เป็นการเรียนรู้จากคุณลักษณะเด่นของภาพ ซึ่งได้จากกระบวนการที่ใช้รูปแบบการจำแนกภาพ (Classify) และการขจัด (Eliminating) ซึ่งโครงข่ายมันทำการสกัดคุณลักษณะเด่นด้วยตัวเอง


โครงข่ายประสาทเทียมเริ่มต้นจากการค้นพบของ Hubel และ Wisel ในปีพ. ศ. 2502 [68] ตามที่ได้กล่าวไว้ว่าเซลล์ของเยื่อหุ้มสมองที่มองเห็นได้ของสัตว์จะสามารถรับรู้แสงในช่องรับแสงขนาดเล็ก ในปี 1980 Kunihiko Fukusima ได้แรงบันดาลใจจากผลงานนี้จึงได้เสนอโครงข่าย neocognitron [69] นี้ขึ้นเป็นแบบจำลองทางทฤษฎีแรกสำหรับ CNN ในปี 1990 LeCun และคณะ ได้พัฒนากรอบการทำงานสมัยใหม่ให้กับ CNN ที่เรียกว่า LeNet-5 [67] เพื่อจดจำตัวเลขที่เขียนด้วยลายมือ การฝึกโดย backpropagation [70] อัลกอริทึมนี้ช่วยให้ LeNet-5 สามารถจดจำรูปแบบภาพจากภาพต้นฉบับได้โดยตรงโดยไม่ต้องใช้วิศวกรรมคุณลักษณะใด ๆ ในการแยก แต่ในสมัยนั้นแม้จะมีข้อดีหลายประการ แต่ประสิทธิภาพของ CNN ยังมีปัญหาที่ซับซ้อนยิ่งขาดข้อมูลการฝึกอบรมจำกัด ขาดนวัตกรรมของอัลกอริทึมและพลังในการประมวลผลที่ไม่เพียงพอ และเมื่อเร็ว ๆ นี้ได้มีชุดข้อมูลขนาดใหญ่คืออัลกอริทึมที่เป็นนวัตกรรมใหม่และเครื่องที่มี GPU ที่ทรงพลังเกิดขึ้นในปี 2012 ด้วยความสามารถในการไล่ระดับสีของ CNN มีความลึกและขนาดใหญ่เพิ่มขึ้นเรียกว่า AlexNet ซึ่ง

เป็นการออกแบบโดย Krizhevsky และคณะ [71] แสดงให้เห็นถึงประสิทธิภาพที่ตีเทียมใน ILSVRC [72] ความสำเร็จของ AlexNet ได้เป็นแนวทางไปสู่การประดิษฐ์ CNN แบบจำลองต่าง ๆ [73] รวมถึงการประยุกต์ใช้โมเดลในสาขาต่าง ๆ ของคอมพิวเตอร์ การประมวลผลภาษาธรรมชาติและ การประมวลผลภาพ โครงข่ายประสาทเทียมแบบดั้งเดิมประกอบด้วยเลเยอร์คอนโวลูชันและเลเยอร์รวมกลุ่มเดี่ยวหรือหลายบล็อกตามด้วยเลเยอร์ที่เชื่อมต่อกันเต็มรูปแบบ (Fully connected : FC) หนึ่งหรือหลายเลเยอร์และเลเยอร์เอาต์พุต เลเยอร์คอนโวลูชันเป็นส่วนประกอบหลักของ CNN เลเยอร์นี้มีจุดมุ่งหมายเพื่อเรียนรู้การแสดงคุณลักษณะของอินพุต เลเยอร์คอนโวลูชันประกอบด้วย เคอร์เนลคอนโวลูชันที่เรียนรู้ได้หลายตัวหรือหลายตัวกรองซึ่งใช้ในการคำนวณแผนที่คุณสมบัติต่าง ๆ แต่ละหน่วยของแผนผังคุณลักษณะ เชื่อมต่อกับช่องรับสัญญาณในเลเยอร์ก่อนหน้า แผนผังคุณลักษณะใหม่สร้างขึ้นโดยการแปลงข้อมูลเข้ากับ kernels และใช้ฟังก์ชันการเปิดใช้งานที่ไม่ใช่เชิงเส้นตามองค์ประกอบของผลลัพธ์ที่ได้รับการแปลง คุณสมบัติการแชร์พารามิเตอร์ของเลเยอร์คอนโวลูชันช่วยลดความซับซ้อนของโมเดล เลเยอร์การรวมกลุ่ม (Pooling) หรือการสุ่มตัวอย่างย่อย (Sub-sampling layer) ใช้พื้นที่ขนาดเล็กของเอาต์พุตแบบ Convolutional ซึ่งเป็นอินพุตและตัวอย่างเพื่อสร้างเอาต์พุตเดี่ยว มีเทคนิคการสุ่มตัวอย่างย่อยที่แตกต่างกัน เช่น การรวมสูงสุด (Max pooling) การรวมขั้นต่ำ (Min pooling) การรวมค่าเฉลี่ย (Average pooling) เป็นต้น

การรวมกลุ่ม (Pooling reduces) จะช่วยลดจำนวนพารามิเตอร์ที่จะคำนวณ ส่วนสุดท้ายของ CNN นั้นโดยพื้นฐานแล้วประกอบด้วยเลเยอร์ FC อย่างน้อยหนึ่งชั้นที่มักพบในโครงข่ายประสาทเทียมแบบ feedforward เลเยอร์ FC รับอินพุตจากเลเยอร์พูลหรือคอนโวลูชันสุดท้ายและสร้างเอาต์พุตสุดท้ายของ CNN ในกรณีของการจัดประเภทภาพ CNN สามารถดูได้จากการรวมกันของสองส่วน คือ ส่วนการแยกคุณลักษณะและส่วนการจำแนกประเภท ทั้งเลเยอร์คอนโวลูชันและการรวมกันจะทำให้สามารถแยกคุณลักษณะได้ ตัวอย่างเช่น ภาพของสุนัขเลเยอร์คอนโวลูชันที่แตกต่างกันตั้งแต่ระดับล่าง ไปจนถึงระดับสูงจะสามารถตรวจจับลักษณะต่าง ๆ เช่น ตาสองข้าง หูยาว สีขา เป็นต้น เพื่อการจดจำและเพิ่มความละเอียดของ features โดยเลเยอร์ FC จะถูกเพิ่มเป็นลักษณะนามและมีการกำหนดความน่าจะเป็นสำหรับภาพอินพุตที่เป็นสุนัข นอกเหนือจากการออกแบบเลเยอร์แล้วการปรับปรุง CNN นั้นขึ้นอยู่กับลักษณะต่าง ๆ เช่น ฟังก์ชันการเปิดใช้งานวิธีการทำให้เป็นมาตรฐานของฟังก์ชันการสูญเสียการทำให้เป็นมาตรฐานการเพิ่มประสิทธิภาพและความเร็วในการประมวลผล เป็นต้น

แนวคิดการทำงานของโครงข่ายประสาทเทียม Convolutional Neural Network (CNN) หรือที่เรียกว่า ConvNet เป็นประเภทของ Artificial Neural Network (ANN) ซึ่งมีสถาปัตยกรรมที่สามารถบอกถึงสิ่งที่จะเกิดขึ้นในอนาคตข้างหน้าได้ในเชิงลึกและมีความสามารถในการสรุปภาพรวมที่น่าสนใจเมื่อเทียบกับเครือข่ายอื่น ๆ แล้วและมีเลเยอร์ FC ที่สามารถเรียนรู้คุณสมบัติที่เป็นนามธรรมของออบเจกต์ (Object) หรือวัตถุโดยเฉพาะข้อมูลเชิงพื้นที่และสามารถระบุได้อย่างมีประสิทธิภาพมากขึ้น แบบจำลอง CNN เชิงลึกนี้ประกอบด้วยชุดชั้นการประมวลผลที่จำกัด ซึ่งสามารถเรียนรู้คุณสมบัติต่าง ๆ ของข้อมูลนำเข้าหรืออินพุต (เช่น รูปภาพ) ที่มีลักษณะหลายระดับ เลเยอร์เริ่มต้นจะเรียนรู้และดึงคุณลักษณะระดับสูง (ที่มีลักษณะต่ำกว่า) และชั้นที่ลึกลงไปจะเรียนรู้และดึงคุณสมบัติ

ระดับต่ำออกมา (ที่มีลักษณะสูงกว่า) แบบจำลองพื้นฐานของ CNN สามารถแสดงในภาพที่ 2.34 ซึ่งเป็นเลเยอร์ประเภทต่าง ๆ ที่จะอธิบายไว้ในส่วนต่อ ๆ ไป



ภาพที่ 2.34 แบบจำลองแนวคิดของ CNN

ที่มา : [73]

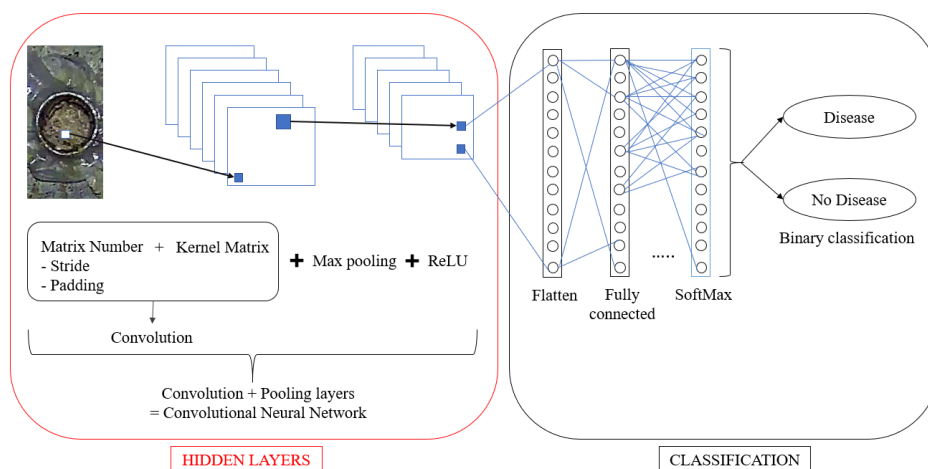
หากจะถามว่าเหตุใด Convolutional Neural Networks ถึงมีความสำคัญกว่าเครือข่ายประสาทเทียมแบบดั้งเดิมที่มีการนำมาใช้ในบริษัทที่ทำงานร่วมกับคอมพิวเตอร์ สามารถสรุปเหตุผลหลักได้ดังนี้

1. เหตุผลหลักประการแรกคือ คุณลักษณะการแบ่งน้ำหนักของ CNN ซึ่งลดจำนวนพารามิเตอร์ที่ฝึกอบรมหรือเรียนรู้ได้ในเครือข่าย ซึ่งช่วยให้แบบจำลองสามารถทำงานได้เร็วขึ้นและสามารถปรับปรุงลักษณะทั่วไปได้

2. ใน CNN เลเยอร์การจำแนกประเภทและเลเยอร์การแยกคุณลักษณะจะสามารถเรียนรู้ร่วมกันได้ ซึ่งทำให้ผลหรือเอาต์พุตของแบบจำลองมีการจัดระเบียบมากขึ้น และทำให้ผลที่ได้ขึ้นอยู่กับคุณสมบัติที่แยกออกมามากขึ้น

3. การใช้งานเครือข่ายขนาดใหญ่ทำได้ยากกว่า โดยใช้เครือข่ายประสาทเทียมประเภทอื่น ๆ แทนที่จะใช้ Convolution Neural Networks

จากที่กล่าวข้างต้น โดยหลักการทำงานของ CNN นั้นจะต้องอาศัยพื้นฐานของการทำงานโครงข่ายประสาทที่เชื่อมต่อกัน หรือเรียกว่าโครงข่ายประสาทเทียม การสร้างการเรียนรู้ในคอมพิวเตอร์โดยใช้การเลียนแบบการทำงานของสมองมนุษย์ ประกอบด้วยเซลล์ประสาท (Neuron) และแต่ละเซลล์จะถูกเชื่อมโยงกันเป็นโครงข่าย ซึ่งใน Neuron จะเรียกว่า โหนด (Node) และแต่ละโหนดจะถูกแบ่งออกเป็นชั้น (Layer) ดังภาพที่ 2.35

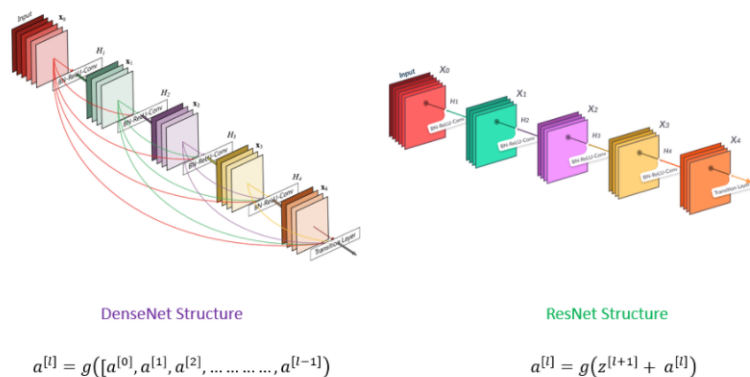


ภาพที่ 2.35 สถาปัตยกรรม CNN

ที่มา <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

งานที่นำ CNN มาใช้ในการแก้ปัญหาด้านการจำแนกประเภท (Classification) ที่เป็นรูปภาพ ซึ่ง CNN จะจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นพื้นที่ย่อย ๆ และนำกลุ่มของพื้นที่ย่อย ๆ มาผสมกัน เพื่อดูว่าสิ่งที่เห็นอยู่คืออะไร และทำการแยกคุณลักษณะของสิ่งที่มองอยู่ (Feature extraction) เช่น ลายเส้น และการตัดกันของสี ซึ่งการที่รู้ว่าพื้นที่ตรงนี้เป็นเส้นตรงหรือสีตัดกันจะดูทั้งจุดที่สนใจและบริเวณรอบ ๆ ประกอบกับ ในส่วนของ Hidden layer เป็นส่วนที่สอน Model ให้เรียนรู้ และทำการแยกคุณลักษณะของข้อมูล (Feature extraction) โมเดลที่ใช้ในงานวิจัยนี้ผู้วิจัยเลือกใช้จำนวน 4 โมเดล มีรายละเอียดดังนี้


1. DensNet201 (Dense Convolutional Network) เป็นการคิดค้นร่วมกันของ Cornwell University, Tsinghua University และ Facebook AI Research (FAIR) และได้รับรางวัล Best Paper Award ด้วยการอ้างอิงมากกว่า 2,000 รายการ [74] DenseNet เป็นหนึ่งในการค้นพบใหม่ในเครือข่ายประสาทเทียมสำหรับการจดจำวัตถุที่มองเห็น DenseNet ค่อนข้างคล้ายกับ ResNet โดยมีความแตกต่างพื้นฐานบางประการ ResNet ใช้วิธีการเพิ่มเติม (+) ที่รวมเลเยอร์ก่อนหน้า (เอกลักษณ์) กับเลเยอร์ในอนาคต ในขณะที่ DenseNet เชื่อม (.) เอาต์พุตของเลเยอร์ก่อนหน้ากับเลเยอร์ในอนาคต ได้รับความรู้เชิงลึกเกี่ยวกับ ResNet [75] ดังแสดงในภาพที่ 2.36



ภาพที่ 2.36 สถาปัตยกรรม DensNet และ ResNet  
ที่มา : <https://www.jeremyjordan.me/convnet-architectures/>

โดยการทำงานของ DenseNet เอาต์พุตของเลเยอร์ก่อนหน้าทำหน้าที่เป็นอินพุตของเลเยอร์ที่สอง โดยใช้การทำงานของฟังก์ชันคอมโพสิต การดำเนินการแบบผสมนี้ประกอบด้วย convolution layer, pooling layer, batch normalization, and non-linear activation layer การเชื่อมต่อเหล่านี้หมายความว่าเครือข่ายมีการเชื่อมต่อโดยตรง  $L(L+1)/2$  ซึ่ง  $L$  คือจำนวนชั้นในสถาปัตยกรรม DenseNet มีเวอร์ชันต่างๆ เช่น DenseNet-121, DenseNet-160, DenseNet-201 เป็นต้น ตัวเลขแสดงถึงจำนวนเลเยอร์ในโครงข่ายประสาทเทียม

2. ResNet50 (Deep Residual Network) ได้รับการนำเสนอครั้งแรกในงานวิจัยชื่อ Deep Residual Learning for Image Recognition ได้รับการอ้างอิง 96,000 ครั้ง นำเสนอวิธีการแก้ปัญหาเรื่อง Vanishing gradient ซึ่งเกิดขึ้นกับโครงข่ายที่มีความลึกค่อนข้างมาก ด้วยการใส่ทางลัด (shortcut) ลงในโครงข่าย [75] ดังแสดงในภาพที่ 2.37



ภาพที่ 2.37 สถาปัตยกรรม ResNet50  
ที่มา : <https://iq.opengenus.org/resnet50-architecture/>

3. InceptionV3 (1st ILSVRC-2015) ถูกกล่าวถึงในงานวิจัย Christian Szegedy และคณะ [76] ซึ่งเป็นโมเดลที่ได้รับการ พัฒนาโดย Google ซึ่งถูกต่อยอดจาก Inception2,1 (ซึ่งมาจากการพัฒนามาจาก GoogLeNet2012) โดยการลดโครงสร้างภายในออกเป็น 5 Step คือ Inception

Module A จำนวน 5 Module

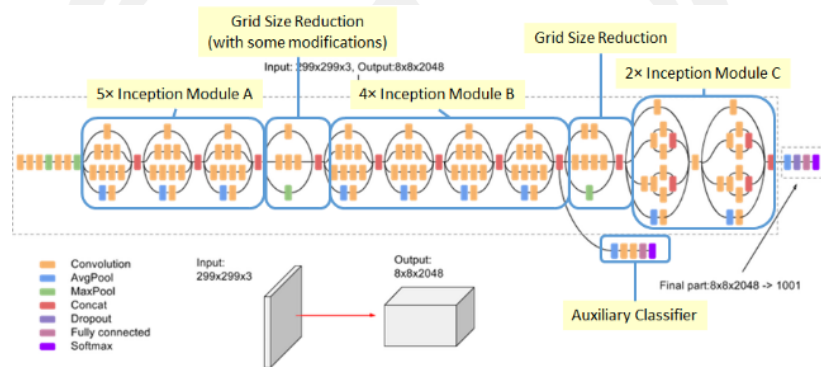
(1) Grid Size of Reduction Step1 จำนวน 1 Module

(2) Inception Module B จำนวน 4 Module

(3) Grid Size of Reduction Step2 จำนวน 1 Module

(4) Inception Module C จำนวน 2 Module

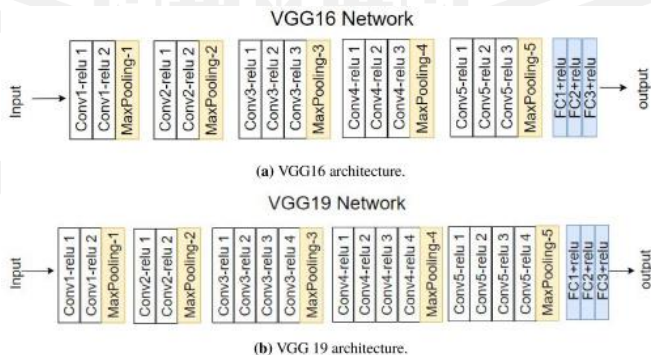
(5) Head (8x8x2048) สามารถแยก output ได้ 1,000 classes ดังในภาพที่ 2.38



ภาพที่ 2.38 สถาปัตยกรรม Inception  
ที่มา : [76]

พัฒนาให้ Inception-v3 มี parameter ลดลงจากเดิม แต่ยังคงมีประสิทธิภาพสูงโดยการปรับปรุง convolutions เดิมที่ 5x5 ลงเหลือ 3x3 pixels และ maxpooling เดิมที่ 3x3 ลงเหลือ 2x2 pixels

4. VGGNet [77] ย่อมาจาก Visual Geometry Group เป็นสถาปัตยกรรม Convolutional Neural Network ที่เสนอโดย Karen Simonyan และ Andrew Zisserman จาก University of Oxford ในปี 2014 VGG19 เป็นรุ่นที่แตกต่างจากรุ่น VGG ซึ่งโดยย่อประกอบด้วย 19 ชั้น (16 convolution layers, 3 Fully connected layer, 5 MaxPool layers and 1 SoftMax layer) ซึ่งการทำงานของ VGG นั้น จะเป็น CNN ระดับลึกที่ใช้ในการจำแนกรูปภาพ [78] ดังในภาพที่ 2.39



ภาพที่ 2.39 สถาปัตยกรรม VGG19 network model  
ที่มา : [79]

สำหรับส่วนประกอบพื้นฐานต่าง ๆ ของ CNN ผู้วิจัยได้นำเนื้อหาที่ได้ศึกษาสรุปโดยสังเขปมีรายละเอียดดังนี้

Network Layers อย่างที่ทราบแล้วว่า CNN นั้นประกอบด้วยหลายส่วนคือ สถาปัตยกรรมชั้นการทำงานแต่ละส่วนซึ่งจะอธิบายในรายละเอียดต่อไปนี้ ซึ่งเป็นสถาปัตยกรรมของ CNN



1. Convolution Layer เป็นชั้นที่ดำเนินการเกี่ยวกับการนำข้อมูลภาพไปประมวลผลกับชุดของ Convolution Filters ซึ่งจะได้ Features บางอย่างออกมาจากชุดข้อมูลภาพ กล่าวคือ ทำการแยกองค์ประกอบของรูปร่าง เช่น ขอบ สี รูปร่าง เป็นต้น โดยที่ CNN จะมีตัวกรองหรือ Filter ในการตรวจสอบเพื่อแยกองค์ประกอบของรูป

1.1 Kernel คือ เส้นที่วางเป็นตารางใช้ในการทำงานเพื่อกำหนดขอบเขตของน้ำหนักภาพหรือเรียกว่าน้ำหนักของคอร์เนล ซึ่งจะทำงานระหว่างเริ่มต้นการทำงานของขั้นตอนข้อมูลหรือเรียนรู้ข้อมูล โดยในการดึงน้ำหนักของภาพจะเป็นการคูณตัวเลข ด้วยวิธีการที่แตกต่างกัน สำหรับการเริ่มต้นหาค่าน้ำหนัก จากนั้นในแต่ละช่วงการฝึกอบรมน้ำหนักจะถูกปรับและคอร์เนลการเรียนรู้จะทำการดึงคุณสมบัติที่มีความหมายออกมาดังภาพที่ 2.40

0	1
-1	2

ภาพที่ 2.40 ตัวอย่างขนาดของคอร์เนล 2x2 Kernel

1.2 Convolution operation ก่อนที่จะทำความเข้าใจในรายละเอียด จะขออธิบายรูปแบบการป้อนข้อมูลของ CNN ก่อน ซึ่งแตกต่างจากเครือข่ายประสาทแบบดั้งเดิม โดยที่ข้อมูลนำเข้าอยู่ในรูปแบบเวกเตอร์ใน CNN ข้อมูลนำเข้าเป็นภาพหลายแบบ เช่น ภาพ RGB จะแบบชั้นข้อมูลได้ 3 ระดับ คือ สีแดง สีเขียว และสีน้ำเงิน ซึ่งภาพแต่ละภาพจะเกิดจากการผสมสีของสีทั้ง 3 ระดับนี้ และภาพระดับสีเทาจะเป็นภาพเดียวโดยจะเป็นสีขาวและสีดำ



ภาพที่ 2.41 ตัวอย่างภาพ RGB

เพื่อทำความเข้าใจเกี่ยวกับการดำเนินการ Convolution ถ้าใช้ภาพสีเทาขนาด  $4 \times 4$  ดังแสดงในภาพที่ 2.42 และคอร์เนลขนาด  $2 \times 2$  มีน้ำหนักเริ่มต้นแบบสุ่มดังแสดงในภาพที่ 2.44

1	0	-2	1
-1	0	1	2
0	2	1	0
1	0	0	1

ขนาดภาพสี่เทา 4x4

0	1
-1	2

ขนาดของเคอร์เนล 2x2

ภาพที่ 2.42 ภาพสี่เทาขนาด 4 x 4 และขนาดของเคอร์เนล ขนาด 2 x 2

ที่มา : [65]

ในการดำเนินการ Convolution จะนำเคอร์เนล 2x2 เลื่อนไปบนภาพขนาด 4x4 ในแนวนอนและแนวตั้ง และนำเคอร์เนลไปคูณในช่องที่ตรงกันโดยการนำไปทาบกับขนาดของภาพแต่ละช่อง จากนั้นทำการเลื่อนไปที่ละเคอร์เนลจนครบภาพ และสิ่งที่ได้นั้นเรียกว่า ฟีเจอร์ลักษณะ (Feature map)

Step-1

1	0	-2	1
-1	0	1	2
0	2	1	0
1	0	0	1

⊗

0	1
-1	2

→

1			

Step-2

1	0	-2	1
-1	0	1	2
0	2	1	0
1	0	0	1

⊗

0	1
-1	2

→

1	0		

Step-3

1	0	-2	1
-1	0	1	2
0	2	1	0
1	0	0	1

⊗

0	1
-1	2

→

1	0	4	

Step-4

1	0	-2	1
-1	0	1	2
0	2	1	0
1	0	0	1

⊗

0	1
-1	2

→

1	0	4	
4			

Step-5

1	0	-2	1
-1	0	1	2
0	2	1	0
1	0	0	1

⊗

0	1
-1	2

→

1	0	4	
4	1		

ภาพที่ 2.43 ตัวอย่างขั้นตอนในการทำ Convolution

ที่มา : [65]

หลังจากดำเนินการทำ Convolution เรียบร้อยแล้วจะได้คุณสมบัตินี้สุดท้ายดังภาพที่ 2.44

1	0	4
4	1	1
1	1	2

ภาพที่ 2.44 ตารางคุณลักษณะผลลัพธ์ที่ได้หลังจากการดำเนินการ Convolution สมบูรณ์

ที่มา : [65]



จากในตัวอย่างนี้เป็นการดำเนินการผ่านขั้นตอนการทำ Convolution โดยที่ไม่ผ่านช่องว่างใด ๆ ในรูปภาพ ซึ่งในการขยับช่องของคอร์เนลหรือขั้นตอนการเลื่อน เรียกว่า Strides value เป็นตัวกำหนดว่าจะทำการเลื่อนตัวกรอง (Filter) ไปด้วย Step เท่าไหร่ ซึ่งโดยทั่วไปแล้วจะกำหนด Stride เท่ากับ 1 และ Padding เป็นการขยับขอบภาพที่นำเข้าไปเพื่อเป็นการหาลักษณะของภาพที่อาจจะอยู่ขอบภาพได้ดีขึ้น โดยใช้ค่า 0 รอบให้ภาพขอบ ๆ ได้ ซึ่งเรียกว่า zero padding ซึ่งในการหาขนาดของช่องเพื่อหาคุณลักษณะของภาพเอาต์พุตหลังจากดำเนินการ Convolution มีสมการดังนี้

$$h' = \left[ \frac{(h - f + p)}{s} + 1 \right] \quad (2.1)$$


$$w' = \left[ \frac{(w - f + p)}{s} + 1 \right] \quad (2.2)$$

โดยที่  $h'$  คือ ความสูงของช่องภาพผลลัพธ์ที่ได้  
 $w'$  คือ ความกว้างของช่องภาพผลลัพธ์ที่ได้  
 $h$  คือ ความสูงของช่องภาพที่นำเข้าไป  
 $w$  คือ ความกว้างของช่องภาพที่นำเข้าไป  
 $f$  คือ ขนาดของ filter หรือ Kernel sizer  
 $p$  คือ Padding  
 $s$  คือ Stride

2. Detector Layer คือ ส่วนที่รับข้อมูลส่งออก (Output) ที่มาจากข้อที่ 1 และแปลงให้อยู่ในรูปของ “Nonlinear” และเป็นส่วนที่ต้องระบุ “อัลกอริทึม” (Activation) ที่จะใช้ในการจำแนกคุณลักษณะของข้อมูล ซึ่งหลังจากนั้นสามารถสร้างโมเดลแบบพื้นฐานแล้ว จะต้องมีการสำรวจปัญหาต่าง ๆ ในการเทรน Neural network และแนวทางแก้ไขนั่นคือปัญหาการไล่ระดับสีที่หายไป (Vanishing gradients) ในการเรียนรู้ (Tran) Deep neural network ซึ่งอาจพบว่า โมเดล Tran จบแล้วได้ค่า Loss ที่ต่ำที่สุด แต่ไม่ต่ำเท่าที่ควร หมายความว่า เกิดปัญหา Bias ทั้ง ๆ ที่มีการวางโครงสร้างชั้น (Layers), จำนวนโนนด (Neuron) และจำนวนรายการเนื้อหาที่เหมาะสมเพียงพอแล้ว ซึ่งหากเกิดปัญหา Vanishing gradients มีแนวทางแก้ไขดังนี้ 1). การเปลี่ยนวิธีการตั้งค่าตั้งต้นของ Parameter 2). การเปลี่ยน Activation function 3). การใช้เทคนิค Batch normalization ซึ่งอธิบาย Activation function ในหัวข้อถัดไป


3. Pooling Layer เป็นเลเยอร์ที่ใช้ในการย่อขนาดของภาพที่ผ่านการดำเนินการ Convolution แล้ว ซึ่งจะทำให้การย่อขนาดของภาพลงแต่ยังรักษาความโดดเด่นของข้อมูลภาพนั้นไว้ โดยการทำให้ Pooling นั้นมีหลายวิธีแต่นิยมมากที่สุดคือ การหาค่าที่มากที่สุดเรียกว่า Max Pooling ซึ่งใช้เทคนิคการรวมกลุ่ม แต่ข้อเสียที่พบคือบางครั้งประสิทธิภาพโดยรวมของ CNN อาจลดลง ซึ่ง

เลเยอร์การรวมกลุ่มช่วยให้ CNN ค้นหาคุณลักษณะเฉพาะของภาพที่กำหนดได้หรือไม่สนใจตำแหน่งที่ถูกต้องของคุณลักษณะนั้น



ภาพที่ 2.45 ตัวอย่างการทำ Pooling  
ที่มา : [65]

4. Fully Connected Layer (FC) เป็นการนำผลลัพธ์ที่ได้จากขั้นตอนการทำคอนโวลูชันเลเยอร์และการทำพูลิงเลเยอร์ โดยทำการแผ่ออก (Flatten) จาก 2 มิติเป็น 1 มิติ ซึ่งข้อมูลจะเชื่อมต่อกันทั้งหมด ก่อนที่จะนำไปเข้าสู่ขั้นตอนการจำแนก หรือกล่าวอีกได้ว่า Fully connected layer คือ Hidden layer และ Output layer ของโครงข่ายประสาทเทียมซึ่งทำหน้าที่ในการเรียนรู้ (Train) และจำแนกประเภทของวัตถุ โดยผลลัพธ์ที่ได้คือจำนวนของเฉลี่ย (Class) ที่ต้องการจำแนก โดยใช้เทคนิคในการจัดประเภทคือ ซอฟต์แม็กซ์ (Softmax)



ภาพที่ 2.46 การจำแนกคำตอบด้วย Fully connected layer  
ที่มา : <https://towardsdatascience.com/>

## 2.10 Mask R-CNN

Mask R-CNN [80-83] เป็น Framework ที่สามารถทำการแบ่งกลุ่มตัวอย่างแบบวัตถุ (Object instance segmentation) ซึ่งถูกออกแบบมาสำหรับตรวจจับวัตถุได้อย่างยืดหยุ่น โดยสร้างจาก Python และ Keras (Neural Network API) ซึ่ง Mask R-CNN นั้นมีความสามารถในการระบุชั้น (class) ในระดับแต่ละกรณีพื้นฐาน (Instance-based) เช่น คน1,คน2, คน3,... แล้วแต่ว่าแต่ละ class จะมีกี่กรณี (Instance) อยู่ในภาพ เป็นวิธีการของการตรวจจับวัตถุในภาพได้อย่างมีประสิทธิภาพ และขณะเดียวกันสามารถสร้างมาสก์ (Mask) การแบ่งส่วนคุณภาพสำหรับแต่ละ instance พร้อมกัน โมเดล Mask R-CNN เหมือนเป็นการรวม Faster R-CNN และ FCN (Fully Convolutional Network) เข้าไว้ด้วยกัน ซึ่ง Mask R-CNN ใช้ Faster R-CNN เป็นพื้นฐาน และนำ FCN มาเพิ่มเติมสามารถอธิบายได้ดังภาพที่ 2.47

ใน CVPR2014 Girshick และคณะ [84] เสนอวิธีชื่อ R-CNN (Regions with CNN features) ที่นำ CNN มาต่อยอดช่วยงานด้านตรวจหาวัตถุ (Object detection) แต่มีปัญหา คือ งานด้าน detection สิ่งที่ต้องการหาบางครั้งอาจไม่มีปรากฏในภาพเลย หรือ บางครั้งอาจปรากฏขึ้นมาพร้อมกันครั้งเดียวหลายอันและแต่ละอันอยู่คนละมุมในภาพ อีกทั้งยังมีขนาดเล็กบ้างใหญ่บ้างต่าง ๆ กันลักษณะส่วนขยายภาพ (Image classifier) อย่างเดียวไม่เพียงพอ ดังนั้นจึงได้นำ R-CNN เพิ่มส่วนการทำค้นหาบริเวณภาพ (Region proposals) ที่ทำหน้าที่เสนอ ROI (Region of interest) เป็นกรอบสี่เหลี่ยมมุมฉากหลายขนาด (Size) หลายตำแหน่งขึ้นมา จำนวน 2000 อันต่อ 1 ภาพนำเข้า (Input) ภาพนำเข้าต้นฉบับจะถูกครอบตัด (Crop) ด้วย ROI ก่อนที่จะถูกส่งต่อไปยัง CNN เพื่อทำแยกคุณลักษณะของภาพ (Feature extraction) และได้คุณลักษณะเวกเตอร์ (Feature vector) ขนาด 4096 ช่อง จากนั้นสุดท้ายใช้ SVM (Support Vector Machine) ทำการจำแนก (Classification) เพื่อดูเฉพาะส่วนที่ถูกครอบตัดออกมา คือ วัตถุ (Object) ที่อยู่ในคลาส (Class) ไດหรือไม่ และสำหรับ Bounding box regression เป็นการปรับเพิ่มความแม่นยำให้กับตำแหน่งจุด 4 มุมของ ROI ให้มากขึ้น

แนวคิดนี้ทำให้ภาพหนึ่งภาพมีวัตถุอยู่ที่คลาส แต่ละวัตถุจะหลบอยู่มุมไหนของภาพ หรือมีขนาดใหญ่เล็กเพียงใดก็ตาม ก็สามารถสร้าง ROI ครอบและ crop เฉพาะส่วนของ object นั้น ๆ เพื่อส่งภาพที่ crop ได้เข้าสู่ขั้นตอนการทำคอนโวลูชันเนี่ยลรอนเน็ตเวิร์ค CNN และ SVM ช่วยกันทำ image classifier ต่อได้


ข้อเสียของ R-CNN คือ 1.) จำนวน ROI เยอะมาก (1 ภาพมี 2000 ROI) 2.) ส่วน CNN feature extraction ของแต่ละ ROI ก็ทำงานซ้ำซ้อน overlap กัน 3.) มีโมเดลแยกกันอยู่หลายส่วน ทำ end-to-end training ครั้งเดียวไม่ได้

ต่อมาในปี 2015 Girshick และคณะ [85] โมเดล Fast R-CNN ถูกเสนอเพื่อแก้ปัญหาที่เกิดขึ้นในปี 2014 โดยนอกจากรวบรวมทุกส่วนให้กลายเป็น 1 network (ทำ end-to-end training สำเร็จ) ยังเพิ่ม ROI Pooling โดยทำ feature extraction ด้วย CNN กับอินพุตทั้งภาพแค่รอบเดียว จากนั้น ROI ตัวใดที่ต้องการ feature เฉพาะบริเวณไหนในภาพเพื่อนำไปใช้ค่อยนำมาเลือกไปจาก

feature ส่วนกลางนี้ ดังนั้นการที่จะต้องรัน CNN 2000 ครั้งต่อภาพ จะเหลือรันเพียงครั้งเดียว จากนั้นทำการแชร์ feature กันใช้ได้ ในการทดลอง Fast R-CNN ใช้เวลาทำงานต่อภาพเพียง 2.3 วินาที (sec.) ในขณะที่ R-CNN ใช้เวลาถึง 49 วินาที (sec.)

ในปี 2016 Kaiming He. และคณะ [86] ได้มีการแก้ปัญหา Faster R-CNN ในส่วน Region proposals ที่ยังไม่มีมีการแก้ไข โดยนอกจากส่วนนี้จะผลให้เกิดความล่าช้าเป็นลักษณะคอขวด การคำนวณแล้ว ยังเป็น fixed algo ที่ไม่สามารถเรียนรู้อะไรได้และไม่มีการเรียนรู้ว่าภาพแบบใดควรเสนอ ROI ต่างกันอย่างไร เดิม Region proposals (แยกกันอยู่กับส่วน CNN) จะคัดเลือก ROI ด้วยวิธี Selective search (IJCV2012) ซึ่งเป็นวิธีที่ช้า ดังนั้นจึงใช้วิธี segmentation เพื่อหา initial candidate regions แล้วค่อย ๆ นำมาทำ greedy grouping รวม region ที่คล้ายกันไปเรื่อย ๆ จากนั้นจึงสรุป hierarchy of bounding boxes ออกมา การจัดการเปลี่ยน Region proposals เดิเป็น Region proposal network (RPN) ที่เป็นส่วนเพิ่มซึ่งแชร์ feature จาก CNN (ที่มีอยู่แล้ว) มาใช้คำนวณหาการสร้าง ROI ขึ้นที่ส่วนใดในภาพบ้าง โดยส่วนเพิ่มของ RPN ที่ขอใช้ CNN ตัวกลางร่วมด้วยนี้ไม่สามารถทำให้เวลาการคำนวณเพิ่มขึ้นจาก CNN เดิม สำหรับในการทดลองต่อ 1 ภาพ R-CNN ใช้เวลาทำงาน 49 วินาที, Fast R-CNN ใช้ 2.3 วินาที, Faster R-CNN ใช้ 0.2 วินาที และในขั้นตอนการทำ Fast R-CNN นั้น ได้ใช้ภาพหนึ่งภาพในการทำเข้าซึ่งจะได้ผลลัพธ์ 2 ขา คือ ขาแรกจะบอกพิกัด 4 จุดของกรอบ ROI และขาที่สองจะบอกถึง class label ของ ROI

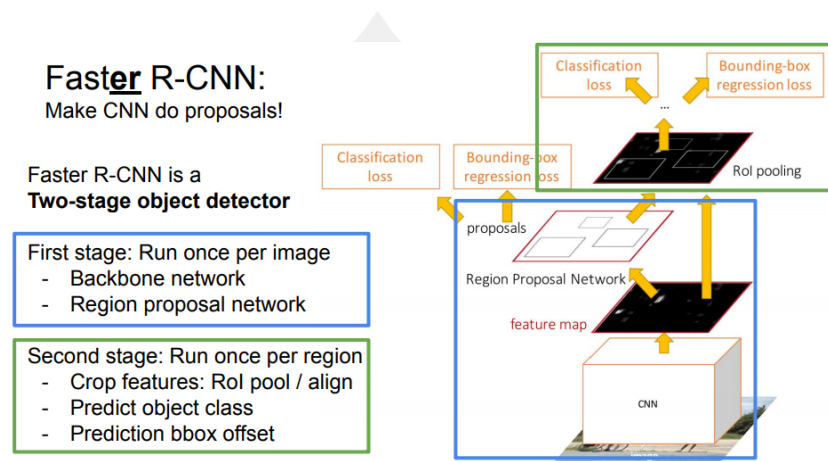
ต่อมาในปี 2017 ทีมวิจัยจาก Facebook AI Research (FAIR) [80] ได้นำ Fast R-CNN เพิ่มในส่วนผลลัพธ์ขาที่สาม คือ ทำหน้าที่สร้าง Mask image ขนาด  $15 \times 15$  พิกเซล (pixel) จำนวน K อัน ( $K =$  จำนวน class ทั้งหมด) ขึ้นให้กับแต่ละ ROI หากมีการใช้งานจะทำการ resize mask จาก  $15 \times 15$  พิกเซล ให้มีขนาดใหญ่และกลับเป็นขนาดเดิมของ ROI นั้น ๆ ซึ่งนอกจากจะทำ ROI Pooling แล้วจะต้องทำ ROI Align เพิ่มเติม เนื่องจากเมื่อนำภาพขนาดใหญ่จะถูก CNN ลดขนาดให้มีขนาดเล็กลง เช่น จากภาพนำเข้ามีขนาด  $128 \times 128$  ลดขนาดเหลือ mask ขนาด  $15 \times 15$  ซึ่งอาจทำให้บางพิกเซลที่หารตำแหน่งไม่ลงตัว (ก้ำกึ่ง) คือภาพใน mask พิกเซลควรจะถูกจัดให้อยู่เป็นส่วนหนึ่งของ object หรือไม่ ดังนั้นจึงต้องนำ ROI Align มาใช้งานเพิ่มเติมด้วย



ภาพที่ 2.47 โมเดล Mask R-CNN

ที่มา : [http://cs231n.stanford.edu/slides/2017/cs231n\\_2017\\_lecture11.pdf](http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture11.pdf)

## 1. Faster R-CNN เป็นโมเดลที่พัฒนาต่อเนื่องมาจาก R-CNN และ Fast R-CNN



ภาพที่ 2.48 Faster R-CNN

ที่มา : [http://cs231n.stanford.edu/slides/2017/cs231n\\_2017\\_lecture11.pdf](http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture11.pdf)

การทำ object detection ตระกูล R-CNN เรียกว่า two-stage detection มีการแบ่งการประมวลผลเป็นสองขั้นตอน ดังนี้

ขั้นตอนแรก (first stage) เป็นการหาขอบเขต (Region หรือ Bounding box) ที่มีวัตถุอยู่ เพื่อจะส่งเข้าสู่ขั้นตอนที่สองต่อไป ในขั้นตอนนี้จะมีส่วนประกอบที่สำคัญคือ

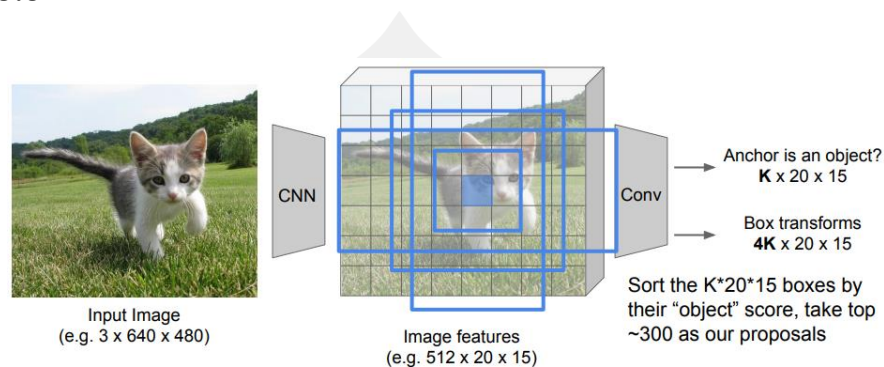
1. backbone network เป็น neural network ที่รับรูปภาพ input และประมวลผลจนได้เป็น feature map ออกมา โดย backbone network จะใช้ architecture สำหรับงาน computer vision แบบใดก็ได้ เช่น ResNet หรือ ResNeXt หรือถ้าใช้ Feature Pyramid รวมด้วย ก็จะทำให้ได้ความถูกต้องที่สูงขึ้น

2. region proposal network เป็น neural network ที่ทำ classification เพื่อจำแนกว่าขอบเขตไหนที่น่าจะมีวัตถุอยู่ รวมทั้งมีการทำ regression เพื่อที่จะได้ขอบเขตที่แม่นยำขึ้น สำหรับ region proposal network นี้เอง เป็นสิ่งที่ทำให้ Faster R-CNN แตกต่างจาก R-CNN ที่ผ่านมา ซึ่งใช้ region proposal algorithm ภายนอก อย่าง Selective Search เข้ามาช่วย

ขอบเขตที่ region proposal network นำมาพิจารณา (อาจเรียกว่า anchor box) คือกล่องสี่เหลี่ยมหลายๆ ขนาด ที่ครอบคลุม feature map ในตำแหน่งต่าง ๆ ดังเช่นรูปด้านล่างนี้แสดงตัวอย่างการทำงานของขั้นตอนแรก เมื่อรูปแอมเวียมขนาด 640x480 ผ่าน CNN ที่เป็น backbone network เข้ามา จะได้ feature map ขนาด 20x15 และมีจำนวน channel เท่ากับ 512

กำหนดให้แต่ละจุดของ feature map มี anchor box จำนวน K ขนาด จะได้ว่ามีจำนวน anchor box ที่ต้องพิจารณาทั้งหมดเท่ากับ  $K \times 20 \times 15$  และในจำนวน anchor box ทั้งหมดนี้ ในส่วนของ region proposal network ก็จะทำการศึกษาขอบเขตที่น่าจะเป็น object มากที่สุดมา

จำนวนหนึ่ง เช่น 300 ขอบเขต เพื่อส่งเป็น region proposal หรือ RoI (Region of Interest) สำหรับขั้นตอนต่อไป



ภาพที่ 2.49 region proposal network


ที่มา : [http://cs231n.stanford.edu/slides/2017/cs231n\\_2017\\_lecture11.pdf](http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture11.pdf)

ขั้นตอนที่สอง (second stage) ประกอบด้วยกระบวนการต่าง ๆ ดังนี้

1. RoI Pool เป็นการทำ RoI ของ feature map ที่มีขนาดแตกต่างกัน ให้มีขนาดเดียวกัน เพื่อเป็น input ให้กับ neural network ในขั้นตอนต่อไป โดย RoI Pool จะใช้ max pooling เลย แต่ Mask R-CNN จะเปลี่ยนขั้นตอนนี้เป็น RoI Align ซึ่งจะกล่าวถึงในหัวข้อถัดไป

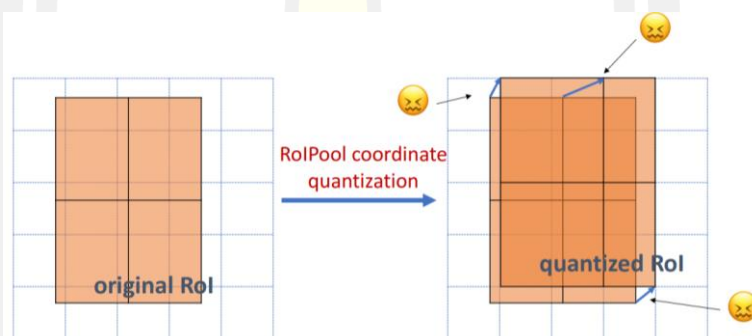
2. ส่วนสุดท้ายจะเป็นหัว classification ที่ทำการจำแนกว่าเป็น object คลาสอะไร (หัว class) และหัว regression ที่ทำการปรับขอบเขตของ RoI ให้แม่นยำขึ้น (หัว box)

2. Fully Convolutional Network (FCN) สำหรับ FCN เป็น neural network ที่มีลักษณะดังภาพที่ 2.50 โดยจะรับ input เข้ามาเป็นรูปภาพ และให้ output เป็นการจำแนกคลาสของแต่ละ pixel ในรูปภาพ โดย feature map ของแต่ละ layer จะมีขนาดเล็กลงเรื่อย ๆ (down sampling) จนถึงตรงกลาง แล้วค่อยขยายให้ใหญ่ขึ้น (up sampling) ที่เป็นเช่นนี้เพราะว่า ถ้าทำ convolution ขนาดเดียวกันกับรูปภาพทั้งหมด จะสิ้นเปลืองการคำนวณมาก นอกจากนี้ยังมีเหตุผลเช่นเดียวกับการทำ Autoencoder นั่นคือในส่วนของ down sampling จะช่วยคัดกรองข้อมูลที่สำคัญเกี่ยวกับความหมายของรูปภาพออกมา (what part) ก่อนที่จะทำการ up sampling เพื่อเก็บรายละเอียดเกี่ยวกับตำแหน่งให้แม่นยำขึ้น (where part) นอกจากนี้จะมี skip connection เพื่อรักษาข้อมูลไม่ให้สูญหายในขั้น down sampling ด้วย



ภาพที่ 2.50 การแบ่งส่วนภาพด้วย Fully convolution Netowors  
 ที่มา : [http://cs231n.stanford.edu/slides/2017/cs231n\\_2017\\_lecture11.pdf](http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture11.pdf)

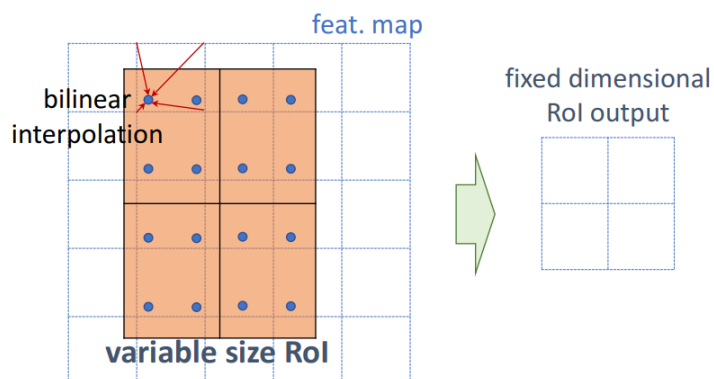
3. Roi Align ในกรณีที่ Roi ของรูปภาพ input ไม่ตรงกับ grid ของ feature map ถ้าใช้ Roi Pool ธรรมดา จะต้องทำการเลื่อนให้ Roi มาอยู่ตรงกับ grid ซึ่งตรงนี้เองที่ทำให้มีความคลาดเคลื่อนของตำแหน่งเกิดขึ้นได้ ดังภาพที่ 2.51



ภาพที่ 2.51 ROI Pool

ที่มา : <https://www.youtube.com/watch?v=nDPWywWRIRo>


Roi Align แก้ปัญหาของ Roi Pool โดยวิธีการที่แสดงดังตัวอย่างในภาพที่ 2.52 เช่นเมื่อมี feature map ขนาด 5x5 และ Roi คือสี่เหลี่ยมใหญ่สีส้ม ถ้าต้องการให้ feature map ของ Roi นี้เหลือขนาด 2x2 ก็ทำการแบ่ง Roi ตั้งต้นเป็นสี่ส่วนเท่าๆ กัน แล้วกำหนดจุดภายในขึ้นมาสี่จุดในแต่ละส่วน และคำนวณค่า feature ของจุดทั้งหมด โดยใช้ bilinear interpolation จากค่า feature จริงที่อยู่ใกล้เคียง จากนั้นจึงทำ max pooling ในแต่ละส่วน ก็จะได้ feature map ขนาด 2x2 ตามที่ต้องการ



ภาพที่ 2.52 RoI Align

ที่มา : <https://www.youtube.com/watch?v=nDPWywWRIRo>

4. Mask Head นอกจาก RoI Align แล้ว สิ่งที่ทำให้ Mask R-CNN ต่างจาก Faster R-CNN ก็คือการเพิ่มหัว mask เข้ามา จากหัว class และหัว box ที่มีอยู่เดิม เพื่อทำหน้าที่ทำนาย mask ที่อยู่ภายใน RoI ของทุกคลาส ดังรูปด้านล่าง โดยในรูปนี้เป็นการแสดงหัว mask มีขนาด  $28 \times 28$  และมี 80 คลาส



ภาพที่ 2.53 Mask Head

ที่มา : [http://cs231n.stanford.edu/slides/2017/cs231n\\_2017\\_lecture11.pdf](http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture11.pdf)

หลังจากนั้นจะทำการปรับสเกลของ mask ให้มีขนาดเท่ากับ RoI ของรูปต้นฉบับ เพื่อเป็น output สำหรับส่วนของการ segmentation ดังภาพที่ 2.54





ภาพที่ 2.54 Final mask

ที่มา : <https://www.youtube.com/watch?v=nDPWywWRIRo>

### 2.11 การประเมินผล

สำหรับงานวิจัยนี้มีการประเมินผลโมเดลการเรียนรู้เชิงลึกและการประเมินการทำ Mask R-CNN มีรายละเอียดดังนี้

#### 1. ประเมินผลโมเดล

การประเมินผลจะเป็นการประเมินในส่วนของความแม่นยำและความถูกต้องในการค้นหาโรคหรือเชื้อจากภาพ แต่สำหรับเบื้องต้นนี้ในงานวิจัยนี้จะทำการประเมินตาราง Confusion matrix [87-89] เพื่อค้นหาค่าที่ดีที่สุดในทุกค่า คือ (1) ค่าความแม่นยำ (Precision : P) เป็นค่าที่บอกว่าโปรแกรมทำนายว่าจริงถูกต้องเท่าไร (2) การวัดค่าความระลึก (Recall : R) เป็นค่าที่บอกว่าโปรแกรมทำนายได้ว่าจริง มีอัตราส่วนเท่าไรกับค่าจริงทั้งหมด (3) ค่าเฉลี่ยประสิทธิภาพโดยรวม (F-measure : F1) เป็นการวัดค่าความถูกต้องการทดสอบที่พิจารณาทั้งความแม่นยำ และค่าความระลึกพร้อมกัน และ (4) การวัดค่าความถูกต้อง (Accuracy : A) เป็นค่าที่บอกว่าโปรแกรมสามารถทำนายได้ถูกต้องมากน้อยเท่าไร จากตัววัดที่กล่าวข้างต้นนั้น สามารถแทนค่าเพื่ออธิบายได้ด้วยตาราง Confusion matrix เพื่อวัดประสิทธิภาพของโมเดล (Model) ที่นำมาใช้ในการทดลอง ซึ่งในที่นี้กำหนดให้คลาสมีค่าตอบ 2 คือ + และ - ดังนั้นตาราง Confusion matrix นี้โดยแสดงตารางขนาด 2x2 ดังแสดงในตารางที่ 2.6

ตารางที่ 2.6 ตาราง Confusion matrix

		Predicted	
		+	-
Actual	+	TP	FN (Type II error)
	-	FP (Type I error)	TN

จากตารางที่ 2.6 ค่าที่ปรากฏในแต่ละช่องนี้สามารถอธิบายได้ดังนี้

- True Positive (TP) คือ ค่าที่โปรแกรมทำนายว่าจริง และมนุษย์บอกว่าจริง
- True Negative (TN) คือ ค่าที่โปรแกรมทำนายว่าไม่จริง และมนุษย์บอกว่าไม่จริง
- False Positive (FP) คือ ค่าที่โปรแกรมทำนายว่าจริง และมนุษย์บอกว่าไม่จริง
- False Negative (FN) คือ ค่าที่โปรแกรมทำนายว่าไม่จริง แต่มนุษย์บอกว่าจริง

จากตารางที่ 2.6 สามารถเขียนเป็นสมการในการคำนวณค่าตัววัดประสิทธิภาพได้ดังนี้

- (1) Accuracy คือ ค่าที่บอกว่าโปรแกรมสามารถทำนายได้ถูกต้องเท่าไร

$$accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2.3)$$

- (2) Recall (True positive rate) คือ ค่าที่โปรแกรมทำนายได้ว่าจริง เป็นอัตราส่วนเท่าไรของค่าจริงทั้งหมด

$$recall = \frac{TP}{(TP + FN)} \quad (2.4)$$

- (3) True negative rate (TNR) คือ ค่าที่โปรแกรมทำนายได้ว่าไม่จริง เป็นอัตราส่วนเท่าไรของค่าจริงทั้งหมด

$$TRN = \frac{TN}{(TN + FP)} \quad (2.5)$$

- (4) False positive rate (FPR) คือ ค่าที่โปรแกรมทำนายว่าจริง เป็นอัตราส่วนเท่าไรของค่าไม่จริงทั้งหมด

$$FPR = \frac{FP}{(TN + FP)} \quad (2.6)$$

- (5) False Negative Rate (FNR) คือ ค่าที่โปรแกรมทำนายว่าไม่จริง เป็นอัตราส่วนเท่าไรของจริงทั้งหมด

$$FNR = \frac{FN}{(TP + FN)} \quad (2.7)$$

- (6) Precision คือ ค่าที่โปรแกรมทำนายว่าจริง ถูกต้องเท่าไร


$$precision = \frac{TP}{(TP + FP)} \quad (2.8)$$

(7) F-measure หรือ F1 คือ การวัดค่าความถูกต้องการทดสอบที่พิจารณาทั้งความแม่นยำ และค่าความระลึก พร้อมกัน

$$F1 = 2 \times \frac{\text{precision} \times \text{recall}}{(\text{precision} + \text{recall})} \quad (2.9)$$

## 2.การประเมินผล Mask R-CNN

การประเมินผล Mask R-CNN นั้นจะมีวิธีในการประเมินสองวิธีหลัก ๆ คือ หากประเมินผลความถูกต้องในการวัดความสอดคล้องของชุดข้อมูลสามารถใช้ IoU และหากมีความต้องการในการวัดประสิทธิภาพเพื่อหาค่าเฉลี่ยความแม่นยำจำของวัตถุต่าง ๆ ในภาพด้วยสามารถใช้ AP (Average precision) สำหรับงานวิจัยนี้ใช้ Intersection over union (IoU) [80-83] คือ วิธีทางสถิติที่ใช้วัดความสอดคล้องของข้อมูลสองชุดที่นิยมนำมาใช้งานด้าน Object detection ซึ่งหาได้จากอัตราส่วนระหว่างพื้นที่เป็นจุดตัด (Intersection) ของ 2 bounding box หารด้วยพื้นที่ (Area) รวมของกรอบทั้งสอง โดยวิธีการนี้เดิมใช้ชื่อ Jaccard Similarity Index เป็นวิธีการในการหาจำนวนเปอร์เซ็นต์ (Percent) ที่ทับซ้อนกัน ระหว่างผลทำนาย คือ P (Predicted) และผลเฉลย คือ G (Ground truth)

$$IoU(P, G) = \frac{|P \cap G|}{|P \cup G|} \quad IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


ภาพที่ 2.55 ตัวอย่างพื้นที่จุดตัดและทับซ้อนของภาพ  
ที่มา : [https://en.wikipedia.org/wiki/Jaccard\\_index](https://en.wikipedia.org/wiki/Jaccard_index)

โดยระดับผลค่า IoU ต่อตำแหน่งของวัตถุ นั้น ๆ ซึ่ง Mark Everingham และคณะ [90] ได้ทำการทดลองเพื่อหามาตรฐานประสิทธิภาพการทับซ้อนกันของ bounding boxes ไว้คือ เมื่อค่า IoU ที่ได้มีค่ามากกว่าหรือเท่ากับ 50% (0.5) เป็นการทับซ้อนในเชิงบวก (Positive overlap threshold) หรือเป็นการที่ซ้อนที่ยอมรับได้ ในขณะที่ต่ำกว่าเป็นการทับซ้อนเชิงลบ (Negative overlap threshold) ถือว่าไม่ดีและไม่สามารถยอมรับได้ดังภาพที่ 2.56



ภาพที่ 2.56 ตัวอย่างระดับการทับซ้อนของภาพ

## 2.12 งานวิจัยที่เกี่ยวข้อง

ตารางที่ 2.7 สรุปงานวิจัยที่เกี่ยวข้อง

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
1	amara และคณะ [50]	แนวทางการเรียนรู้เชิงลึกสำหรับการจำแนกโรคใบตอง (A Deep Learning-based Approach for Banana Leaf Diseases Classification)	วิธีการที่นำเสนอสามารถใช้เป็นเครื่องมือสนับสนุนการตัดสินใจเพื่อช่วยเกษตรกรในการระบุโรคในสวนกล้วย ซึ่งเกษตรกรสามารถถ่ายภาพใบที่มีอาการจากนั้นระบบจะระบุซึ่งในการศึกษารั้งนี้ใช้กับกล้วยชีกาโตกะและกล้วยหอม ซึ่งกล้วย 2 ชนิดนี้มีอาการโรคเชื้อราดำและพัฒนาเป็นริ้วสีน้ำตาลที่ล้อมรอบด้วยเส้นใบ และมีโรคใบตองเป็นโรคเชื้อรา โดยเริ่มเป็นจุดเล็ก ๆ สีน้ำตาลอ่อนและเมื่อเวลาผ่านไปก็จะขยายขนาดเพิ่มขึ้น ข้อมูลที่ใช้ : 3,700 ภาพ โดยแบ่งข้อมูลสำหรับเรียนรู้ (Train) ภาพที่ไม่เป็นโรค 1,643 ภาพ ภาพที่เป็นโรค 1,817 ภาพ และภาพสำหรับทดสอบความถูกต้องในการเรียนรู้ทั้งภาพเป็นโรคและไม่เป็นโรคจำนวน 240 ภาพ โดยแบ่งข้อมูลออกเป็น 80%, 60%, 50%, 40% และ 20% และใช้อัลกอริทึม (Stochastic gradient descent : SGD) เพื่อนำมาใช้ในการสร้างแบบจำลองเพื่อเรียนรู้ค่าน้ำหนักและค่า biases ที่ดีที่สุดของโครงข่ายประสาทเทียมที่ลดการสูญเสียให้น้อยที่สุด	Convolutional neural network: CNN โดยใช้สถาปัตยกรรม LeNet	ผลการทดลองสามารถรองรับการตรวจหาโรคทางใบได้อย่างแม่นยำ โดยผลที่ได้มีค่าความแม่นยำ (Accuracy) สูงที่สุดคือ 99 % โดยเปอร์เซ็นต์ในการแบ่งข้อมูลเรียนรู้และทดสอบที่ 50% ต่อ 50%

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
			(Loss) ซึ่งค่าที่ได้คือ 0.001 ซึ่งเป็นอัตราการเรียนรู้ โดยที่หากค่าการเรียนรู้ต่ำทำให้ผลลัพธ์ที่แม่นยำยิ่งขึ้น แต่ต้องใช้เวลาในการเรียนรู้มากขึ้น โมเมนตัมเป็น ปัจจัยเพิ่มเติมในการพิจารณาอัลกอริทึม SGD มา บรรจบกันที่จุดที่เหมาะสมได้เร็วเท่าไรโดยตั้งค่าเป็น 0.9		
2	Sharada และ คณะ [91]	การใช้การเรียนรู้เชิง ลึกสำหรับการ ตรวจสอบโรคพืชด้วย ภาพ (Using deep learning for image-based plant disease detection)	งานวิจัยนี้ทำการศึกษาเพื่อรู้จำพันธุ์พืชที่เป็นโรคและ ตรวจสอบโรคพืชด้วยภาพ โดยรวบรวมภาพพืชที่เป็น โรคและไม่เป็นโรคจาก PlantVillage โดยระบุพืช จำนวน 14 ชนิด และชนิดของโรคจำนวน 26 โรค จำนวน 54,306 ภาพ ซึ่งภาพจะปรับขนาด 256 x 256 พิกเซล โดยทำการทดสอบในสองรูปแบบ ประกอบด้วย เริ่มต้นเรียนรู้จากศูนย์ (Training from Scratch) และเรียนรู้แบบวิธีการถ่ายโอนความรู้ในการ ทดสอบประสิทธิภาพของการเรียนรู้เชิงลึกใช้วิธี Cross Validation เพื่อแบ่งข้อมูลออกเป็นข้อมูลชุดเรียนรู้ 80%, 60%, 50%, 40% และ 20% ตามลำดับ	Convolutional neural network: CNN โดยใช้สถาปัตยกรรม AlexNet และ GoogLeNet	ผลการทดลองพบว่า เมื่อแบ่งข้อมูล ออกเป็นชุดเรียนรู้ จำนวน 80% และ ชุดทดสอบจำนวน 20% ของ สถาปัตยกรรม GoogLeNet ที่ใช้ในการ เรียนรู้แบบ วิธีการถ่ายโอน ความรู้มีอัตราความ ถูกต้องสูงสุดคือ 99.34%
3	Sladojevic และคณะ [92]	โครงข่ายประสาท เทียมเชิงลึกจากการ	งานวิจัยนี้ได้พัฒนาแบบจำลองการจดจำโรคพืชโดย อาศัยการจำแนกภาพใบไม้โดยการใช้เครือข่ายการ	Convolutional neural network: CNN	ผลการทดลองพบว่า มีค่าความถูกต้อง

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
		รับรู้โรคพืชโดยการจำแนกภาพใบไม้ (Deep neural networks based recognition of plant diseases by leaf image classification)	เรียนรู้เชิงลึก โดยนำรูปภาพใบไม้ (Leaf) มาเพื่อทดลอง โดยมีรูปตัวอย่างใบไม้ที่เป็นโรคจำนวน 13 ชนิด และรวมกับใบไม้ที่ไม่เป็นโรค 2 ชนิด รวมเป็น 15 ชนิด ในการทดลองใช้เทคนิคในการเพิ่มข้อมูลในการเรียนรู้ (Augmented Data) ด้วยวิธีการในการประมวลผลภาพ (Image processing) ประกอบด้วย การนำภาพไปบิดให้ผิดรูป (Distortion) และการหมุนภาพ (Rotation) เป็นต้น ซึ่งข้อมูลที่ใช้ในการทดสอบมีจำนวนทั้งสิ้น 4,483 ภาพและเมื่อนำไปผ่านวิธีการ Augmented จะได้รูปภาพเพิ่มขึ้น 30,880 ภาพ	และเทคนิค CaffeNet CNN	96.3%
4	Dyrmann และคณะ [93]	การจำแนกประเภทวัชพืชอย่างชาญฉลาดและการเพาะปลูกโดยใช้ภาพด้วยเทคนิคโครงข่ายประสาทเทียมแบบเต็ม (Pixel-wise classification of weeds and crop in images by using a	งานวิจัยนี้จะตรวจสอบปัญหาเกี่ยวกับการรับรู้ของพืชและการแยกแยะพืชออกจากวัชพืชที่ขึ้นโดยรอบต้นพืช โดยทำการจำแนก ต้นข้าวโพด ดิน และวัชพืช วัตถุประสงค์หลักในงานวิจัยนี้ เพื่อที่จะระบุหาตำแหน่งที่แน่นอนของวัชพืชและพืชผล ซึ่งจะช่วยลดระยะเวลาและค่าใช้จ่ายในการตรวจหาวัชพืช และกำหนดเป้าหมายในการใช้สารเคมีกำจัดวัชพืชได้ตรงจุด โดยระบบจะสามารถตรวจจับวัชพืชได้โดยอัตโนมัติ ข้อมูลที่ใช้ เป็นข้อมูลที่เก็บรวบรวมจากศูนย์วิจัย Foulum ประเทศเดนมาร์กจำนวน 36 แปลง ซึ่ง 36 แปลงนั้นประกอบไปด้วยพืชหลายชนิด	Convolutional neural network: CNN โดยใช้สถาปัตยกรรม VGG-16	พบว่า สามารถแยกแยะข้าวโพดวัชพืชและดินในภาพจริงโดยมีความแม่นยำมากกว่า 94% นอกจากนี้เครือข่ายประสาทเทียมยังสามารถแยกแยะวัชพืชออกจากข้าวโพดได้เมื่อพืชซ้อนทับกัน

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
		Fully Convolutional neural Network)	คือ หัวใจเท้า ข้าวบาร์เลย์ หญ้าวัชพืช และตอไม้ รวม 352 ตารางวา มีภาพดินทั้งหมด 301 ภาพ และภาพพืชที่แบ่งส่วนแล้ว 8,430 ภาพ เพื่อสร้างแบบจำลองซึ่งพืชเหล่านี้ได้มาจากชุดข้อมูล 8 ชุดที่ได้มาจากสภาพแวดล้อมภายในและภายนอกอาคาร ดังนั้นจึงมีความแตกต่างกันทั้งในแง่ของความละเอียดและความสว่างของภาพ โดยแบ่งภาพสำหรับเรียนรู้ 80% และ 20 % สำหรับทดสอบ พืชที่กล่าวมานั้นครอบคลุมทั้งวัชพืช และข้าวโพดจำนวน 23 ชนิด เหตุที่ใช้ข้อมูลลักษณะนี้ เนื่องจากในการเพาะปลูกพืชนั้นจะมีการหมุนเวียนการเพาะปลูกตลอดซึ่งอาจทำให้ภาพมีความเข้ม ความสว่างของภาพแตกต่างกัน		ดังนั้นระบบนี้จะมีประโยชน์ในการกำหนดปริมาณวัชพืชและพื้นที่เพาะปลูกได้
5	Lee และคณะ [88]	การแยกแยะชนิดของพืชด้วยเครือข่ายประสาทเทียม (Deep - Plant: Plant Identification With Convolutional Neural Networks)	งานวิจัยนี้ได้ทำการศึกษาเพื่อเรียนรู้การแสดงคุณลักษณะของพืช และความสามารถในการระบุพันธุ์พืชใหม่หรือพันธุ์พืชที่หายากเพื่อที่จะนำมาใช้ในการปรับปรุงอุตสาหกรรมยาโรค รักษาสมดุลงของระบบนิเวศตลอดจนผลผลิตทางการเกษตรและความยั่งยืน ซึ่งนักพฤกษศาสตร์ได้ใช้การเปลี่ยนแปลงลักษณะของใบไม้เป็นเครื่องมือในการเปรียบเทียบในการศึกษาพันธุ์พืช เนื่องจากลักษณะของใบสามารถสังเกตและตรวจสอบได้ตลอดทั้งปี โดยใช้ใบพืช	Convolutional neural network: CNN โดยใช้สถาปัตยกรรม AlexNet	ผลการศึกษาในการเรียนรู้ลักษณะการแยกแยะภาพใบพืชและแยกประเภทสำหรับการระบุพืชที่แตกต่างกันด้วยประสิทธิภาพ 99.5%

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
			<p>ทั้งหมด 44 ชนิด ที่รวบรวมจาก Royal Botanic Gardens เมือง Kew ประเทศอังกฤษ ซึ่งลักษณะของใบไม้มีความคล้ายคลึงกันมาก ในการทดลองจะทำการแบ่งข้อมูลภาพเป็น 2 ชุด โดยชุดแรกนั้นจะทำการดึงพื้นที่ของสี HSV เพื่อขยายข้อมูลจากนั้นทำการหมุนภาพแต่ละใบใน 7 แนวที่แตกต่างกัน คือ 45°, 90°, 135°, 180°, 225°, 270° และ 315° จากนั้นสุ่มเลือกใบพืช 528 ภาพเพื่อทดสอบและ 2,288 สำหรับการเรียนรู้ ข้อมูลชุดที่ 2 ทำการครอบตัดภาพใบไม้แต่ละภาพในข้อมูลชุดที่ 1 ด้วยมือให้เป็นชนิดเล็กภายในพื้นที่ของใบพืช ซึ่งการทำวิธีนี้เพื่อตรวจสอบถึงความแม่นยำของลักษณะนามที่ระบุใบพืชคือชนิดใด หากไม่ได้เห็นรูปร่างของใบทั้งหมด ในทางกลับกันก็ต้องการทราบว่าสามารถใช้การระบุใบพืชโดยใช้ใบที่ตัดได้หรือไม่ เนื่องจากภาพต้นฉบับมีขนาดตั้งแต่ 3,000 x 3,000 ถึง 500 x 500 จึงมีการเลือกขนาดของภาพที่แตกต่างกัน 3 ขนาด คือ 500 x 500, 400 x 400 และ 256 x 256 และทำการหมุนในลักษณะเดียวกันกับข้อมูลชุดที่ 1 และสุ่มภาพ 8,800 ภาพสำหรับการทดสอบและ 34,672 ภาพสำหรับการเรียนรู้ ผลการเปรียบเทียบเทียบชุดข้อมูลทั้ง 2 พบว่า</p>		



ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
			ชุดข้อมูลชุดที่ 2 (99.5%) มีความแม่นยำในการจำแนกประเภทของใบพืชได้แม่นยำกว่าข้อมูลชุดที่ 1 (97.7%)		
6	Grinblat GL และคณะ [94]	การเรียนรู้เชิงลึกสำหรับการจำแนกพืชโดยใช้รูปแบบทางสัณฐานวิทยาของหลอดเลือด (Deep learning for plant identification using vein morphological patterns)	งานวิจัยนี้ได้เสนอวิธีการสำหรับการระบุพืชจากรูปแบบเส้นหลอดเลือดของใบ โดยจะพิจารณาจำแนกพืชตระกูลถั่วที่แตกต่างกัน 3 ชนิด คือ ถั่วขาว ถั่วแดง และถั่วเหลือง โดยใช้เทคนิคโครงข่ายประสาทเทียม Convolutional neural network (CNN) เนื่องจากมีความทันสมัย และสามารถเรียนรู้ได้ลึกทำให้ช่วยเพิ่มความแม่นยำในการวิเคราะห์รูปแบบเส้นหลอดเลือดของใบถั่วได้ ในการศึกษาแบ่งออกเป็น 4 ขั้นตอน ขั้นตอนที่ 1 : รวบรวมชุดข้อมูลภาพของใบไม้ด้วยเครื่องสแกนแทนมาตรฐาน จากนั้นทำการแบ่งส่วนภาพโดยใช้ Hitor miss transform (UHMT) [95] เพื่อแยกรูปแบบทางสัณฐานวิทยาของหลอดเลือดใบถั่ว ซึ่งผลลัพธ์ของการแปลงภาพเป็นแบบไบนารีนี้สามารถกำจัดข้อมูลสี ขั้นตอนที่ 2 : จากนั้นทำการแยกส่วนภาพไบนารีโดยการครอบตัดกึ่งกลางของภาพ (100 x 100) พิกเซล จุดประสงค์เพื่อกำจัดรูปร่างของใบที่ไม่จำเป็นออกไป ขั้นตอนที่ 3 : จากนั้นชุดข้อมูลนี้จะถูกดึงออกมาจาก	Convolutional neural network: CNN	ผลการทดลองพบว่า ค่าความแม่นยำของข้อมูลชุด S2 มีค่า 96.9%

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
			<p>วิธีการของ LEAF GUI [96] ซึ่งชุดข้อมูลนี้ ประกอบด้วยการวัด เช่น จำนวนเส้นลวดลายทั้งหมด จำนวนโหนดทั้งหมด และความกว้างของเส้นลวดลาย เฉลี่ย เป็นต้น ขั้นตอนที่ 4 : การจำแนกประเภท มีการทดสอบอัลกอริทึม Machine learning ที่แตกต่างกัน 3 แบบ คือ Support vector machines (SVM), Penalized Discriminant Analysis (PDA) และ Random Forests (RF) [97] โมเดลเหล่านี้ได้รับการเรียนรู้โดยใช้คุณสมบัติตามขั้นตอนที่กล่าวมา ซึ่งวิธีการปรับขนาดของภาพในระดับต่าง ๆ ด้วยวิธี UHMT นั้นพิจารณาที่ 100% (ไม่ปรับขนาด) 80% และ 60% หลังจากเตรียมข้อมูลนำเข้าการประมวลผลด้วย CNN โดยทำการแบ่งข้อมูลภาพเป็น 2 ชุดคือ S1 มีขนาดภาพนำเข้า CNN คือ 100 x 100 x 1 binary image และชุด S2 มีขนาดภาพนำเข้า CNN คือ 100 x 100 x 4 One image และมีการปรับพารามิเตอร์ให้เหมาะสมด้วย Stochastic gradient descent (SGD) ในชุดการเรียนรู้โดยใช้กลุ่มตัวอย่างจำนวน 20 ตัวอย่าง และได้นำเทคนิค Drop out มาช่วยในการแก้ปัญหาไม่ให้เกิดปัญหา Overfitting เกินไป และได้ทดสอบ Model CNN นั้น</p>		

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
			ได้เพิ่มความลึกจาก 2 ชั้น ถึง 6 ชั้น และกำหนดค่า Pooling ที่ 2x2		
7	Hulya Yalcin [89]	การรับรู้การเจริญเติบโตของพืชโดยใช้การเรียนรู้เชิงลึก (Plant Phenology Recognition using Deep Learning: Deep-Pheno)	งานวิจัยนี้ทำการศึกษาวิธีการเพื่อรับรู้และจำแนกขั้นตอนการเจริญเติบโตของพืชหลายประเภท โดยอาศัยข้อมูลภาพถ่ายที่สามารถถ่ายได้ทุกครั้งชั่วโมง โดยกล้องจะติดตั้งบนสถานีเกษตรภาคพื้นดินที่ปลูกพืชทั่วตุรกี ซึ่งเป็นส่วนหนึ่งของระบบเครือข่ายเฝ้าระวังทางเกษตร แนวทางในการศึกษานี้ได้นำสถาปัตยกรรม CNN มาเปรียบเทียบกับการใช้ตัวบอกลักษณะด้วยการกำหนดด้วยมือ (ใช้อัลกอริทึมการเรียนรู้ของเครื่อง) เพื่อแยกแยะการเจริญเติบโตของพืช โดยทำการปรับแต่ง Convolutional Neural Network ใช้คลาสพืช 6 ชั้นจากชุดข้อมูล TARBIL มีตัวอย่างภาพประมาณ 400 ภาพ สำหรับพืชแต่ละประเภท ใช้ภาพ 280 ภาพในการฝึกอบรมและ 120 ภาพสำหรับการทดสอบ นั่นทำให้มีภาพตัวอย่างเกือบ 30 ภาพสำหรับแต่ละช่วงการเติบโต เพื่อเพิ่มข้อมูลการฝึกอบรมแต่ละภาพจะถูกแบ่งออกเป็นแพตช์ขนาดใหญ่และมีการแยกคุณสมบัติสำหรับแต่ละแพตช์ขนาดดั้งเดิมของภาพคือ 2288 x 1712 พิกเซล แพตช์ขนาด 227 x 227 ถูกตัดจากภาพต้นฉบับเพื่อเพิ่ม		ประสิทธิภาพการจำแนกประเภทของการเจริญเติบโตของพืช CNN มีประสิทธิภาพมากกว่า


ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
			ข้อมูลการฝึกอบรมรวมถึงการเตรียมขนาดนำเข้าสำหรับ AlexNet และทำการแบ่งภาพอีก 30 ภาพเพื่อนำมาเพิ่มข้อมูลฝึกอบรมโดยจะทำเพิ่มขนาดของภาพให้มีขนาดใหญ่ขึ้นและแยกคุณสมบัติ ซึ่งสำหรับภาพถ่ายที่นำมาใช้ในงานคือ ระยะเวลาเจริญเติบโตที่แตกต่างกันของข้าวสาลี ข้าวบาร์เลย์ ถั่วเลนทิล โดยเป็นภาพถ่ายตั้งแต่การไถดินจนถึงการปลูกและการเจริญเติบโต การวิเคราะห์นั้นได้ทำการเปรียบเทียบความถูกต้องตามแนวทางของ CNN และคุณลักษณะที่ถูกสกัดด้วยมือกล่าวคือใช้วิธีการเรียนรู้ด้วยเครื่องที่มีเฉลยบอกไว้ให้		
8	Nuttakarn Kitpo และคณะ [87]	อินเทอร์เน็ตทุกสรรพสิ่ง สำหรับระบบตรวจสอบภายในโรงเรือนกระจก โดยใช้การเรียนรู้เชิงลึกและบริการแจ้งเตือนด้วยบอต (Internet of Things for Greenhouse Monitoring System	ได้ศึกษาระบบติดตามการเจริญเติบโตของอุณหภูมิ ความชื้น ปริมาณน้ำ การเฝ้าระวังโรคในระยะเริ่มต้น และระบบตรวจจับ เพื่อนำเสนอแนวทางการทำฟาร์มที่ชาญฉลาด ดังนั้นจึงได้ทำการเสนอและทดลองนำระบบ IoT พร้อมการแจ้งเตือนด้วยบอตเกี่ยวกับการปลูกมะเขือเทศ ซึ่งได้ชุดข้อมูลมะเขือเทศจาก Shinchi AgriGreen ซึ่งเป็นโรงเรือนมะเขือเทศในฟุกุชิมะประเทศญี่ปุ่น จากนั้นได้ทำการเรียนรู้ข้อมูลและทดสอบโมเดลการเรียนรู้เชิงลึกเพื่อตรวจจับสีผิวของผลมะเขือเทศ จากนั้นทำการแบ่งเขตสีผิวของผล	Deep learning K-Means Support Vector Machine (SVM)	การเปลี่ยนแปลงของผลมะเขือเทศใช้ความยาวคลื่นที่มองเห็นได้โดยใช้คุณสมบัติ SVM และสามารถจำแนกประเภทด้วยความแม่นยำคือ 91.5%

ลำดับ	ผู้เขียน	เรื่อง	รายละเอียด	เทคนิคที่ใช้	ผลการทดลอง
		Using Deep Learning and Bot Notification Services)	<p>มะเขือเทศออกเป็น 6 ระยะ คือ สีเขียว สีเขียวอมเทา สีเขียวออกแดง สีชมพู สีแดงสว่าง และสีแดง โดยมีขั้นตอนในการดำเนินงานวิจัยดังนี้</p> <ol style="list-style-type: none"> <li>1.ทำการเก็บภาพถ่ายลูกมะเขือเทศทุกวันเป็นเวลา 25 วัน ขนาดภาพ 1280 x 720 พิกเซล</li> <li>2.ทำการปรับขนาดภาพก่อนการประมวลผล เหลือ 400 x 225 พิกเซล ซึ่งจะช่วยให้ประหยัดเวลาในการประมวลผล โดยแบ่งข้อมูลด้วยการ Random แบ่งเป็นข้อมูลสำหรับเรียนรู้ 80% ข้อมูลสำหรับทดสอบ 20%</li> <li>3.ตรวจจับภาพถ่ายลูกมะเขือเทศด้วยการเรียนรู้เชิงลึก</li> <li>4. ทำการแบ่งภาพเฉดสีมะเขือเทศและการปรับภาพพื้นหลังด้วย K-mean</li> <li>5. แยกสีและวิเคราะห์ความยาวคลื่นของสีในพื้นที่สี HSV</li> <li>6. จัดกลุ่มของการเปลี่ยนเฉดสีของมะเขือเทศโดยใช้การจำแนกประเภทด้วย SVM</li> </ol>		

### บทที่ 3

#### วิธีดำเนินการวิจัย

งานวิจัยนี้เป็นงานวิจัยเชิงประยุกต์ (Applied research) มีวัตถุประสงค์เพื่อสร้างระบบที่ควบคุมสภาพแวดล้อมที่เหมาะสมในการเพาะปลูก และสามารถวิเคราะห์โรคราเขียวสำหรับเห็ดนางฟ้า ซึ่งเป็นการประยุกต์การทำงานของอินเทอร์เน็ตทุกสรรพสิ่ง (Internet of things) การประมวลผลภาพ (Image processing) และปัญญาประดิษฐ์ (Artificial intelligent) ตามวิธีการดำเนินการวิจัย (Research methodology) ดังภาพที่ 3.1 ให้มีความเหมาะสมกับภาคเกษตร ช่วยเพิ่มผลผลิต ช่วยในการแก้ปัญหาการเกิดโรคเห็ด และช่วยให้เกษตรกรมีสุขภาพที่ดี รวมถึงการออกแบบขั้นตอนการประเมินผลที่ดีเพื่อนำผลของการวิจัยที่ได้ไปใช้ในการพัฒนาระบบโรงเรือนปลูกเห็ด (Smart farming) ให้สามารถป้องกันการเกิดโรคเชื้อราของเห็ดนางฟ้าให้กับเกษตรกรได้อย่างแม่นยำและรวดเร็ว โดยใช้เทคนิควิธีการเรียนรู้เชิงลึกในการสร้างแบบจำลองสำหรับการวิเคราะห์เพื่อหาโรคราเขียวในเกษตรกรอัจฉริยะ ซึ่งผู้วิจัยได้ออกแบบและกำหนดวิธีการดำเนินการวิจัยการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าโดยใช้การเรียนรู้เชิงลึกสำหรับเกษตรกรอัจฉริยะดังภาพที่ 3.1



ภาพที่ 3.1 วิธีการดำเนินการวิจัย (Research methodology)

### 3.1 ศึกษากระบวนการเกิดโรคราเขียวของเห็ดนางฟ้า

โรคราของเห็ดนางฟ้ามีหลากหลายชนิด เช่น ราดำ ราเขียว ราส้ม เป็นต้น แต่ปัญหาราเขียวนั้นพบมากที่สุด [2] ซึ่งในการศึกษาพบว่า เกษตรกรส่วนใหญ่ที่ปลูกเห็ดนั้นมักจะพบปัญหาราเขียวเป็นอันดับต้น เนื่องจากราเขียวนั้นเป็นเชื้อราที่อาศัยอยู่ในดินหรืออยู่ในอากาศก็ได้ เมื่อดินหรือวัสดุเพาะมีความชื้น เชื้อราจะเริ่มเจริญเติบโตขึ้นที่ดินไปถึงขี้เถ้าหรือขี้ฟาง ราเขียวที่มักพบในก้อนเห็ดมี 2 ชนิด คือ กลีโอเคลเดียม (*Gliocladium* sp.) และ ไตรโคเดอร์มา (*Trichoderma* sp.) สามารถสังเกตเห็นได้ง่าย เนื่องจากสปอร์ของเชื้อราที่มีสีเขียวอ่อนในสี เมื่อรวมกันหนาแน่นจะเปลี่ยนสีเขียวเข้ม ราเขียวเป็นราที่มีความแข็งแรง สามารถทำลายเชื้อราได้หลายชนิด จากการศึกษาข้อมูลของเชื้อราเขียวนั้นสามารถนำเชื้อราเขียวไตรโคเดอร์มาไปใช้ในการป้องกันและกำจัดโรคพืชต่างๆ ในผักที่ปลูกได้ ดังนั้นราเขียวถือได้ว่าเป็นราชนิดหนึ่งซึ่งหากมีการปนเปื้อนกลีโอเคลเดียม หรือไตรโคเดอร์มา ในก้อนเห็ดจะทำให้เกิดปัญหาได้

สาเหตุการเกิดราเขียว ซึ่งเป็นสาเหตุที่ได้จากการสัมผัสภาชนะเกษตรกรรมที่เพาะปลูกฟาร์มเห็ดนางฟ้าสามารถสรุปปัจจัยเสี่ยงในการเกิดราเขียวพอสังเขปดังนี้

1. ขี้เถ้ายังไม่พร้อมนำมาใช้ ขี้เถ้าต้องหมักไว้อย่างน้อย 1 เดือน (อาจมากกว่านั้นขึ้นอยู่กับชนิดของเห็ด) ก่อนจะนำมาใช้ได้ การหมักขี้เถ้าเป็นเรื่องจำเป็น เนื่องจากเห็ดย่อยอาหารกินเองไม่ได้ จำเป็นต้องให้จุลินทรีย์ช่วยย่อยโปรตีนให้เล็กลง ในระยะเริ่มต้นของการหมักจุลินทรีย์ประเภทที่ไม่ต้องการอากาศ เช่น แบคทีเรียหรือเชื้อแอสคิตินอสิตา จะทำการย่อยสลายสารอาหารที่เป็นโปรตีนที่มีโครงสร้างที่ซับซ้อนให้อยู่ในรูปที่เล็กลง ซึ่งในระหว่างกระบวนการทางเคมีที่กล่าวมานี้ จะมีเกลือและก๊าซแอมโมเนียเกิดขึ้น เกลือและก๊าซแอมโมเนีย จะถูกจุลินทรีย์ประเภทที่ต้องการอากาศเปลี่ยนเป็นโปรตีนขนาดเล็กลง เพื่อให้เห็ดสามารถเอาไปใช้ได้ ดังนั้นหากมีการนำเอาขี้เถ้าหรือวัสดุเพาะที่กระบวนการย่อยสลายยังไม่สิ้นสุด โดยการใช้เกลือและแอมโมเนียที่เหลืออยู่จะก่อให้เกิดปัญหาต่อเส้นใยเห็ดเป็นอย่างมาก รวมทั้งเป็นสาเหตุหนึ่งที่ทำให้เกิดราชนิดต่างๆ เช่น ราเขียว ราดำ ราส้ม เป็นต้น

2. การนึ่งก้อนเชื้อเห็ดไม่ดีพอ วัตถุดิบต่างๆ ที่บรรจุใส่ในก้อนเห็ดมีโอกาสปนเปื้อนเชื้อราเขียวได้ทั้งหมด โดยเฉพาะรา หากการนึ่งก้อนเห็ดทำได้ดีพอ คือ อุณหภูมิไม่ถึง ระยะเวลาไม่ได้ ราที่ปนเปื้อนในก้อนเห็ดไม่ตาย ไม่นานจะสามารถฟื้นตัวมาแข่งแย่งอาหารกับเส้นใยเห็ด ดอกที่ได้จึงไม่สมบูรณ์ ไม่สวย รวมทั้งอาจเป็นสาเหตุให้เห็ดดอกออกช้า

3. เชื้อเห็ดไม่แข็งแรง เชื้อที่อ่อนแรง เช่น เชื้อที่ต่อเชื้อหลาย ๆ รอบอาจไม่แข็งแรงพอที่จะสู้กับราหรือเชื้ออื่น ๆ ได้ หากพบว่าฟาร์มเห็ดที่ไม่ได้ดูแลรักษาความสะอาดที่เพียงพอ และใช้เชื้อต่อ ๆ กันหลาย ๆ รอบ มีโอกาสที่จะทำให้ก้อนเห็ดนั้นไม่สามารถเจริญเติบโตได้

4. การหยอดเชื้อไม่สะอาด การปนเปื้อนของราเขียวในขั้นตอนการหยอดเชื้ออาจเกิดจาก 3 สาเหตุหลัก คือ

- 4.1 เกิดจากเชื้อข้าวฟ่าง (เชื้อขยาย) มีราเขียวปนเปื้อนอยู่ ก่อนหยอดเชื้อข้าวฟ่าง จึงควรตรวจสอบให้ดีเสียก่อนว่าเชื้อข้าวฟ่างมีการปนเปื้อน (Contamination) หรือไม่ ถ้าปัญหาเกิดจากข้อนี้ จะสังเกตเห็นได้ว่าก่อนจะติดราเขียวเป็นชุด ๆ ติด ๆ กัน เพราะมาจากเชื้อข้าวฟ่างแหล่งเดียวกัน
- 4.2 เกิดจากสถานที่หยอดเชื้อข้าวฟ่างไม่ได้มาตรฐาน สุ่มเสี่ยงต่อการปนเปื้อนเชื้อราที่ปลิวอยู่ในอากาศได้ง่าย ในต่างประเทศถือว่าขั้นตอนนี้อ่อนไหวง่ายมาก ขั้นตอนจึงมักทำในห้องที่ได้มาตรฐาน
- 4.3 เกิดจากขั้นตอนการทำงานที่ไม่ได้มาตรฐาน เช่น นำคนที่เก็บดอกเห็ดในโรงเรือนมาหยอดเชื้อข้าวฟ่างโดยไม่ทำความสะอาดร่างกายก่อน คนเก็บเห็ดจึงกลายเป็นพาหะนำเชื้อราเขียวที่เกิดในโรงเปิดดอกเห็ด (หากมี) มาแพร่กระจายต่อที่ก้อนเห็ดใหม่

5. มาตรฐานความสะอาดไม่ดีพอ ความสะอาด ถือ ส่วนที่สำคัญมากในการทำฟาร์มเห็ดที่เจ้าของฟาร์มขาดการเอาใจใส่ที่ดีพอมักจะเกิดปัญหาเชื้อราที่เป็นปรปักษ์ต่อเชื้อเห็ดได้ง่าย เช่น บางฟาร์มเก็บดอกเห็ด โดยปล่อยเศษดอกเห็ดตกและหมักหมมที่พื้นโรงเรือนโดยไม่ทำความสะอาด หรือบางฟาร์มจะทิ้งก้อนเห็ดที่เป็นเชื้อรา ติดแบคทีเรียไว้ในบริเวณฟาร์ม โดยไม่ทำลาย หรือมีระบบจัดการที่ไม่ดี สปอร์ของราเขียวที่อยู่ในก้อนเห็ดเก่าอาจจะฟุ้งกระจายไปทั่วฟาร์มได้

6. ทิศทางของฟาร์มเห็ดไม่ถูกต้อง ทิศทางของฟาร์มเห็ดนั้นมีส่วนสำคัญที่ทำให้การแพร่กระจายของเชื้อราทำได้ง่าย ฟาร์มเห็ดที่ดีจึงควรตั้งขวางทิศทางลม เพื่อลดโอกาสเสี่ยงในการแพร่กระจายของเชื้อรา ซึ่งไม่ใช่เฉพาะแค่ราเขียวเพียงอย่างเดียว ข้อนี้มีความสำคัญ โดยเฉพาะฟาร์มที่บกพร่องในข้อ 5.

7. การดูแลก้อนเห็ดไม่ถูกต้อง ในส่วนนี้มีสาเหตุได้หลากหลาย เช่น 1) การรดน้ำที่ไม่ถูกวิธีการให้ความชื้นที่เกินพอดี 2) การใช้ซ็อนเขี่ยทำความสะอาดหน้าก้อนเห็ดโดยที่ไม่ใช้แอลกอฮอล์ทำความสะอาด หากก้อนเห็ดก้อนใดมีเชื้อราเขียวปนเปื้อนอยู่ โอกาสจะแพร่กระจายจากก้อนหนึ่งไปสู่อีกก้อนหนึ่งมีโอกาสดีได้ง่าย 3) ฤกษ์ก้อนเห็ดมีรู ปรี หรือแตก เป็นต้น

สำหรับก้อนเห็ดนางฟ้า นั้นจะมีลักษณะเหมือนกับก้อนเห็ดทั่วไป ต่างกันที่เชื้อเห็ดที่นำมาใช้ในการปลูกไว้ในก้อนเห็ด สำหรับวิธีการทำก้อนเห็ดนั้นไม่ได้กล่าวถึงขั้นตอนการทำ แต่สำหรับงานวิจัยนี้จะนำภาพตัวอย่างลักษณะของก้อนเห็ดที่ดำเนินการทำพร้อมนำส่งและพร้อมเปิดก้อนเห็ดเพื่อให้เชื้อเห็ดภายในก้อนเห็ดเดินและออกดอกเห็ดได้ ระยะที่เชื้อเห็ดเดิน ระยะที่เชื้อเห็ดเดินเต็มก้อน และระยะที่เชื้อก้อนเห็ดหมดคุณภาพหรือหมดเชื้อเห็ดแล้ว ซึ่งจากการศึกษาจากเอกสารและสอบถามเกษตรกรผู้เชี่ยวชาญการเลี้ยงเห็ดพบว่า ก้อนเห็ดจะออกดอกภายใน 15 วันหลังจากเปิดก้อนเห็ด และจะพักการออกดอกประมาณ 7 วัน แล้วก้อนเห็ดจึงจะออกดอกอีกครั้ง และจะวนออกดอกไปเรื่อย ๆ จนครบ 6 เดือน หลังจากนั้นก้อนเห็ดก็จะเดินเต็มก้อนและเสื่อมคุณภาพไป ดังแสดงตัวอย่างตามภาพ





เชื้อเห็ดเริ่มเดิน



เชื้อเห็ดเดินเต็มก้อน

ภาพที่ 3.2 ระยะเวลาเดินเชื้อเห็ด


โรคราเขียวนั้นเป็นโรคที่พบมากที่สุดในพื้นที่นางฟ้า เนื่องจากในการปลูกเห็ดนางฟ้า นั้นจะต้องอาศัยความชื้นและความเย็นที่เหมาะสมต่อการออกดอก หากมีความชื้นมากเกินไปก้อนเห็ดมีโอกาสเกิดราเขียวเป็นอันดับต้น และจากการสอบถามเกษตรกรผู้ปลูกเห็ดนางฟ้าจะพบปัญหานี้เป็นโรคราเขียวเป็นปัญหาหลัก ซึ่งการเกิดราเขียวในโรงเรือนเพาะปลูกเห็ดหรือในฟาร์มเห็ด จะแพร่กระจายลูกกลมเป็นวงกว้างในเวลา 24 ชั่วโมง ด้วยปัญหานี้จึงทำให้เกษตรกรสูญเสียก้อนเห็ดในจำนวนมาก เช่น หากเกษตรกรซื้อก้อนเห็ดมาในราคาก้อนละ 15 บาท ใน 1 โรงเรือนมาตรฐาน (2 x 15 x 2 คือ กว้าง x ยาว x สูง) ซึ่งสามารถวางก้อนเห็ดได้ประมาณ 4,000 ก้อน หากคำนวณราคาลงทุนแล้วจะใช้งบประมาณ 60,000 บาท นี่คือนั่นทุนที่เกษตรกรได้ลงทุนไปในการซื้อก้อนเห็ด การลงทุนจริง ๆ แล้วเกษตรกรจะลงทุนอยู่ที่ประมาณ 3 - 4 โรงเรือน เมื่อรวมแล้วค่าใช้จ่ายในการลงทุนสูง ดังนั้นหากในหนึ่งโรงเรือนที่ปลูกเห็ดนางฟ้า เกิดโรคราเขียวและเกษตรกรไม่สามารถตรวจสอบได้ทัน หมายความว่าราเขียวได้ลูกกลมไปยังก้อนเห็ดก้อนอื่นจนหมดทั้งโรงเรือนได้ ดังนั้นโรคราเขียวในพื้นที่นางฟ้าเป็นปัญหาใหญ่สำหรับเกษตรกรเป็นอย่างมาก หรือแม้หากมีวิธีการป้องกันบ้าง แต่หากวิธีการนั้นไม่สามารถป้องกันได้จริงแล้วจากราเขียวอาจกลายเป็นโรคราชนิดอื่นได้

นอกจากเรื่องของอุณหภูมิและความชื้นในการเกิดราเขียวแล้ว ยังมีในส่วนของการผลิตก้อนเห็ดนางฟ้าร่วมด้วย ในการผลิตก้อนเห็ดนางฟ้านั้นจะต้องใช้กากมะพร้าวที่สะอาด ไม่มีเชื้อของราที่มากับกากมะพร้าว เมื่อผสมกากมะพร้าวเรียบร้อยแล้วจะต้องทำการนำก้อนเห็ดที่อัดกากมะพร้าวเข้าไปทำการอบด้วยอุณหภูมิมากกว่า 100 องศาเซลเซียส เพื่อฆ่าเชื้อโรคและเชื้อราที่มากับกากมะพร้าว จากนั้นทิ้งไว้ให้แห้งในห้องปลอดเชื้อและทำการหยอดเชื้อเห็ดนางฟ้าเข้าไปยังก้อนเห็ดเมื่อหยอดเชื้อเห็ดเสร็จแล้วทำการปิดปากก้อนเห็ดด้วยสำลีและเม็ดข้าวฟ่าง ซึ่งเม็ดข้าวฟ่างนั้นจะเป็นอาหารให้กับราเห็ดสามารถเจริญเติบโตได้ดี และปิดปากก้อนเห็ดด้วยพลาสติกหรือหนังสือพิมพ์ ใช้ยางรัดปากก้อนเห็ดให้มิดชิด ในขั้นตอนการผลิตก้อนเห็ดนี้หากอบก้อนเห็ดได้ไม่ดีมีโอกาสที่ก้อนเห็ดจะเกิดเชื้อราเขียวได้ง่าย และเชื้อราเขียวนี้จะทำให้ราเห็ดตายได้และลูกกลมได้อย่างรวดเร็ว

### 3.2 วิเคราะห์และออกแบบระบบโรงเรือนเกษตรอัจฉริยะร่วมกับเกษตรกร

ในขั้นตอนนี้เป็นการวิเคราะห์และออกแบบโรงเรือนด้วยระบบปิดที่มีการนำอุปกรณ์ด้านอินเทอร์เน็ตของสรรพสิ่ง (Internet of thing :IoT) เข้ามาใช้ในการติดตั้ง เพื่อควบคุมอุณหภูมิ ความชื้น แสงสว่าง ฯลฯ ให้กับฟาร์ม เพื่อให้เห็ดนั้นสามารถให้ผลผลิตที่ดี มีปริมาณที่มากและคุณภาพของดอกเห็ดดี ในการสร้างระบบฟาร์มเห็ดอัจฉริยะนั้น ผู้วิจัยได้รับความร่วมมือกับเกษตรกรเจ้าของฟาร์มบ้านเห็ดดุษฎี อำเภอเมือง จังหวัดขอนแก่น ซึ่งเกษตรกรมีความพร้อมในการที่จะร่วมพัฒนาและสร้างระบบฟาร์มเห็ดอัจฉริยะในครั้งนี้ ทั้งนี้ระบบภายในโรงเรือนจะต้องสามารถควบคุมอุณหภูมิที่แตกต่างกันระหว่างภายในและภายนอกได้ดี มีการติดตั้งอุปกรณ์เซนเซอร์แสงและกล้องถ่ายภาพ ทำการทดสอบระบบเซนเซอร์แสงและกล้องภายในโรงเรือน วัดค่าสภาพแวดล้อมต่าง ๆ ภายในโรงเรือน เช่น อุณหภูมิ เป็นต้น ซึ่งขั้นตอนนี้เป็นการลงพื้นที่โดยใช้พื้นที่ของเกษตรกรผู้ปลูกเห็ดนางฟ้าที่มีความพร้อมและร่วมกันออกแบบโรงเรือนสมาร์ฟาร์ม เมื่อมีการติดตั้งระบบและอุปกรณ์เรียบร้อยแล้ว มีการทดสอบระบบเซนเซอร์แสงและกล้องถ่ายภาพภายในโรงเรือน และวัดค่าสภาพแวดล้อมต่าง ๆ ภายในโรงเรือน เช่น อุณหภูมิ เป็นต้น จากนั้นทำการตรวจสอบอุณหภูมิภายในโรงเรือน เพื่อที่จะตรวจสอบความมีเสถียรภาพของอุณหภูมิภายในโรงเรือน หากอุณหภูมิภายในโรงเรือนมีความคงที่หรือมีเสถียรภาพจะทำการวนการตรวจสอบอย่างต่อเนื่องตลอดเวลา หากมีการตรวจสอบพบว่าอุณหภูมิไม่มีความคงที่หรือไม่มีเสถียรภาพ ระบบการถ่ายภาพของกล้องจะเปิดการทำงานเพื่อถ่ายภาพเห็ดทั่วไปทั้งหมดภายในโรงเรือน ซึ่งจะนำระบบปัญญาประดิษฐ์เข้ามาใช้ในการทำงานโดยระบบนี้จะทำการวิเคราะห์ข้อมูลเพื่อกำหนดเวลาการถ่ายภาพทั้งหมดภายในโรงเรือน

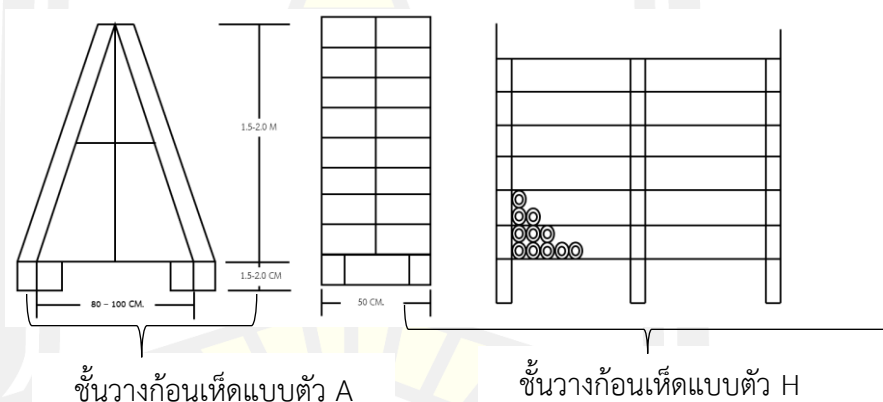
1. การออกแบบภายในและภายนอกของโรงเรือนหรือฟาร์มแบบระบบปิด โดยทำการออกแบบโครงสร้างโรงเรือนเพาะเห็ด ตำแหน่งการติดตั้งพัดลมระบายอากาศ ตำแหน่งพื้นที่วางระบบน้ำที่ใช้สำหรับให้ความเย็นผ่านแผงไอน้ำทำความเย็น (Evap หรือ Cooling pad) และจุดสำหรับการติดตั้งอุปกรณ์ควบคุมทั้งระบบ IoT และตัวควบคุม เช่น หัวพ่นหมอก เป็นต้น ดังตัวอย่าง



ภาพที่ 3.3 ตัวอย่างการสร้างฟาร์มเห็ดอัจฉริยะ


ระบบเกษตรอัจฉริยะสามารถควบคุมอุณหภูมิต่าง ๆ ภายในโรงเรือนได้ดี ซึ่งการเจริญเติบโตของเห็ดนางฟ้า นั้นจะต้องอาศัยแสง อุณหภูมิ ความชื้น และการถ่ายเทของอากาศที่เหมาะสมจึงจะสามารถช่วยให้เห็ดนั้นออกดอกมากและสมบูรณ์ น้ำหนักดี ดังนั้นในการออกแบบโรงเรือนแบบปิดที่มีความเหมาะสมนั้นจะช่วยให้เกษตรกรสามารถเก็บผลผลิตได้ตลอดทั้งปีและให้ผลกำไรที่ดีกับเกษตรกรได้ สำหรับระบบโรงเรือนแบบเกษตรอัจฉริยะนั้นเป็นระบบโรงเรือนแบบปิด ซึ่งในการออกแบบนั้นจะต้องมีการติดตั้งระบบเซ็นเซอร์ และอุปกรณ์ต่าง ๆ ที่เกี่ยวข้อง ซึ่งขนาดโรงเรือนมาตรฐานทั่วไปนั้นจะสามารถนำก้อนเห็ดนางฟ้ามาทำการเปิดก้อนเห็ดอยู่ที่ 4,000 – 5,000 ก้อน โดยมีขนาด กว้าง 6 เมตร ยาว 20 เมตร และสูง 3.5 เมตร

2. การออกแบบภายในและการออกแบบชั้นวางก้อนเห็ดชั้นวางก้อนเห็ดนั้นสามารถออกแบบได้หลากหลายวิธีแต่โดยส่วนมากนั้นจะมีการออกแบบ 2 ลักษณะ คือ แบบวางบนชั้นแบบเอียง ๆ คล้ายตัว A และแบบวางบนชั้นแบบตัว H เมื่อทำการออกแบบฟาร์มเห็ดเรียบร้อยแล้วในการเลือกชั้นวางเห็ดนั้นก็มีผลต่อการเจริญเติบโตของเห็ดได้เช่นกัน กล่าวคือ หากวางก้อนเห็ดสับหว่างกันไปมาโดยไม่มีช่องระบายอากาศ ก็จะทำให้ก้อนเห็ดมีการสะสมความชื้นไว้มากเกินไป ทำให้มีโอกาสในการเกิดรามากขึ้น และการวางก้อนเห็ดแบบเรียงต่อกันหรือวางซ้อนกันเป็นแถวเดียวกันจะทำให้ก้อนเห็ดลดการสะสมความชื้นและอากาศระบายผ่านก้อนเห็ดได้ทั่วทั้งก้อนและทั่วถึงทุกก้อน




ภาพที่ 3.4 การออกแบบชั้นวางก้อนเห็ด

การออกแบบชั้นวางก้อนเห็ดเนื่องจากชั้นวางก้อนเห็ดนั้นจะสามารถทำให้เกษตรกรสามารถนำก้อนเห็ดที่จะเพาะปลูกได้ในปริมาณที่เหมาะสมและไม่แออัดมากเกินไป สำหรับโรงเรือนแบบเกษตรอัจฉริยะนั้นจะนิยมนำเหล็กเส้นที่มีเส้นผ่าศูนย์กลาง 1 นิ้ว มาทำการเชื่อมเป็นชั้นวางเห็ดเพื่อป้องกันการยุบตัวของไม้ไผ่ ซึ่งชั้นวางก้อนเห็ดจะวางห่างกันประมาณ 1-1.5 เมตร ความกว้างประมาณ 0.5 – 1.5 เมตร ความสูงประมาณ 2 – 2.30 เมตร ส่วนความยาวขึ้นอยู่กับขนาดของโรงเรือน จำนวนชั้น 5 – 6 ชั้น แต่ละชั้นห่างกัน 45 เซนติเมตร ส่วนชั้นล่างสุดห่างจากพื้นประมาณ 30 เซนติเมตร ซึ่งการทำชั้นจะทำตามความยาวของโรงเรือนและมีทางเดินรอบชั้นวางก้อนเห็ด



ภาพที่ 3.5 ตัวอย่างชั้นวางก้อนเห็ด



ภาพที่ 3.6 ระยะห่างระหว่างชั้นวางก้อนเห็ด

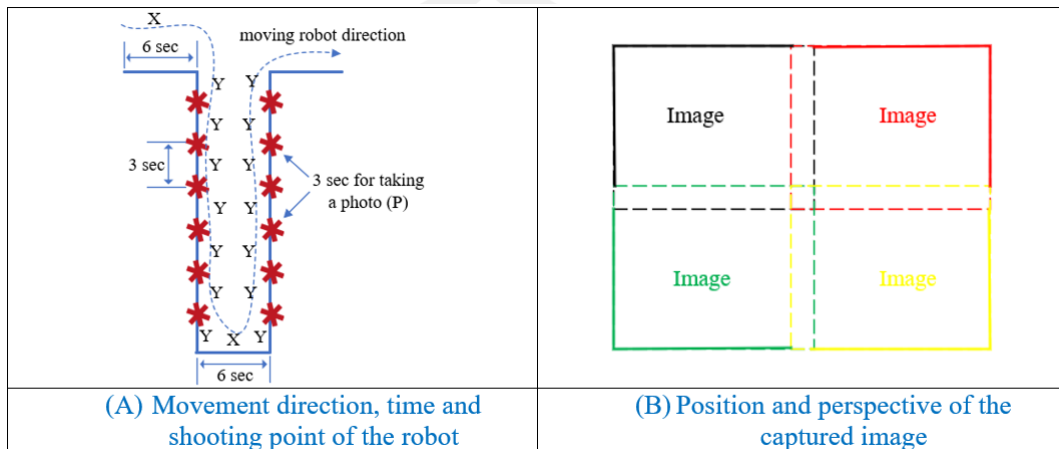
สำหรับงานวิจัยนี้ได้เลือกแบบชั้นวางเป็นชั้นวางก้อนเห็ดแบบตัว H หลังจากทำการออกแบบระบบภายในโรงเรือนเรียบร้อยแล้ว จะเป็นขั้นตอนในการเตรียมระบบสำหรับจัดเก็บภาพภายในโรงเรือนเกษตรอัจฉริยะมีรายละเอียดในหัวข้อถัดไป

### 3.3 การออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือนเกษตรอัจฉริยะ

การเตรียมระบบจัดเก็บภาพภายในโรงเรือนสามารถทำได้นั้น จะทำการออกแบบวิธีการถ่ายภาพและออกแบบหุ่นยนต์สำหรับการถ่ายภาพภายในโรงเรือนที่สามารถเคลื่อนขึ้น เคลื่อนลง และเคลื่อนซ้าย เคลื่อนขวาได้ เมื่อทำการเคลื่อนครบแต่ละจุดที่กำหนดแล้วจะทำการถ่ายภาพหรือเรียกว่า Photography robot (IBOT)

โดยการออกแบบระบบที่สามารถเคลื่อนและถ่ายภาพได้นั้น จะทำการกำหนดระยะของขอบภาพและระยะการวางกล้องโดยจะมีรายละเอียดในหัวข้อการออกแบบและพัฒนาระบบการ

วิเคราะห์โรคราเขียวของเห็ดนางฟ้า ซึ่งจะทำการกำหนดระยะการเคลื่อนของกล้องที่ 7 เซนติเมตร หรือหากนับเป็นวินาทีจะใช้เวลาในการเคลื่อนแต่ละจุดใช้เวลา 00.03 วินาที และจะถ่ายภาพเมื่อกล้องหยุดนิ่งในแต่ละระยะดังภาพที่ 3.7




ภาพที่ 3.7 การเคลื่อนกล้องเพื่อทำการถ่ายภาพ

เมื่อทำการถ่ายภาพเรียบร้อยแล้วในแต่ละระยะ กล้องจะทำการส่งไฟล์ภาพไปยังคอมพิวเตอร์ โดยการส่งภาพผ่าน IP ของกล้องซึ่งจะต้องอยู่ในวงเครือข่ายอินเทอร์เน็ตเดียวกัน โดยไฟล์ภาพที่ได้จะเป็นภาพนามสกุล JPG ส่งไปยังเครื่องคอมพิวเตอร์หลักที่จะใช้ในการวิเคราะห์โรค ลักษณะการส่งข้อมูลภาพดังแสดงในภาพที่ 3.8




ภาพที่ 3.8 การส่งภาพถ่ายผ่าน IP กล้อง CCTV

จากนั้นเป็นแนวความคิดการออกแบบตัวหุ่นยนต์ถ่ายภาพเพื่อใช้ในการเคลื่อนกล้อง CCTV ให้สามารถเก็บภาพและถ่ายภาพได้ตามที่กำหนด และกำหนดการวางกล้อง CCTV ด้านละ 1 ตัว เพื่อที่จะสามารถถ่ายภาพได้ทั้ง 2 ฝั่งของชั้นวางเห็ด ให้สามารถเก็บภาพถ่ายได้ครบและรวดเร็วเพิ่มขึ้นซึ่งมีรายละเอียดการออกแบบแสดงดังภาพที่ 3.9



ภาพที่ 3.9 ภาพรวมการออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือน



ภาพที่ 3.10 ภาพรวมการออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือน (ต่อ)

หลังจากได้รับหุ่นยนต์ต้นแบบที่ออกแบบด้วยโปรแกรม 3 มิติ ด้วยโปรแกรม Autodesk-Tinkercad แล้ว ขั้นตอนต่อไปคือการสร้างระบบรางเพื่อให้หุ่นยนต์เคลื่อนที่ภายในฟาร์มอัจฉริยะได้ในทิศทางที่กำหนดไว้ วัสดุของรางจะต้องมีขนาดเล็ก น้ำหนักเบา แข็งแรง และราคาไม่แพง ดังนั้นโปรไฟล์อลูมิเนียมจึงถูกนำมาใช้ในการสร้างระบบรางดังแสดงในภาพที่ 3.11

	
<p>(ก) อลูมิเนียมโปรไฟล์ V-Slot และอลูมิเนียมโปรไฟล์และชุดเคลื่อนที่</p>	<p>(ข) V-Slot Gantry Plate 20mm + อะลูมิเนียมอัลลอยเชื่อมขัดใส่เชื่อมขัด</p>
	
<p>(ค) V-slot 2020 Linear Actuator Bundle Belt Driven 350mm สำหรับขับเคลื่อนระบบราง</p>	<p>(ง) อลูมิเนียมท่อกลม 4ท่อน หนา 1.2 มม สีเงิน</p>
	
<p>(จ) ส่วนประกอบหุ่นยนต์</p>	

ภาพที่ 3.11 รายละเอียดชุดอุปกรณ์สำหรับการสร้างระบบราง

หลังจากติดตั้งหุ่นยนต์บนรางแล้ว ขั้นตอนต่อไปคือการติดตั้งไมโครคอนโทรลเลอร์ เช่น เซอร์ แอคทูเอเตอร์ (มอเตอร์) กล้อง IP ไฟส่องสว่าง และอุปกรณ์อื่น ๆ อุปกรณ์แต่ละตัวที่ติดอยู่กับหุ่นยนต์มีฟังก์ชันที่แสดงในตารางที่ 3.1


ตารางที่ 3.1 อุปกรณ์แต่ละตัวที่ติดอยู่กับหุ่นยนต์

ลำดับ	ชื่ออุปกรณ์และข้อมูลเฉพาะ	คำอธิบายการทำงานของอุปกรณ์
1	 <p>Arduino Microcontroller ATmega328P Operating Voltage 5V UNO R3 type SMD</p>	ควบคุมและใช้งานอุปกรณ์เซ็นเซอร์ (Impact switches) and actuators (Stepper motors and LED light bulb)
2	 <p>Stepper Motor 42BYGH47-401A Nema 17</p>	ควบคุมการเคลื่อนที่ของหุ่นยนต์ในแกน X และ Y
3	 <p>Switch Collision Module Sensor (Impact Switch Module)</p>	ระบุการชนของหุ่นยนต์เมื่อสิ้นสุดการเคลื่อนที่ของแกน X และ Y (เปลี่ยนทิศทางการเคลื่อนที่)
4	 <p>TB6600 &amp; TinyG2 Arduino Due wiring example for MOTOR 1 as K-ASL</p> <p>TB6600 Stepper Motor Driver</p>	ตัวขับเคลื่อนมอเตอร์สำหรับขับเคลื่อนมอเตอร์
5	 <p>Timing belt width 6-8 mm for 3D printer</p>	ใช้เพื่อบังคับหุ่นยนต์ให้เคลื่อนที่ในแกน X และ Y
6	 <p>CCTV MODEL: IPC-V380-IPC AK type IP Came: HD CAMERA V380-IPC 3</p>	กล้อง CCTV สำหรับถ่ายภาพเห็นที่ความละเอียด HD (720p) และสื่อสารผ่านเครือข่าย Wi-Fi
7	 <p>LED NEO LDAHV12DH5T 12w</p>	ให้แสงสว่างในขณะที่หุ่นยนต์กำลังถ่ายภาพ



ลำดับ	ชื่ออุปกรณ์และข้อมูลเฉพาะ	คำอธิบายการทำงานของอุปกรณ์
8	 Adapter 2000mA (DC 5.5 x 2.5MM) 12V 5A	แหล่งจ่ายไฟสำหรับไมโครคอนโทรลเลอร์ มอเตอร์ และเซ็นเซอร์
9	Other accessories fo CNC	อุปกรณ์เสริมอื่นๆ สำหรับประกอบเป็น หุ่นยนต์ ได้แก่ น็อต สกรู ฯลฯ เป็นต้น

### 3.4 การออกแบบและพัฒนาระบบการวิเคราะห์โรคเชื้อราเขียวของเห็ดนางฟ้า




ภาพที่ 3.12 กรอบการทำงานที่เสนอสำหรับการตรวจจับและแจ้งเตือนสำหรับระบบฟาร์มอัจฉริยะ

การออกแบบและพัฒนาระบบการวิเคราะห์โรคเชื้อราเขียวของเห็ดนางฟ้าผู้วิจัยได้ดำเนินการแบ่งวิธีการดำเนินการออกเป็น 7 ขั้นตอน ดังนี้ 1) ฟาร์มอัจฉริยะและการถ่ายภาพ 2) การออกแบบพัฒนาฟาร์มอัจฉริยะและหุ่นยนต์ถ่ายภาพ 3) การเตรียมข้อมูลภาพ 4) การเตรียมภาพ 5) การเลือกใช้โมเดล CNN และ 6) การวัดประสิทธิภาพและการประเมินผล และ 7) การวิเคราะห์โรคเชื้อราแบบอัตโนมัติ

1) ฟาร์มอัจฉริยะและการถ่ายภาพ (Smart farming and photography) เป็นส่วนหนึ่งของวิธีการสำหรับการสร้างหุ่นยนต์ถ่ายภาพก่อนเห็ดภายในฟาร์มอัจฉริยะ ซึ่งจากการศึกษาหลายพื้นที่และการรวบรวมข้อมูลปัญหาของโรคเชื้อราจากเห็ด พบว่าสาเหตุสำคัญของโรคเชื้อรามี 2 ประการ


ได้แก่ การปนเปื้อนของวัสดุปลูกระหว่างกระบวนการบรรจุก้อนเห็ด และความชื้นสะสมภายในโรงเรือนอัจฉริยะ โดยโรคเชื้อราจะเกิดขึ้นอย่างรวดเร็วหากมีการติดเชื้อตั้งแต่ 1 – 48 ชั่วโมง ดังแสดงในตารางที่ 2.2

2) การออกแบบ พัฒนาฟาร์มอัจฉริยะและหุ่นยนต์ถ่ายภาพ สำหรับภาพรวมของฟาร์มนวัตกรรมที่แท้จริงสำหรับการเพาะเห็ดแสดงในภาพที่ 3.13 อุปกรณ์ในฟาร์มอัจฉริยะประกอบด้วย พัดลมระบายอากาศ, ปั้มน้ำ, แผงระบายความร้อน (EVAP), แผงโซลาร์เซลล์, ตู้ควบคุมพลังงานแสงอาทิตย์ (อินเวอร์เตอร์), ระบบไฟฟ้า 220 โวลต์, กล้อง IP, ระบบไฟส่องสว่างตามภาพที่ 3.13 อุปกรณ์ IoT ได้แก่ ไมโครคอนโทรลเลอร์ อุ่นหมุมิ เช่น เซอร์ความชื้น ความชื้นในดิน การพ่นหมอกควัน และการให้แสงสว่าง (ภาพที่ 3.13) อุ่นหมุมิและความชื้นภายในฟาร์มอัจฉริยะอยู่ในช่วง 28-32 องศาเซลเซียส (°C) และ 60-80% ตามลำดับ (เหมาะสำหรับการเพาะเห็ด) ห้องควบคุมระบบตั้งอยู่นอกเรือนกระจกซึ่งประกอบด้วยระบบไฟฟ้า ระบบควบคุมอุปกรณ์ทั้งหมด ตัวรับเซ็นเซอร์ทั้งหมด และระบบคอมพิวเตอร์สำหรับการประมวลผล AI ดังแสดงในภาพที่ 3.13 (ค,ง)



ภาพที่ 3.13 โครงสร้างฟาร์มอัจฉริยะสำหรับการเพาะเห็ด

สำหรับการออกแบบหุ่นยนต์ถ่ายภาพนั้นจะออกแบบโดยจะให้เกษตรกรสัมผัสกับสปอร์ของเห็ดน้อยที่สุดโดยใช้หุ่นยนต์ถ่ายภาพภายในฟาร์มอัจฉริยะ คือ IBOT จากนั้นภาพเห็ดที่ถ่ายได้จะถูกประมวลผลด้วยการเรียนรู้เชิงลึกเพื่อทำนายโรคเชื้อราบนเครือข่ายไร้สาย IBOT ดังแสดงไว้ในภาพที่ 3.14 (ก) รูปแบบการเคลื่อนไหวของหุ่นยนต์เป็นคลื่นสี่เหลี่ยมดังแสดงในภาพที่ 3.14 (ข) เวลาเคลื่อนที่ของหุ่นยนต์ขณะถ่ายภาพคือ 15.8 นาทีต่อเมตร (เวลาเคลื่อนที่แกน X + เวลาเคลื่อนที่แกน Y + เวลาถ่ายภาพ) เพื่อป้องกันปัญหาภาพบิดเบี้ยวและภาพเบลอ เราจำเป็นต้องถ่ายภาพซ้อนเพื่อแก้ปัญหาภาพเบลอที่ขอบ ดังแสดงในภาพที่ 3.14 (ค) (ซ้อนภาพ 15%: 108x230 พิกเซล) ภาพกว้างประมาณ 17.06 ซม. และยาว 33.87 ซม. เราคำนวณระยะทางและความสว่างที่เหมาะสมที่สุดสำหรับการถ่ายภาพด้วยกล้อง IP โดยการทดลองกับระยะการถ่ายภาพสี่ระยะ: 50, 60, 70 และ 80 เซนติเมตร (ซม.) จากการทดลอง ระยะที่ดีที่สุดจากกล้องถึงเห็ดที่ภาพชัดที่สุดคือ 60 ซม. และแสงคือ 12 วัตต์ ดังแสดงในภาพที่ 3.14 (ง)



ภาพที่ 3.14 ภาพรวมของหุ่นยนต์ถ่ายภาพ (IBOT) และการกำหนดพารามิเตอร์

3) การเตรียมข้อมูลภาพ ส่วนนี้อธิบายวิธีการครอบตัดรูปภาพเห็ดโดยใช้ Mask R-CNN (โดยใช้ ResNet101) ตามภาพที่ 3.15 (ก) เป็นตัวอย่างภาพเห็ดที่ IBOT ถ่ายไว้ภายในฟาร์มอัจฉริยะ ที่มีขนาด 720 x 1,280 พิกเซล จริงๆ แล้ว เห็ดรามักเกิดขึ้นบริเวณหน้าก้อนเห็ด (บริเวณวงกลม) แล้วค่อยๆ ลามไปยังบริเวณอื่นๆ ดังนั้นพื้นที่นี้จึงถูกเลือกให้เป็นเป้าหมายของ Mask R-CNN [98] สำหรับการครอบตัดรูปภาพเอาท์พุทที่ครอบตัดด้วย Mask R-CNN จะคงที่ที่ 200 x 200 พิกเซล เสมอ และจำนวนภาพที่ครอบตัดจะได้ภาพ 13 ภาพโดยมีขั้นตอนต่อไปนี้




(ก) ภาพต้นฉบับที่ถ่ายได้จาก IBOT

(ข) รูปภาพที่มีคำอธิบายประกอบ (Annotation) รูปทรงหลายเหลี่ยม

ภาพที่ 3.15 ตัวอย่างภาพเห็ดต้นฉบับและภาพที่มีคำอธิบายประกอบ

3.1 กระบวนการใส่คำอธิบายประกอบ (Annotation process) ขั้นตอนนี้คือการทำเครื่องหมายวงกลมในภาพเห็ดต้นฉบับด้วยรูปหลายเหลี่ยมก่อนครอบตัด จำนวนรูปภาพทั้งหมดที่ใช้สำหรับการทำเครื่องหมายคือ 250 ภาพ แบ่งออกเป็น 2 กลุ่ม คือ ชุดข้อมูลภาพ 200 ภาพสำหรับการฝึกอบรม (80%) และชุดข้อมูลภาพ 50 ภาพสำหรับการทดสอบ (20%) รูปภาพทั้งหมดมีการทำคำอธิบายประกอบ (Annotation) ในรูปแบบหลายเหลี่ยมที่กึ่งกลางของรูปภาพเห็ดแต่ละรูปดังแสดงในภาพที่ 3.15 (ข) ผลลัพธ์ของขั้นตอนนี้คือตำแหน่งของรูปหลายเหลี่ยมที่ส่งออกในรูปแบบ JSON



ภาพที่ 3.16 ภาพตัวอย่างการแบ่งข้อมูลภาพสำหรับการทำ Mask R-CNN

3.2 กระบวนการครอบตัดโดย Mask R-CNN (Cropping process) เมื่อทำการใส่คำอธิบายประกอบเสร็จครบตามจำนวนภาพที่กำหนดโดยแบ่งภาพแสดงดังภาพที่ 3.16 และไฟล์ JSON ที่ส่งออกได้ถูกนำเข้ามายังกระบวนการนี้ของโมเดลการเรียนรู้ จำนวน 10 รอบ และค่าอื่น ๆ ทั้งหมดจะขึ้นอยู่กับ Mask R-CNN เริ่มต้น ซึ่งเริ่มต้นโดยใช้กลไกที่เรียกว่า Selective Search เพื่อแยกขอบเขตที่น่าสนใจ (ROI) โดยที่ ROI แต่ละอันจะเป็นสี่เหลี่ยมผืนผ้าที่อาจแสดงถึงขอบเขตของวัตถุในภาพ ขึ้นอยู่กับสถานการณ์ อาจมีสูงถึงสองพัน ROI หลังจากนั้นแต่ละ ROI จะถูกป้อนผ่านโครงข่ายประสาทเทียมเพื่อสร้างแอตทริบิวต์แอตพุต สำหรับแต่ละแอตทริบิวต์แอตพุต ROI ชุดของตัวแยกประเภทเวกเตอร์ที่รองรับจะถูกใช้เพื่อกำหนดประเภทอ็อบเจกต์ (ถ้ามี) ภายใน ROI [98] และทดสอบประสิทธิภาพคาบเกี่ยวกันด้วย Intersection over Union (IoU) สาเหตุของจำนวนรอบถูกกำหนดเพียง 10 รอบเนื่องจากความสอดคล้องของข้อมูลเฉลี่ยหรือจุดตัดผ่านสหภาพ (IoU) ที่ได้รับการทดลอง 10, 20 และ 30 รอบที่ไม่แตกต่างกัน ออบเจกต์ของภาพเห็นหลังจากการประมวลผล Mask R-CNN (โดยใช้ ResNet101) สำเร็จจะแสดงเป็นวงกลมดังแสดงในภาพที่ 3.17 (ค) หลังจากกระบวนการนี้สิ้นสุดลง โมเดลที่ผ่านการฝึกอบรมก็พร้อมสำหรับการทดสอบ ผลการวิจัยพบว่า Mask R-CNN สามารถค้นหาวัตถุทรงกลมทั้งหมด (Center of the Mushroom) มีค่าเฉลี่ยความสม่ำเสมอของชุดข้อมูลที่ 0.86 (86%) ค่า IoU [90] ที่มากกว่าหรือเท่ากับ 50% (0.5) เป็นที่ยอมรับได้ (เกณฑ์การทับซ้อนเชิงบวก) และอย่างอื่นไม่เป็นที่ยอมรับ (เกณฑ์การทับซ้อนเชิงลบ)



(ก) ภาพต้นฉบับ

(ข) ภาพที่ผ่านการทำคำอธิบายประกอบ (Annotation)

(ค) ผลลัพธ์การทำ Mask R-CNN

ภาพที่ 3.17 กระบวนการทำ Mask R-CNN

ในขั้นตอนการทดสอบแบบจำลองนำเข้าทั้งไฟล์ภาพทดสอบและไฟล์ที่มีคำอธิบายประกอบ เพื่อประเมินประสิทธิภาพของแบบจำลอง ผลการประเมินแสดงในภาพที่ 3.17 ผลการทดสอบแบบจำลองสามารถแบ่งออกเป็นสามส่วน:


(ก) ภาพต้นฉบับ

(ข) ผลลัพธ์ของการทำ Annotation

(ค) ความสามารถในการค้นหาวัตถุโดยใช้เทคนิค Mask R-CNN ผลการวิจัยพบว่า Mask R-CNN สามารถค้นหาวัตถุทรงกลมทั้งหมด (Center of the Mushroom) นอกจากนี้ ค่า IoU ที่ได้คือ 0.86 (86%) ซึ่งมากกว่าค่าเริ่มต้นด้วย (ค่าเริ่มต้นของ IoU = 0.5) หลังจากค้นหาวัตถุที่ต้องการได้ด้วยเทคนิค Mask R-CNN แล้ว ขั้นตอนต่อไปคือการครอบตัดหน้าก้อนเห็ดที่ละภาพ

หลังจากสามารถค้นหาตำแหน่งของวัตถุที่ต้องการด้วยเทคนิค Mask R-CNN แล้ว ขั้นตอนต่อไปเป็นการ Crop ภาพหน้าก้อนเห็ดดอกที่ละก้อน เพื่อนำไปใช้ในการเรียนรู้โมเดล CNN ซึ่งวิธีการ Crop ภาพดังนี้

1. ทำการหาตำแหน่ง X, Y ดัง FIGURE.18 โดยจะเริ่มที่ค่าตำแหน่ง X,Y เริ่มต้น (มุมบนซ้าย, มุมบนขวา) และค่าตำแหน่ง X,Y สุดท้าย (มุมล่างขวา, มุมล่างซ้าย)




ภาพที่ 3.18 ตัวอย่างตำแหน่งสำหรับครอบตัด

2. จากนั้นระบบจะทำการสร้าง Bounding box ขึ้นเพื่อให้เห็นตำแหน่งของหน้าก้อนเห็ดที่ Detection ได้และแสดงหมายเลขแต่ละก้อน เพื่อสามารถเปรียบเทียบรูปที่ได้หลังจากการ ครอบตัด ดังแสดงภาพที่ 3.19




ภาพที่ 3.19 กล่องขอบเขตสำหรับการตรวจจับ

3. ระบบหาจุดกึ่งกลางของตำแหน่งหน้าก้นเห็ดเพื่อทำการ Crop ภาพ ให้มีขนาด 200 x 200 พิกเซล ดังแสดงในภาพที่ 3.20




ภาพที่ 3.20 ตัวอย่างภาพที่ได้หลังจากการครอบตัด

เมื่อทำการ Crop ภาพหน้าก้นเห็ดได้ครบทั้งหมดแล้วทำการแยกข้อมูลภาพเป็น 2 ชุด คือ ชุดภาพที่เป็นโรค และไม่เป็นโรค โดยทำการจำแนกด้วยมือ เป็นการเตรียมภาพเพื่อนำเข้าสู่ขั้นตอนการทดสอบ Model ด้วย CNN โดยภาพที่ทำการแยกแยะนั้นจะแบ่งออกเป็นชุดข้อมูลที่เป็นโรค จำนวน 2,000 ภาพ และชุดข้อมูลที่ไม่เป็นโรค จำนวน 2,000 ภาพ ดังแสดงภาพที่ 3.21 และภาพที่ 3.22




ภาพที่ 3.21 ตัวอย่างภาพที่เป็นโรค (Disease)




ภาพที่ 3.22 ภาพตัวอย่างที่ไม่เป็นโรค (No-disease)

4) การเตรียมภาพสำหรับการทดลองหลังจากที่ได้ภาพหน้าก้นเห็ดที่เป็นโรคและไม่เป็นโรคจำนวนอย่างละ 2,000 ภาพ เข้าสู่ขั้นตอนการเตรียมภาพสำหรับการทดสอบ Model CNN โดยการทดลองจะแบ่งข้อมูลออกเป็น 2 แบบ คือ 1) ข้อมูลภาพที่เป็นโรคและไม่เป็นโรคที่ทำ Augmentation [99] และ 2) ข้อมูลภาพที่เป็นโรคและไม่เป็นโรคที่ไม่ได้ทำ Augmentation ซึ่งในการทดลองนี้พวกเราได้ทำการนำเทคนิค Augmentation มาใช้ในการเตรียมภาพเพื่อเป็นการเพิ่มความหลากหลายให้กับภาพที่นำมาใช้ในการทดลอง เป็นเทคนิคที่นำมาใช้ในการลดปัญหาการเกิด Overfitting [100] ของข้อมูลอีกวิธีหนึ่ง ซึ่งได้ทำการแบ่งข้อมูลสำหรับการทำ Augmentation จำนวน 65% ของชุดข้อมูล Train ดังแสดงในภาพที่ 3.24 และเลือกใช้จำนวน 5 วิธี ของเทคนิค Augmentation โดยทำการเลือกภาพด้วยวิธีการสุ่ม 13% ดังแสดงในตัวอย่างภาพที่ 3.23



ภาพที่ 3.23 ภาพตัวอย่างการใช้เทคนิค Augmentation

หลังจากเตรียมข้อมูลภาพสำหรับการทดลองครบทั้งหมดแล้ว เข้าสู่ขั้นตอนการแบ่งข้อมูลภาพสำหรับการ Train and Testing โดยจะแบ่งข้อมูลภาพดังภาพที่ 3.24



ภาพที่ 3.24 การแบ่งข้อมูลสำหรับการเรียนรู้และการทดสอบ

จากภาพที่ 3.24 เป็นการนำภาพที่ถูกแบ่งออกเป็น ภาพที่เป็นโรคและภาพที่ไม่เป็นโรค อย่างละ 2,000 บาท จากนั้นทำการแบ่งข้อมูลออกเป็น 2 ส่วน คือ ข้อมูลสำหรับการ Train 80% ซึ่งในการ Training จะทำการแบ่งข้อมูลสำหรับ Train 65% and Validation 15% และ ข้อมูลสำหรับการ Test 20% โดยทำการแบ่งข้อมูลแบบนี้ทั้งชุดข้อมูลที่เป็นโรคและไม่เป็นโรค

5) การเลือกใช้โมเดลเป็นการนำเสนอเทคนิค CNN สำหรับสร้างแบบจำลองโดยการเรียนรู้ สำหรับการ detection โรคเชื้อราเขียวของเห็ดนางฟ้าที่พัฒนาด้วย Google Colaboratory ซึ่งเป็นการเขียนโค้ดในเซิร์ฟเวอร์ระบบคลาวด์ของ Google และใช้ Keras เวอร์ชัน 2.6.0 ร่วมกับ Tensorflow เวอร์ชัน 2.6.0 เป็นเครื่องมือที่ใช้สำหรับสร้างแบบจำลองตามกระบวนการเรียนรู้เชิงลึก (Deep learning) ด้วยภาษา Python การสร้างแบบจำลองเพื่อใช้จำแนกโรคราเขียวของเห็ดนางฟ้า เพื่อวิเคราะห์ว่าก่อนเห็ดมีโอกาสเป็นโรคราเขียวกี่เปอร์เซ็นต์ โดยกำหนดรอบการทดสอบ (Epochs) จำนวน 30 รอบ ในการสร้างแบบจำลองครั้งนี้พวกเราได้ใช้แบบจำลอง (Model) ของ CNN (deep learning models) เนื่องจากชุดโมเดลของ CNN ได้มีการนำมาใช้และผ่านการทดสอบแล้วว่ามี ความสามารถ มีประสิทธิภาพ ประสบความสำเร็จในการตรวจสอบหาโรคพืชได้ และมีความถูกต้องในการทดสอบที่สูง ดังนั้นพวกเราจึงเลือกใช้โมเดลดังกล่าวจากงานวิจัยของ Chen J และคณะ [101] ดังนี้ DenseNet201, ResNet50, Inception V3 และ VGGNet19 โดยมีรายละเอียดขั้นตอนในการสร้างแบบจำลองดังนี้

1. ทำการแยกชุดข้อมูลภาพที่ได้ทำการแบ่งภาพที่มีการทำ Augmentation และ ภาพที่ยังไม่ได้ทำ Augmentation เพื่อที่จะทำการเปรียบเทียบประสิทธิภาพการทำนายด้วยแบบจำลองของ CNN

2. จากนั้นทำการกำหนดตัวแปร (Parameter) สำหรับการทดสอบโมเดลโดยมีรายละเอียดดังนี้

2.1 ทำการลดขนาดภาพให้มีความเหมาะสมสำหรับการนำไปใช้งาน โดยกำหนดขนาด (Image resize) 224 x 224

2.2 กำหนดขนาดของชุดข้อมูลที่จะนำไปทดสอบในโมเดลในแต่ละรอบ (Batch\_size) ขนาด 32

2.3 กำหนดจำนวนรอบที่ทำการทดสอบ (Epochs) จำนวน 300 รอบ



2.4 กำหนด Activation function เป็น Sigmoid เนื่องจากเป็นฟังก์ชันที่มีขนาด 0 – 1 และเป็นฟังก์ชันที่เหมาะสมกับการทำงานเนื่องจากงานวิจัยนี้มี class จำนวน 2 class

2.5 กำหนด Optimizers เป็น SGD เนื่องจากการอัปเดตค่าพารามิเตอร์ในทุก ๆ ชุดข้อมูลที่ฝึกสอน และเป็นอัลกอริทึมที่ไว เพราะทำการอัปเดตแค่ครั้งเดียวต่อการเทรน 1 รอบ

2.6 กำหนด Loss function เป็น binary\_crossentropy เนื่องจากงานวิจัยนี้มี class เพียงแค่ 2 class ดังนั้นจึงเลือกใช้ binary\_crossentropy

2.7 จากนั้นนำโมเดลของ CNN มาใช้เพื่อทดสอบหาค่าความถูกต้องและเปรียบเทียบหาโมเดลที่ให้ค่าความถูกต้องที่ดีที่สุด

3. ทำการเปรียบเทียบค่าความถูกต้องของแต่ละโมเดลและเลือกโมเดลนั้น เพื่อนำไปใช้ในการสร้างโมเดลสำหรับการวิเคราะห์หาโรคราเขียวของเห็ดนางฟ้าต่อไป

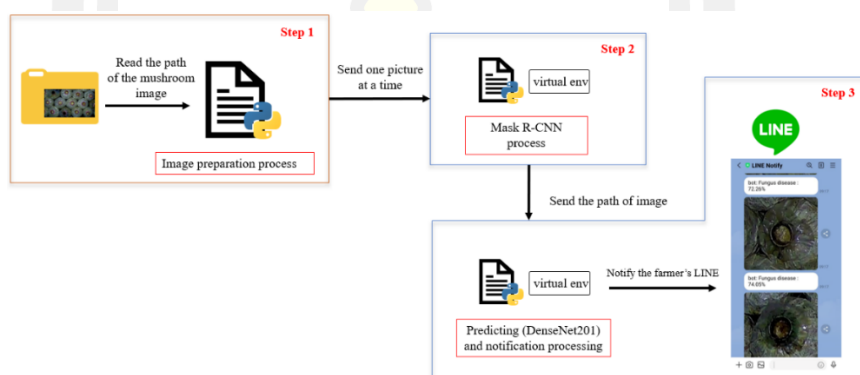
#### 6) การวัดประสิทธิภาพและการประเมินผล

การวัดประสิทธิภาพ Mask R-CNN สำหรับงานวิจัยนี้ใช้ Intersection over union (IoU) [80-83] คือ วิธีทางสถิติที่ใช้วัดความสอดคล้องของข้อมูลสองชุดที่นิยมนำมาใช้ในด้าน Object detection ซึ่งหาได้จากอัตราส่วนระหว่างพื้นที่เป็นจุดตัด (Intersection) ของ 2 bounding box หารด้วยพื้นที่ (Area) รวมของกรอบทั้งสอง โดยวิธีการนี้เดิมใช้ชื่อ Jaccard Similarity Index เป็นวิธีการในการหาจำนวนเปอร์เซ็นต์ (Percent) ที่ทับซ้อนกัน ระหว่างผลทำนาย คือ P (Predicted) และผลเฉลย คือ G (Ground truth) รายละเอียดดังที่กล่าวในบทที่ 2

การวัดประสิทธิภาพโมเดล สำหรับเบื้องต้นนี้ในงานวิจัยนี้จะทำการประเมินตาราง Confusion matrix เพื่อค้นหาค่าที่ดีที่สุดในทุกค่า คือ (1) ค่าความแม่นยำ (Precision : P) เป็นค่าที่บอกว่าโปรแกรมทำนายว่าจริงถูกต้องเท่าไร (2) การวัดค่าความระลึก (Recall : R) เป็นค่าที่บอกว่าโปรแกรมทำนายได้ว่าจริง มีอัตราส่วนเท่าไรกับค่าจริงทั้งหมด (3) ค่าเฉลี่ยประสิทธิภาพโดยรวม (F-measure : F1) เป็นการวัดค่าความถูกต้องการทดสอบที่พิจารณาทั้งความแม่นยำ และค่าความระลึกพร้อมกัน และ (4) การวัดค่าความถูกต้อง (Accuracy : A) เป็นค่าที่บอกว่าโปรแกรมสามารถทำนายได้ถูกต้องมากน้อยเท่าไร จากตัววัดที่กล่าวข้างต้นนั้น สามารถแทนค่าเพื่ออธิบายได้ด้วยตาราง Confusion matrix เพื่อวัดประสิทธิภาพของโมเดล (Model) ซึ่งในงานนี้เบื้องต้นจะทำการวัดค่าความถูกต้องเป็นหลัก เพื่อวัดประสิทธิภาพของแบบจำลอง ซึ่ง Confusion Matrix ถือเป็นเครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย หรือ Prediction ที่ทำนายจาก Model ที่สร้างขึ้น ใน Machine learning โดยมีแนวคิดจากการวัดว่า สิ่งที่เกิด (Model ทำนาย) กับ สิ่งที่เกิดขึ้นจริง มีสัดส่วนเป็นอย่างไร สมการตามที่ได้อธิบายในบทที่ 2 สำหรับงานวิจัยนี้ผู้วิจัยจะทำการเลือกใช้ค่าวัดประสิทธิภาพโมเดล 2 ค่า คือ ค่า F-measure และ ค่า Accuracy เนื่องจากในการถ่ายภาพก้อนเห็ดในช่วงแรกที่มีการนำก้อนเห็ดเข้าไปในโรงเรือน ก้อนเห็ดจะมีสีที่เหมือนกันทั้งหมด และยังไม่มีความแตกต่างทางด้านของสีก้อนเห็ดมาก จึงเป็นสาเหตุให้มีความต้องการที่จัดวัดค่า F-measure ของภาพเพื่อที่จะสามารถวิเคราะห์หาโรคราเขียวของเห็ดได้แม่นยำยิ่งขึ้น สำหรับค่า Accuracy หรือค่าความถูกต้อง จะนำมาใช้ในช่วงท้ายหรือช่วงที่ก้อนเห็ดได้มีการให้ผลผลิตไปได้ระยะกลาง ๆ ถึงท้ายของ

ก้อนเห็ด คือก้อนเห็ดเปิดหน้าก้อนเห็ดไปแล้วที่ 3-4 เดือน เนื่องจากในระยะดังกล่าวสีของก้อนเห็ดก็จะมีสภาพสีที่เริ่มแตกต่างกัน และมีการเปลี่ยนสีของก้อนเห็ด จึงอาจทำให้มีโอกาสในการที่จะหาความแม่นยำได้ยากขึ้น จึงต้องมีการนำค่าความถูกต้องมาใช้ในการหาค่าประสิทธิภาพของโมเดลในระยะหลัง ดังนั้นสำหรับงานวิจัยนี้จึงได้นำ 2 วิธีการหาค่าประสิทธิภาพนี้มาใช้ในวิเคราะห์การเกิดโรคราเขียวภายในฟาร์มเห็ดนางฟ้า

7) การวิเคราะห์โรคเชื้อราแบบอัตโนมัติ เมื่อได้โมเดลที่ทำการทดลองแล้วจะทำการนำโมเดลที่ได้มาใช้ในการตรวจสอบหาโรคโดยใช้ Python Virtual Environments สำหรับการสร้างแบบจำลองเครื่องเพื่อให้สามารถทำงานร่วมกันได้ทั้ง 3 ส่วน คือ ส่วนที่เป็น Client, Mask R-CNN และ Model predict เนื่องจากมีข้อจำกัดในเรื่องรุ่นของแพ็คเกจ (Package) และมีการใช้ Dependency ต่างเวอร์ชันกัน



ภาพที่ 3.25 การวิเคราะห์โรคเชื้อราแบบอัตโนมัติ

จากภาพที่ 3.25 มีขั้นตอนการพัฒนาระบบมีรายละเอียดดังนี้

1. นำภาพถ่ายที่ได้จาก IBOT เก็บไว้ในคอมพิวเตอร์หลัก โดยจะทำการกำหนดชื่อไฟล์ภาพด้วยวันที่ เดือน ปี เวลา นาที และวินาที (เป็นข้อมูล ณ ปัจจุบัน) เพื่อให้ง่ายต่อการนำไปใช้งานในส่วนถัดไปและเพื่อไม่ให้เกิดความซ้ำซ้อนของภาพเมื่อต้องมีการถ่ายภาพในวันต่อไป โดยจะส่งที่อยู่ของภาพไปยัง Server Mask R-CNN

2. Server run Mask R-CNN จะเป็นการจำลองเครื่องคอมพิวเตอร์ให้เป็น Server โดยใช้ Python Virtual Environments และใช้ Dependency package version 1.2 เนื่องจาก python versino ที่ใช้ใน Mask R-CNN นั้นยังไม่รองรับ version ใหม่ ๆ ของ Python ได้ โดยจะทำการหาหน้าในการหาหน้าก้อนเห็ดที่อยู่ในภาพ 1 ภาพ และทำการครอบตัดภาพนั้นออกมาให้มีขนาด 200 x 200 pixel จากนั้นจะทำการสร้าง Folder ขึ้นเพื่อเก็บภาพโดยใช้ วันที่ เดือน ปี เวลา นาที และวินาที (เป็นข้อมูล ณ ปัจจุบัน) สำหรับสร้างชื่อของ Folder จากนั้นจะทำการส่งที่อยู่ของภาพที่ครอบตัดได้ไปยัง Server Predict เพื่อทำนายผลต่อไป

3. Server Predict จะเป็นการจำลองเครื่องคอมพิวเตอร์ให้เป็น Server โดยใช้ Python Virtual Environments และใช้ Dependency package version 2.4 โดยทำหน้าที่ในการทำนายผลที่ได้จากภาพที่ส่งมาจาก Mask R-CNN โดยจะส่งผลค่าความถูกต้องในการเป็นโรคกีเปอร์เซ็น และส่งภาพที่เป็นโรคไปยัง application line ของเกษตรกร

กระบวนการทำงานทั้งหมดนี้เป็นการทำงานแบบ Reltime ด้วยเหตุนี้พวกเราจึงต้องทำการกำหนดชื่อไฟล์ภาพและFolder เก็บภาพเป็น วันที่ เดือน ปี เวลา นาที และวินาที (เป็นข้อมูล ณ ปัจจุบัน) เพื่อให้ง่ายและถูกต้องในการทำงานอีกทั้งเมื่อทำงานครบทั้ง 3 ขั้นตอนนี้ ภาพที่อยู่ใน Folder จะถูกลบเพื่อให้เครื่องคอมพิวเตอร์ไม่ต้องทำงานหนักเนื่องจากจะต้องเก็บภาพในจำนวนมากมายไว้ในเครื่องซึ่งจะทำให้การทำงานในเครื่องช้าได้ สำหรับเวลาที่ใช้สำหรับการทำนายผลการเกิดโรคเชื้อราของเห็ดนางฟ้าแบบ Reltiem นั้นใช้เวลา ทั้งหมด 00:02:03 นาที (หรือ 2 นาที 3 วินาที)



## บทที่ 4

### ผลการวิจัย

จากการทดลองตามวิธีการดำเนินงานการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าโดยใช้การเรียนรู้เชิงลึกสำหรับเกษตรกรอัจฉริยะ สามารถแบ่งผลการทดลองดังนี้

#### 4.1 ผลการประเมินสมาร์ฟาร์ม

การประเมินประสิทธิภาพเกษตรกรอัจฉริยะเป็นส่วนสำคัญเนื่องจากการทำระบบการวิเคราะห์โรคเชื้อรานี้ จะดำเนินการภายในระบบเกษตรกรอัจฉริยะทั้งหมดและเป็นวิธีการที่ช่วยป้องกันการแพร่กระจายของโรคเชื้อราภายในโรงเรือนหากมีการแพร่กระจายในวงกว้างฟาร์มจะเกิดความเสียหายเป็นอย่างมากและลุกลามได้เร็วเนื่องจากระบบเกษตรกรอัจฉริยะนั้นเป็นระบบปิด ซึ่งผลการประเมินเกษตรกรอัจฉริยะสามารถสรุปได้ดังตารางที่ 4.1

ตารางที่ 4.1 เกณฑ์การประเมินเกษตรกรอัจฉริยะ

ลำดับ	สภาพแวดล้อมที่หลากหลายภายในการทำฟาร์มอัจฉริยะ	สภาพแวดล้อมที่เหมาะสมสำหรับการเพาะเห็ด	ความสามารถในการควบคุมของการทำฟาร์มอัจฉริยะที่เรานำเสนอ	
			YES	NO
1.	อุณหภูมิ (Celsius: °C)	25 – 30 °C	✓	
2.	ความชื้น (Percentage: %)	60 – 70 %	✓	
3.	แสงสว่าง (Percentage: %)	20 – 30 %	✓	
4.	ความชื้นในดิน (Percentage: %)	60 – 70 %	✓	

ตารางที่ 4.1 แสดงผลการประเมินความสามารถในการควบคุมสภาพแวดล้อมต่าง ๆ ภายในฟาร์มอัจฉริยะ ผลการวิจัยพบว่าเกษตรกรอัจฉริยะออกแบบมาให้สามารถควบคุมสภาพแวดล้อมต่าง ๆ ให้เหมาะสมกับการเพาะเห็ด

#### 4.2 ผลการออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือนสมาร์ฟาร์ม


ผลการออกแบบหุ่นยนต์ถ่ายภาพภายในโรงเรือนเกษตรกรอัจฉริยะ ที่ได้วิเคราะห์และออกแบบหุ่นยนต์เพื่อใช้ในการถ่ายภาพก่อนเห็ดภายในโรงเรือนเพื่อนำภาพที่ได้นำไปใช้ในการสร้างโมเดลการวิเคราะห์โรคเชื้อรานี้ มีผลการออกแบบดังนี้



ส่วนประกอบชุดควบคุมการเคลื่อนที่ตามแนวแกน X แกน Y ด้านหน้า

ส่วนประกอบชุดควบคุมการเคลื่อนที่ตามแนวแกน X แกน Y ด้านหลัง

ภาพที่ 4.1 ส่วนประกอบชุดควบคุมการเคลื่อนที่ด้านหน้า-ด้านหลัง



ภาพที่ 4.2 การวางและติดตั้งกล้องสำหรับถ่ายภาพ

การเคลื่อนที่ของหุ่นยนต์ถ่ายภาพนั้นจะทำการเคลื่อนที่จากจุดเริ่มต้นซึ่งสามารถจะกำหนดจุดเริ่มต้นได้ว่าจะเริ่มจากซ้าย ไปขวา หรือจากขวา ไปซ้าย เมื่อได้จุดเริ่มต้นแล้วหุ่นยนต์จะทำการเลื่อนไปตามรางเลื่อนตามระยะเวลาที่กำหนด จากนั้นจะทำการหยุดถ่ายภาพโดยการเลื่อนถ่ายภาพไปเรื่อย ๆ จนถ่ายภาพครบทุกชั้นวางก้อนเห็ด

การประเมินประสิทธิภาพสำหรับหุ่นยนต์ถ่ายภาพ ประสิทธิภาพของหุ่นยนต์ในโรงเรียนได้รับการประเมินดังแสดงในตารางที่ 4.2 ตารางแสดงให้เห็นว่าหุ่นยนต์ถ่ายภาพที่ออกแบบสามารถทำหน้าที่ทั้งหมดตามที่กำหนด ซึ่งกล้องที่ติดตั้งในหุ่นยนต์นั้นเป็นกล้องวงจรปิด รุ่น : IPC-V380-IPC ประเภท AK IP Came : HD CAMERA V380-IPC 3


ตารางที่ 4.2 เกณฑ์การประเมินสำหรับหุ่นยนต์สร้างภาพ

ลำดับ	เงื่อนไขการทดสอบหุ่นยนต์	ความสามารถในการควบคุมของหุ่นยนต์ที่เรานำเสนอ	
		YES	NO
1.	ความสามารถในการเคลื่อนที่ในแกน X (60 sec per meter)	✓	
2.	ความสามารถในการเคลื่อนที่ในแกน Y (240 sec per meter)	✓	
3.	ความสามารถในการถ่ายภาพหุ่นยนต์ (6 times per meter)	✓	
4.	การควบคุมแสงสำหรับการถ่ายภาพหุ่นยนต์ (turn a lamp on and off 6 times per meter)	✓	
5.	การควบคุมความเร็วในการเคลื่อนที่ทั้งแกน X และ Y (200 Steps/Rev)	✓	
6.	ความสามารถในการส่งข้อมูลภาพผ่านเครือข่ายไร้สาย (2.4 GHz, 150 Mbps)	✓	

#### 4.3 ผลการออกแบบและพัฒนาระบบการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้า

ผลการออกแบบและพัฒนาระบบผู้วิจัยทำการอธิบายถึงการวัดประสิทธิภาพความสอดคล้องของเทคนิค Mask R-CNN และอธิบายผลการเปรียบเทียบผลโมเดลทั้ง 4 โมเดล รวมถึงผลการวัดประสิทธิภาพการสร้างระบบการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าที่ได้กล่าวถึงในบทที่ 3 หัวข้อการออกแบบและพัฒนาระบบการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้า มีรายละเอียดดังนี้

1) การวัดประสิทธิภาพความสอดคล้องของเทคนิค Mask R-CNN หรือเรียกว่าการทับซ้อนของชุดข้อมูล (Intersection over union: IoU) ซึ่งเทคนิคดังกล่าวนี้นำมาใช้ทั้งในขั้นตอนการเตรียมข้อมูลภาพก่อนเข้าทดลองกับโมเดล CNN และการนำมาใช้วิเคราะห์โรคด้วยระบบออนไลน์แบบ Real-time




ภาพที่ 4.3 ตัวอย่างการทับซ้อนของชุดข้อมูล

จากผลการทดสอบ (Testing)


ภาพที่ 4.3 ได้แบ่งออกเป็น 4 ภาพ โดยภาพที่ 4.3 (ก) คือภาพต้นฉบับ ภาพที่ 4.3 (ข) คือภาพที่เกิดจากการทำ Annotation และภาพที่ 4.3 (ค) เป็นผลที่ได้จากการ testing ด้วยเทคนิค

Mask R-CNN ซึ่งเป็นภาพ Result Mask ที่เกิดจากการเรียนรู้ของโมเดล ResNet101 (Mask R-CNN จะใช้โมเดลนี้เป็นหลัก) เมื่อนำภาพเข้าไปทดสอบพบว่าสามารถค้นหาภาพหน้าก้อนเห็ดได้ครบทุกภาพที่ 4.3 (ง) ด้วยเหตุนี้จึงทำให้เห็นว่าความสามารถในการเรียนรู้สำหรับการตรวจสอบตำแหน่งหรือค้นหาวัตถุภายในภาพด้วยเทคนิค Mask R-CNN นั้นให้ผลความถูกต้องในการวัดความสอดคล้องหรือทับซ้อนของชุดข้อมูล (Intersection over union: IoU) [80-83] ซึ่งมีค่าเฉลี่ยของความสอดคล้องของชุดข้อมูลอยู่ที่ 86% หรือ 0.86 ดังแสดงผลในภาพที่ 4.4 เป็นค่าความสอดคล้องที่มีประสิทธิภาพสูง โดยระดับผลค่า IoU ต่อตำแหน่งของวัตถุ นั้น ๆ ซึ่ง Mark Everingham และคณะ [90] ได้ทำการทดลองเพื่อหามาตรฐาน ประสิทธิภาพการทับซ้อนกันของ bounding boxes ไว้คือ เมื่อค่า IoU ที่ได้มีค่ามากกว่าหรือเท่ากับ 50% (0.5) เป็นการทับซ้อนในเชิงบวก (Positive overlap threshold) หรือเป็นการที่ซ้อนที่ยอมรับได้ ในขณะที่ต่ำกว่าเป็นการทับซ้อนเชิงลบ (Negative overlap threshold) ถือว่าไม่ดีและไม่สามารถยอมรับได้



ภาพที่ 4.4 กราฟแสดงค่าเฉลี่ยการทับซ้อนของข้อมูลภาพ

2) การเปรียบเทียบผลการทดลองโมเดล DenseNet201, ResNet50, InceptionV3 และ VGG19 ซึ่งจากผลการทดลองพบว่า DenseNet201 มีค่าความถูกต้องมากกว่าโมเดลอื่น ๆ ดังปรากฏในภาพที่ 4.5




DenseNet201

ResNet50

InceptionV3

VGG19

Augmentation



DenseNet201

ResNet50

InceptionV3

VGG19

No augmentation

ภาพที่ 4.5 เปรียบเทียบค่าความถูกต้องการเรียนรู้โมเดล CNN โดยแบ่งแสดงผลด้วยการใช้เทคนิค Augmentation

และ No augmentation



จากผลการทดลองการเรียนรู้ (Train) พบว่า DenseNet201 มีค่าความถูกต้องมากที่สุดทั้งการทำ Augmentation และ no augmentation นอกจากนี้ DenseNet201 มีค่า overfitting ที่น้อยที่สุดหากเปรียบเทียบกับ ResNet50, InceptionV3 and VGGNet29 การทำ Augmentation และ No augmentation พบว่า การทำ Augmentation นั้นมีการเกิด overfitting น้อยมาก กล่าวคือข้อมูลที่นำมาใช้ในการทดลองนั้นมีรูปแบบข้อมูลที่หลากหลายทำให้ไม่เกิดการจดจำหรือเกิดการเรียนรู้ได้ดี แม้หากมีข้อมูลใหม่ที่เข้ามาทดสอบก็สามารถที่จะตอบคำถามนั้นได้ เนื่องจากมีการเรียนรู้ข้อมูลมาหลากหลายรูปแบบ สำหรับกราฟ No augmentation จากภาพเกิด overfitting เกิดขึ้นอย่างเห็นได้ชัด แต่ภาพรวมของกราฟยังสามารถยอมรับได้เนื่องจากช่วงเริ่มต้นของกราฟมีการเรียนรู้ได้ดีมาตลอดในช่วงรอบ (Epoch) ที่ 1-40 จากนั้นเริ่มมีการเรียนรู้ข้อมูลในลักษณะแบบซ้ำ ๆ และคล้าย ๆ กัน กล่าวคือเริ่มไม่มีพัฒนาการในการเรียนรู้เพิ่ม จึงทำให้เกิด overfitting ขึ้นในรอบที่ 41-300 ซึ่งความหมายของ overfitting คือการที่ Model ที่ได้จากการ Training Data set มีค่าความถูกต้องในการบ่งบอกคลาสเป้าหมายสูง แต่เมื่อนำไปใช้กับข้อมูล Validation Data set หรือ Test data set ได้ค่าความถูกต้องต่ำ หรือ กล่าวอีกนัยหนึ่งคือ ตัวแบบที่ได้เป็นการเรียนรู้ข้อมูลจาก Training Data set ดีมาก แต่ไม่สามารถนำไปใช้กับข้อมูลที่ไม่เคยพบมาก่อนได้ดี

ตารางที่ 4.3 เปรียบเทียบผลการทดสอบโมเดล CNN

Testing CNN Model	Class	Augmentation				No augmentation			
		Accuracy (%)	Precision (%)	Recall (%)	F1 (%)	Accuracy (%)	Precision (%)	Recall (%)	F1 (%)
DenseNet201	Disease	86.50	86.50	88.15	87.45	89.74	91.45	90.25	91.48
	No Disease		87.24	85.45	86.50		90.57	92.70	91.74
ResNet50	Disease	70.74	73.72	66.70	69.71	74.25	74.20	75.25	75.23
	No Disease		69.00	76.33	72.74		75.24	74.27	74.25
InceptionV3	Disease	77.74	88.74	65.57	74.00	87.25	88.25	85.20	87.26
	No Disease		72.71	90.72	80.75		86.23	88.15	87.25
VGGNet19	Disease	76.24	74.33	81.00	77.67	83.49	81.41	86.49	84.45
	No Disease		79.67	72.33	75.24		86.42	80.40	83.49

จากตารางที่ 4.3 หลังจากทำการ Testing Model CNN ครบทุก Model แล้วพบว่า ทุกโมเดลมีค่าความถูกต้องมากกว่า 50% โดยโมเดล DenseNet201 มีค่าความถูกต้องมากที่สุดทั้งแบบ Augmentation และ No augmentation ผลการ Testing แสดงในตารางที่ 4 จะเห็นว่า No augmentation มีค่าความถูกต้องมากที่สุด ดังนั้นผู้วิจัยจึงเลือกที่จะนำ No augmentation มาใช้ในการสร้างโมเดลการตรวจ (Detection) เนื่องจากความจริงแล้วสำหรับงานการตรวจจับโรคเชื้อราของ

เห็นนางฟ้า นั้นจะถ่ายภาพหน้าก่อนเห็นแบบตรงทั้งหมดและไม่มีมุมมองอื่นมากนักเนื่องจากบริเวณที่เกิดเชื้อราของเห็ดนั้นจะเกิดขึ้นบริเวณปากก่อนเห็นเป็นส่วนมาก (จึงจำเป็นต้องวางกล้องถ่ายภาพตรงกับหน้าก่อนเห็นเท่านั้น) แต่อย่างไรก็ตามสำหรับการนำไปใช้งานจริงนั้นบางครั้งอาจมีการเกิดมุมมองที่หลากหลายเกิดขึ้นได้และเพื่อเป็นการรองรับการทำงานที่หลากหลายผู้วิจัยจึงเลือกใช้ชุดข้อมูลที่ใช้ผ่านการใช้เทคนิค Augmentation สำหรับการนำไปใช้พัฒนาระบบการแจ้งเตือนแบบเวลาปัจจุบัน

ผลสรุปจากตารางที่ 4.3 จากเหตุผลที่กล่าวมาแล้วข้างต้นทำให้ผู้วิจัยเลือกใช้ชุดข้อมูล Augmentation ซึ่งพบว่าค่าความถูกต้อง DenseNet201 อยู่ที่ 86.50% ซึ่ง DenseNet201 ได้แนวคิดจากปัญหาที่เกิดขึ้นของ ResNet50 กล่าวคือ DenseNet แต่ละเลเยอร์จะได้รับอินพุตเพิ่มเติมจากเลเยอร์ก่อนหน้าทั้งหมดและส่งต่อพีเจอร์แมปของตัวเองไปยังเลเยอร์ที่ตามมาทั้งหมด ใช้การเชื่อมต่อแต่ละชั้นและได้รับความรู้ร่วมกันจากทุกชั้นก่อนหน้าทั้งหมด จึงทำให้เกิดความหนาแน่นของ layer อีกทั้งยังสามารถใช้เส้นทางในการส่งข้อมูลได้หลายเส้นได้จึงทำให้ได้ชั้นที่ลึกขึ้นไปได้หลายเลเยอร์ และมีงานวิจัยของ Chen และคณะ[101] ได้วัดประสิทธิภาพของการจดจำวัตถุพบว่า DenseNet201 มีความสามารถในการวิเคราะห์ภาพและดึงคุณลักษณะของภาพที่เป็นโรคเชื้อราในพืชออกมาได้ดีกว่าโมเดลอื่น ๆ

สำหรับ Inception V3 มีค่าความถูกต้อง คือ 77.74% ซึ่งเป็นค่าความถูกต้องที่ได้รับรองมาจาก DenseNet201 ซึ่ง Inception v3 ทำงานผ่านพีเจอร์ขนาดต่างกัน มีการพิจารณาภาพไม่เหมือนกัน คือจะมีทั้งการพิจารณาแบบละเอียดพิจารณาแบบกว้างจึงทำให้เกิดมุมมองที่แตกต่างกัน ซึ่งมีความแตกต่างกับ DenseNet201 ที่มีการพิจารณามุมมองภาพที่ต่างกันแต่ DenseNet201 จะมองภาพลักษณะเดียวกันทั้งหมดมองซ้ำ ๆ ทั้งหมด

ถัดมา VGGNet19 ให้ค่าความถูกต้อง คือ 76.24% เนื่องจาก VGGNet19 นั้นมีโครงสร้างที่ซับซ้อนและมีการกำหนดขนาดรูปภาพที่นำเข้าต้องมีขนาด  $224 \times 224$  ซึ่งภาพในงานวิจัยนี้มีขนาดนำเข้าเพียง  $100 \times 200$  เท่านั้น จึงอาจเป็นสาเหตุทำให้ผลการเรียนรู้ได้ค่าความถูกต้องที่ไม่มากเท่าที่ควร ที่สำคัญหากจำนวนชั้นเลเยอร์ของ VGG ลึกมากเท่าไร gradient หายไปจึงส่งผลออกมาแย่ลง และสุดท้ายคือ ResNet50 มีค่าความถูกต้องที่น้อยกว่าโมเดลอื่น ๆ คือ 70.74% ซึ่ง ResNet50 จะมีลักษณะการทำงานคล้ายกับ VGG และด้วยปัญหาที่พบใน VGG จึงทำให้เกิดแนวคิดการเพิ่มทางลัดเพิ่ม (Residual) ต่อเพิ่มกับเส้นทางหลักเพื่อให้เกิดการเรียนรู้เพิ่มขึ้น เนื่องจากมีช่องทางให้เรียนรู้ที่หลากหลายขึ้น ซึ่งอาจด้วยแนวคิดของ ResNet ที่กล่าวมาจึงทำให้ผลค่าความถูกต้องออกมาน้อยกว่าโมเดลอื่น ๆ (จำนวน layer มากเกินไปอาจส่งผลให้ความสามารถในการเรียนรู้ลดลงเนื่องจากมีหลายมุมมอง กว้างเกินไปและลึกเกินไป)

3) ผลการวัดประสิทธิภาพการวิเคราะห์โรคเชื้อราแบบทันที (Real-time) ได้จากการใช้งานจริงจากระบบที่พัฒนาและออกแบบ โดยในการใช้งานจริงได้ทำการถ่ายภาพจากโรงเรือนจริงของเกษตรกร โดยทำการถ่ายภาพด้วยหุ่นยนต์ถ่ายภาพแบบ Real-time จำนวน 100 ภาพ จากนั้นส่งภาพเข้าไปวิเคราะห์ตามขั้นตอนที่กล่าวไว้ในบทที่ 3 โดยการวัดประสิทธิภาพใช้ตาราง Confusion

matrix ซึ่งค่าที่ใช้ในการวัดประสิทธิภาพ คือ ค่า F1 เนื่องจากต้องการหาประสิทธิภาพของโมเดลที่ใช้ในการทำนายมีการวิเคราะห์โรคได้ถูกต้องว่าสิ่งที่พบนั้นคือ Disease จริง ๆ ในขณะที่เดียวกันก็ต้องตรวจจับ Disease ได้ด้วย ซึ่งเห็นได้ว่าประสิทธิภาพของโมเดลที่เลือกใช้นี้มีความสามารถในการวิเคราะห์โรคได้ 73.05% ดังผลในตารางที่ 4.4

		Predicted	
		Disease	No disease
Actual	Disease	50	10
	No disease	17	23

ภาพที่ 4.6 Confusion matrix

ตารางที่ 4.4 ผลการวิเคราะห์โรคเชื้อราแบบทันที (Real-time)

โรค\ ค่า Confusion matrix	Accuracy	Precision	Recall	F1
Disease	73.05	74.62	83.33	78.79
No disease	27.03	69.69	57.50	63.28

4) สรุปผลการประเมินประสิทธิภาพของระบบการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าสำหรับสมาร์ตฟาร์ม เป็นการประเมินจากเกษตรกรที่ทำโรงเรือนด้วยระบบสมาร์ตฟาร์ม และมีการนำระบบที่พัฒนาพร้อมกับหุ่นยนต์เข้าไปทดสอบประสิทธิภาพในโรงเรือนจริง ผลปรากฏว่าระบบสามารถวิเคราะห์โรคได้ในระดับ ซึ่งสรุปผลการวิเคราะห์ออกเป็น 2 ส่วนดังนี้

ส่วนที่ 1 เป็นข้อมูลทั่วไปของผู้ตอบแบบสอบถาม

ส่วนที่ 2 เป็นความคิดเห็นเกี่ยวกับประสิทธิภาพของระบบ โดยประเมินทั้งหมด 4 ด้าน

ดังนี้

- 1.ด้านกระบวนการ/ขั้นตอนการใช้งานระบบ
- 2.ด้านประสิทธิภาพของระบบ
- 3.ด้านความสะดวก สวยงาม
- 4.ด้านคุณภาพระบบ

ตารางที่ 4.5 การวิเคราะห์ข้อมูล ตอนที่ 1 ข้อมูลทั่วไปของผู้ตอบแบบสอบถาม

ตัวแปร	จำนวนคน (5 คน)	ร้อยละ
1.เพศ		
1.1 เพศชาย	5	100
1.2 เพศหญิง	-	
2.อายุ		
2.1 ต่ำกว่า 19 ปี	-	-
2.2 19-24 ปี	-	-
2.3 25-40 ปี	1	20
2.4 40 ปีขึ้นไป	4	80
3.ระดับการศึกษา		
3.1 ต่ำกว่า ป.ตรี	-	-
3.2 ป. ตรี	5	100
3.3 ป. โท	-	-
3.4 สูงกว่า ป. โท	-	-
4. ระยะเวลาการทำสมาร์ทฟาร์ม		
4.1 1-5 ปี	2	40
4.2 มากกว่า 5 ปี	3	60
5. ความถี่ในการเข้าโรงเรียนสมาร์ทฟาร์ม		
5.1 ทุกวัน	5	100
5.2 สัปดาห์ละครั้ง	-	-
5.3 2-3 วัน/ครั้ง	-	-
5.4 อื่น ๆ	-	-

จากตารางผลการวิเคราะห์ข้อมูลพบว่า ผู้ตอบแบบสอบถามเป็นเพศชาย โดยมีจำนวน 5 คน คิดเป็นหนึ่งร้อยเปอร์เซ็นต์ อายุผู้ตอบแบบสอบถาม 40 ปีขึ้นไป มีจำนวน 4 คน คิดเป็นร้อยละ 80 และอายุระหว่าง 25-40 ปี มีจำนวน 1 คน คิดเป็นร้อยละ 20 ตามลำดับ ระดับการศึกษาผู้ตอบแบบสอบถามอยู่ในระดับปริญญาตรี จำนวน 5 คน คิดเป็นหนึ่งร้อยเปอร์เซ็นต์ ระยะเวลาการทำสมาร์ทฟาร์มผู้ตอบ

แบบสอบถามมีจำนวน 3 คน คิดเป็นร้อยละ 60 และมีจำนวน 2 คน คิดเป็นร้อยละ 40 ตามลำดับ และความถี่ในการเข้าโรงเรียนสมาร์ทฟาร์มมีผู้ตอบแบบสอบถามทุกวัน จำนวน 5 คน คิดเป็นหนึ่ง ร้อยเปอร์เซ็นต์

ตารางที่ 4.6 การวิเคราะห์ข้อมูล ตอนที่ 2 ความคิดเห็นเกี่ยวกับประสิทธิภาพของระบบ

ประเด็นการวัดประสิทธิภาพของระบบ	ระดับความคิดเห็น					ค่าเฉลี่ย การวัด ประสิทธิภาพ ของระบบ	ร้อย ละ
	มากที่สุด	มาก	ปาน กลาง	น้อย	น้อย ที่สุด		
ด้านกระบวนการ/ขั้นตอนการใช้งานระบบ						4.60	92
1.รูปแบบการใช้งานระบบ ความยาก - ง่าย	5					5.00	100
2.กระบวนการทำงานของระบบ	1	4				4.20	84
ด้านประสิทธิภาพของระบบ						4.38	87.50
1.ความถูกต้อง แม่นยำของระบบ		4	1			3.80	76
2.ตรงตามวัตถุประสงค์ที่ต้องการ	5					5.00	100
3.การออกแบบให้ใช้งานง่าย ไม่ซับซ้อน		4	1			3.80	76
4.ความเป็นปัจจุบันของข้อมูล	5					5.00	100
5.ระบบวิเคราะห์โรคเชื้อราได้ถูกต้อง แม่นยำ		3	2			3.60	72
ด้านความสะดวก สวยงาม						4.40	88
1.ความสะดวกในการใช้งานระบบ	4	1				4.80	96
2.ความเหมาะสมในการใช้งานระบบ		5				4.00	80
ด้านคุณภาพของระบบ						5.00	100
1.ความพึงพอใจในการใช้งาน	5					5.00	100
2.ความสามารถของระบบ ในการนำไปใช้ ประโยชน์	5					5.00	100
ผลรวมการวัดประสิทธิภาพของระบบ						4.47	89.45

จากตารางการวิเคราะห์ข้อมูล ตอนที่ 2 ความคิดเห็นเกี่ยวกับประสิทธิภาพของระบบหากเรียงตามค่าเฉลี่ยพบว่า ด้านคุณภาพของระบบ มีค่าเฉลี่ย 5.00 อยู่ในระดับมากที่สุด ด้านกระบวนการ/ขั้นตอนการใช้งานระบบ มีค่าเฉลี่ย 4.60 อยู่ในระดับมากที่สุด ด้านความสะดวก สวยงาม มีค่าเฉลี่ย 4.40 อยู่ในระดับมาก และด้านประสิทธิภาพของระบบ มีค่าเฉลี่ย 4.38 อยู่ในระดับมาก ตามลำดับ และภาพรวมของแบบประเมินการวัดประสิทธิภาพของระบบมีค่าเฉลี่ย 4.47 อยู่ในระดับมาก ผลการประเมินทำให้เห็นว่าเกษตรกรอยู่ในระดับมาก ซึ่งหากพิจารณาแต่ละด้านนั้นพบว่าด้านประสิทธิภาพของระบบมีค่าเฉลี่ยน้อยที่สุด แต่ก็ยังอยู่ในระดับมาก ทำให้เห็นว่าระบบที่มีการพัฒนาขึ้นนั้นมีความถูกต้อง แม่นยำ ตรงตามวัตถุประสงค์ที่ต้องการ ออกแบบให้ใช้งานง่ายไม่ซับซ้อน มีความเป็นปัจจุบันของข้อมูล และระบบวิเคราะห์โรคเชื้อราได้ถูกต้องแม่นยำ ดังนั้นหากมีการพัฒนาต่อยอดต่อไปข้อมูลนี้จะนำไปใช้ในการพัฒนาระบบให้ดียิ่งขึ้น

#### 4.4 สรุปผลการทดลอง

จากการทดลองทั้งหมดนี้ทำให้เห็นว่าโมเดลที่เลือกมาจากงานวิจัยของ Junde chen และคณะ [101] ได้เลือกใช้โมเดล CNN ในการแยกแยะโรคพืช ซึ่งผลที่ได้นั้นมีความสอดคล้องและใกล้เคียงกับโมเดลที่เลือกใช้ แต่อาจเป็นด้วยลักษณะข้อมูลหรือภาพที่ได้มานั้นเป็นภาพที่ถ่ายในสถานที่มืดและแสงสว่างมีไม่มากพอจึงทำให้ผลการทดลองได้ผลของโมเดลที่แตกต่างกัน โดยในงานของ Junde นั้นผลการทดลองโมเดลของ CNN โมเดลที่มีค่าความถูกต้องมากที่สุดคือ Inception V3 แต่ในการทดลองงานวิจัยนี้โมเดลที่มีค่าความถูกต้องมากที่สุดคือ DenseNet201 แต่อย่างไรก็ตามในงานของ Junde ยังได้ค่าความถูกต้องของโมเดล DenseNet201 รองลงมาจาก Inception V3 ทำให้เห็นว่าโมเดล DenseNet201 นั้นมีความสามารถในการวิเคราะห์งานในด้านโรคพืชได้ และสามารถวิเคราะห์การเกิดโรคราเขียวของเห็ดนางฟ้าได้เช่นกัน อย่างไรก็ตามในงานด้านการเรียนรู้เชิงลึกนั้น ยังสามารถที่จะปรับปรุงหรือต่อยอดโมเดลต่าง ๆ ได้อย่างหลากหลายขึ้นอยู่กับลักษณะของงาน และผลการทดลองที่ได้ว่าอยู่ในระดับที่ดีหรือไม่

สำหรับชุดข้อมูลที่ใช้ในการทดลองนี้เนื่องจากภาพต้นฉบับที่ได้จากหุ่นยนต์ถ่ายภาพเป็นการถ่ายภาพที่มีทั้งก้อนเห็ดที่เป็นโรคราและไม่เป็นโรครา จึงไม่สามารถแบ่งตัวเลขของข้อมูลได้ชัดเจนว่าภาพที่ครอบตัดได้นั้นอยู่ในระยะใดบ้าง ซึ่งเห็นได้จากผลการทดลองโมเดลพบว่า ภาพที่เป็นโรคราเชื้อราผ่านการครอบตัดมาแล้วโดยส่วนมากจะอยู่ในระยะที่ 3 – 7 ดังแสดงในตารางที่ 2.2 ซึ่งไม่สามารถนับเป็นจำนวนตัวเลขแต่ละระยะได้ชัดเจน ดังนั้นจึงสรุปได้ว่าภาพที่ถ่ายได้นั้นส่วนมากอยู่ในระยะที่ 3 – 7 ซึ่งจากปัญหานี้ทำให้ทราบว่าควรที่จะทำการเก็บภาพในระยะที่ 1 – 3 ให้มีจำนวนเพิ่มมากขึ้นเพื่อให้ระบบมีความแม่นยำมากยิ่งขึ้น

สุดท้ายนี้ในส่วนของ Mask R-CNN นั้นยังถือว่าเป็นเทคนิควิธีการที่ยังเก่าอยู่ ซึ่งปัจจุบันนี้ ได้มีเทคนิคที่ดีและใหม่กว่าเช่น Fast R-CNN ที่จะช่วยเพิ่มประสิทธิภาพความเร็วในการวิเคราะห์

ผลได้เร็วยิ่งขึ้นอีกทั้งยังสามารถทำการวิเคราะห์วัตถุได้ ดังนั้นจึงเป็นแนวทางที่เหมาะสมสำหรับการพัฒนาระบบงานต่อไป

#### 4.5 สรุปเทคนิคและวิธีการที่เลือกใช้ในงานวิจัย

สำหรับหัวข้อนี้เป็นการสรุปถึงเทคนิค วิธีการและการเลือกใช้ฟังก์ชัน ที่นำมาใช้ในการวิจัยโดยผู้วิจัย จะทำการสรุปรายละเอียดดังตารางที่ 4.7

ตารางที่ 4.7 ตารางสรุปเทคนิค วิธีการและการเลือกใช้ฟังก์ชัน

ลำดับที่	เทคนิค วิธีการ และโมเดล	เหตุผลในการเลือกใช้
1	ไฟที่ใช้ในการติดกล้องถ่าย CCTV ขนาด 12 วัตต์	เนื่องจากแสงสว่างระดับนี้ไม่ส่งผลกระทบต่อการเจริญเติบโตของเห็ด และสว่างเฉพาะจุดที่ต้องการถ่ายภาพและความร้อนไม่ร้อนเกินไป
2	การเตรียมภาพสำหรับตัดหน้าก้อนเห็ดมีขั้นตอนดังนี้ - ทำการปรับปรุงภาพโดยการ blur ภาพ - เมื่อทำภาพ blur แล้วทำการปรับภาพให้มีความคมชัดขึ้น โดยใช้วิธี Unsharp masking - เมื่อได้ภาพที่ทำให้คมชัดขึ้นก็จะทำการ blur อีกครั้ง และแปลงภาพเป็นภาพสีเทา (Grayscale) - จากนั้นทำการ blur อีกครั้งด้วยวิธี Canny	- เพื่อลดจำนวนจุดภาพเล็ก ๆ หรือสัญญาณรบกวนในภาพออก - เป็นวิธีการที่ช่วยทำให้ขอบภาพชัดขึ้น  - เพื่อที่จะหาจุดเด่นของขอบให้มีความชัดมากขึ้น  - เป็นวิธีการที่ทำให้เห็นเส้นขอบภาพได้ชัดเจนมากกว่าวิธีการอื่น ๆ อย่างเห็นได้ชัด
3	เมื่อเตรียมภาพเรียบร้อยแล้วจึงทำการหาพื้นที่วงกลมของหน้าก้อนเห็ด เพื่อทำการหาจุดกึ่งกลางวงกลมสำหรับการครอบตัดภาพออกมาด้วยวิธี Hough Circle	ในการหาวงกลมโดยทางสูตรคณิตศาสตร์นั้นคือ $(x-xcenter)^2+(y-ycenter)^2=r^2$ เมื่อ $(xcenter,ycenter)$ โดยจะหาตรงกลางของวงกลมก่อน และ $r$ นั้นคือ รัศมีของวงกลม จากนั้นจะมี 3 parameter ที่จำเป็นต้องมีความละเอียด 3 มิติมาช่วย โดย OpenCV นั้นมีฟังก์ชันที่ช่วยในการหาและแก้สูตรนั้น และพลิกแพลงการใช้งาน Hough Gradient Method โดยใช้การไล่ระดับสีของ Edges โดยฟังก์ชันที่ใช้คือฟังก์ชัน <code>cv2.HoughCircles()</code> .

ลำดับที่	เทคนิค วิธีการ และโมเดล	เหตุผลในการเลือกใช้
4	ภาพที่ใช้ในการทดลองมีขนาด 200 x 200 พิกเซล	เนื่องจากภาพที่ได้นั้นหลังจากครอบตัดแล้วได้ขนาด 200 x 200 พิกเซล เพื่อให้ภาพมีขนาดเป็นจัตุรัสจึงใช้ขนาด 200 x 200 พิกเซล
5	กำหนดขนาดของชุดข้อมูลที่จะนำเข้าไปทดสอบในโมเดลในแต่ละรอบ (Batch_size) ขนาด 32	โดยส่วนมากขึ้นอยู่กับความเหมาะสมของข้อมูลซึ่งโดยส่วนมากหลาย ๆ งานจะเลือกขนาด 32
6	กำหนดจำนวนรอบที่ทำการทดสอบ (Epochs) จำนวน 30 รอบ	โดยหลักแล้วสามารถกำหนดจำนวนรอบได้มากถึง 100,000 รอบ ขึ้นอยู่กับว่าโมเดลสามารถพัฒนาได้มากถึงรอบที่กำหนดหรือไหม ซึ่งบางงานไม่สามารถพัฒนาได้ครบตามจำนวนรอบที่กำหนด สำหรับงานวิจัยนี้ได้กำหนดเพียง 30 รอบ เนื่องจากใช้เวลาในการทดลองไม่นานมากเกินไป และด้วยข้อจำกัดของพื้นที่ที่ใช้ในการรันข้อมูล
7	กำหนด Activation function เป็น Sigmoid	เนื่องจากเป็นฟังก์ชันที่มีขนาด 0 - 1 และเป็นฟังก์ชันที่เหมาะสมกับการทำงานเนื่องจากงานวิจัยนี้มี class จำนวน 2 class
8	กำหนด Optimizers เป็น SGD	เนื่องทำการอัปเดตค่าพารามิเตอร์ในทุก ๆ ชุดข้อมูลที่ฝึกสอน และเป็นอัลกอริทึมที่ไว เพราะทำการอัปเดตแค่ครั้งเดียวต่อการเทรน 1 รอบ
9	กำหนด Loss function เป็น binary_crossentropy	เนื่องจากงานวิจัยนี้มี class เพียงแค่ 2 class ดังนั้นจึงเลือกใช้ binary_crossentropy





## บทที่ 5

### สรุปผล อภิปรายผล และข้อเสนอแนะ

การดำเนินการวิจัยนี้เป็นงานวิจัยเชิงประยุกต์ (Applied research) เพื่อสร้างระบบที่ควบคุมสภาพแวดล้อมที่เหมาะสมในการเพาะปลูก และสามารถวิเคราะห์โรคราเขียวสำหรับเห็ดนางฟ้า ซึ่งเป็นการประยุกต์การทำงานของอินเทอร์เน็ตทุกสรรพสิ่ง (Internet of things) การประมวลผลภาพ (Image processing) และปัญญาประดิษฐ์ (Artificial intelligent) สามารถสรุปผลอภิปรายผล ปัญหา อุปสรรคในการดำเนินงาน และข้อเสนอแนะต่าง ๆ ดังนี้

#### 5.1 สรุป และอภิปรายผล

การวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าโดยใช้การเรียนรู้เชิงลึกสำหรับเกษตรกรอัจฉริยะ เป็นการพัฒนาแบบประยุกต์ที่มีการนำเทคโนโลยีทางด้านอินเทอร์เน็ตทุกสรรพสิ่ง (Internet of thing) และเทคนิคการเรียนรู้เชิงลึกทางด้านปัญญาประดิษฐ์ (Artificial Intelligence) ให้สามารถทำงานร่วมกันและสามารถนำมาใช้สำหรับช่วยให้เกษตรกรมีสุขภาพที่ดีและมีผลผลิตที่ดีไปพร้อมกัน โดยแนวคิดในการพัฒนาระบบดังกล่าวนี้ ได้มีการลงพื้นที่จริงของเกษตรกรและได้เห็นถึงปัญหาที่เกิดขึ้นจริงจากเกษตรกร จากการพูดคุยและปรึกษาถึงปัญหาและแนวทางแก้ที่ทีมผู้วิจัยจึงได้เสนอแนวคิดดังกล่าวและนำไปสู่การพัฒนาแบบ โดยการวางแผนและวิเคราะห์ถึงวิธีการในการดำเนินงานดังนี้

1. ใช้กล้อง CCTV สำหรับการถ่ายภาพก่อนเห็ดภายในโรงเรือนเกษตรกรอัจฉริยะของเกษตรกร เหตุผลที่ใช้กล้อง CCTV นั้นเนื่องจากมีค่าใช้จ่ายไม่สูงมากนัก หาซื้อได้ตามท้องตลาด และมีคุณภาพที่สูง
2. ทำการนำหลอดไฟให้แสงสว่างบริเวณหน้ากล้อง เพื่อเพิ่มความสว่างให้กับภาพขณะถ่ายภาพซึ่งจะช่วยให้เห็นรายละเอียดของหน้าก้อนเห็ดได้ชัดเจนขึ้น เนื่องจากปกติแล้วเชื้อรามักจะเกิดบริเวณหน้าปากถุงก้อนเห็ด
3. วัดระยะการถ่ายภาพเพื่อเก็บความคมชัดของภาพโดยการวัดมีทั้งหมด 4 ระยะ คือ ระยะ 50 เซนติเมตร 60 เซนติเมตร 70 เซนติเมตร และ 80 เซนติเมตร พบว่าระยะ 60 เซนติเมตรให้ภาพที่คมชัดกว่า เหตุผลที่ทำการวัดระยะการตั้งกล้องเป็นเซนติเมตรเนื่องจากกล้อง CCTV โดยส่วนมากไม่สามารถปรับโฟกัสและซูมเข้าออกอัตโนมัติได้
4. เมื่อได้ระยะที่เหมาะสมกับการถ่ายภาพแล้วจะนำไปสู่การพัฒนาหุ่นยนต์สำหรับการวิ่งถ่ายภาพภายในโรงเรือนเกษตรกรอัจฉริยะ โดยกำหนดระยะการวางหุ่นยนต์กับชั้นวางก้อนเห็ด 60 เซนติเมตร และระยะการเดินของหุ่นยนต์ (ระยะความยาวของชั้นวางก้อนเห็ด) โดยใช้ระยะมาตรฐาน 150 เซนติเมตร
5. ภาพที่ได้จากการถ่ายของหุ่นยนต์ถ่ายภาพก้อนเห็ดแล้ว นำไปสู่การนำภาพที่ได้ไปใช้ในการวิเคราะห์โดยใช้เทคนิค Image processing คือ การเตรียมภาพที่ถ่ายได้จำนวน 250 ภาพ ด้วย

การใช้เทคนิค Mask R-CNN ซึ่งเป็นเทคนิคที่ช่วยในการหาวัตถุภายในภาพเพื่อให้สามารถรู้จำและเรียนรู้ลักษณะของวัตถุที่ต้องการภายในภาพ ด้วยงานวิจัยนี้ภาพถ่ายหน้าก่อนเห็ดนั้นมีเพียง 1 คลาสคือ มีเพียงวัตถุเดียวที่ต้องการค้นหาภายในภาพ (วงกลมหน้าก่อนเห็ด) จึงสามารถวิเคราะห์หาวัตถุในภาพได้อย่างถูกต้อง ซึ่งเทคนิคนี้ผู้วิจัยได้นำมาใช้ทั้งในส่วนของเตรียมภาพสำหรับการนำไปใช้วิเคราะห์ด้วยโมเดล CNN และการวิเคราะห์ภาพแบบเรียลไทม์ (Real-time) เพื่อตรวจหาโรคเชื้อรา

6. เทคนิค Mask R-CNN จะทำให้สามารถหาตำแหน่งของวัตถุในภาพ โดยนำตำแหน่งที่ได้จากการวิเคราะห์ของ Mask R-CNN มาทำการหาตำแหน่งหน้าก่อนเห็ด หลังจากได้ตำแหน่งตัวเลขแล้วจะนำไปใช้สำหรับการครอบตัดภาพ (หน้าก่อนเห็ดเป็นบริเวณที่เกิดราจึงทำการครอบตัดบริเวณดังกล่าว) เพื่อจะนำภาพที่ผ่านการครอบตัดแล้วไปใช้ในการวิเคราะห์หาโรคเชื้อราของเห็ดนางฟ้าในลำดับต่อไป (กำหนดขนาดภาพที่ครอบตัด 200 x 200 พิกเซล) ซึ่งหากกำหนดขนาดภาพเล็กหรือใหญ่เกินไปจะมีผลในการวิเคราะห์ภาพ เนื่องจากภาพอาจแตกหรือความคมชัดขาดหายไป

7. เมื่อทำการครอบตัดเรียบร้อยแล้วผู้วิจัยได้ทำการตรวจสอบและแยกภาพออกเป็น 2 ชุดคือ ชุดภาพที่เป็นโรคเชื้อรา จำนวน 1000 ภาพ และชุดภาพที่ไม่เป็นโรคเชื้อรา จำนวน 1000 ภาพ เพื่อเตรียมสำหรับนำเข้าสู่ขั้นตอนการเรียนรู้ด้วยการเรียนรู้เชิงลึก คือ Convolutional Neural Network (CNN) เพื่อเรียนรู้ลักษณะของสีและลักษณะการลุกลามของเชื้อราบริเวณหน้าก่อนเห็ด ซึ่งโมเดลที่ให้ค่าความถูกต้องมากที่สุดคือ DenseNet201 และโดยการทดลองนี้ได้นำเทคนิค Augmentation ช่วยในการเพิ่มความหลากหลายของภาพพบว่า การที่ไม่ได้ใช้เทคนิค Augmentation นั้นให้ค่าความถูกต้องมากกว่า แต่เกิด Overfitting มากกว่า เมื่อนำผลทั้งที่ได้มาวิเคราะห์ทำให้เห็นว่าหากต้องการนำไปใช้งานกับลักษณะของภาพก่อนเห็ดที่มีความหลากหลาย เช่น หน้าก่อนเห็ดมีความบิดเบี้ยวมาก หรือภาพมีความสว่างมากเกินไป เป็นต้น แต่ด้วยลักษณะงานที่ผู้วิจัยทำนี้มีการกำหนดค่าต่าง ๆ ได้เหมาะสมในระดับที่นำมาใช้งานได้และทดสอบแล้วว่าสามารถวิเคราะห์หาโรคเชื้อราได้ในระดับที่ดี รวมถึงลักษณะหน้าก่อนเห็ดที่ถ่ายได้นั้นโดยส่วนมากจะถ่ายตรงกับชั้นวางก่อนเห็ดจึงทำให้ได้ภาพหน้าก่อนเห็ดมีลักษณะเหมือนกันทุกภาพ

8. จากการทดลองทั้งหมดนำสู่ขั้นตอนการทำงานแบบเรียลไทม์ ซึ่งใช้ภาษา python ในการพัฒนาระบบทั้งหมด โดยเมื่อเปิดการทำงานหุ่นยนต์จะถ่ายภาพส่งไปยังคอมพิวเตอร์และระบบจะทำการดึงภาพที่ได้มาใช้ในการหาวัตถุในภาพด้วยเทคนิค Mask R-CNN จากนั้นโมเดล DenseNet201 มาใช้ในการวิเคราะห์หาโรคเชื้อราของเห็ดนางฟ้าและส่งผลการวิเคราะห์ไปยัง application line ของเกษตรกร

จากการทดลองทั้งหมดนี้สามารถทำงานได้จริงและช่วยให้เกษตรกรไม่ต้องเข้าไปยังโรงเรือนบ่อยมากเกินไป เนื่องจากหากเข้าไปยังโรงเรือนทุก ๆ ชั่วโมงและทุกวันจะทำให้เกษตรกรสุดตมสปอร์ออกจากดอกเห็ดและเกิดการสะสมภายในโรงเรือนมากเกินไปก็จะทำให้เกิดโรคปอด โรคฝีในปอด และโรคภูมิแพ้ได้


## 5.2 ปัญหา และอุปสรรค

1. ปัญหาในเรื่องของแสงไฟที่กระทบกับดวงก่อนเห็นมีผลกับสีของภาพที่ได้ ดังนั้นในการถ่ายภาพหุ่นยนต์จะต้องหยุดสนิทแล้วจึงทำการถ่าย
2. ปัญหาการส่งภาพและการนำภาพที่ได้ส่งขึ้นตอนการวิเคราะห์โรคมีการหน่วงในเรื่องข้อเวลา กล่าวคือภาพที่ส่งและนำสู่การประมวลเพื่อวิเคราะห์โรคมีการดีเลย์ประมาณ 2 วินาที
3. ร่างสำหรับวางก้อนเห็นและรางเลื่อนสำหรับหุ่นยนต์ถ่ายภาพจะต้องมีขนาดที่ใกล้เคียงกันให้มากที่สุด เพื่อที่จะทำการถ่ายภาพก้อนเห็นได้ครบทั้งหมดทุกก้อน
4. การวางก้อนเห็นบนชั้นวางควรที่จะวางหน้าก้อนเห็นที่ให้ตรงและเท่ากันให้มากที่สุด เพื่อที่จะง่ายในการนำภาพไปใช้งานต่อ
5. ปัญหาข้อจำกัดของการแจ้งเตือนผ่านไลน์เนื่องจากมีข้อจำกัดสิทธิ์การใช้งานหากต้องการเพิ่มจำนวนการแจ้งเตือนผ่านไลน์จะต้องชำระค่าบริการเพิ่มเติม
6. ปัญหาสัญญาณอินเทอร์เน็ตขณะทดลองนั้นบางครั้งมีปัญหาเกิดขึ้นคือสัญญาณขาดหายหรือหลุดหายไปแต่ไม่หายนานเกิน 1 นาที
7. ความชื้นที่เกิดจากการพ่นหมอกอาจส่งผลกระทบต่อหุ่นยนต์ถ่ายภาพได้

## 5.3 ข้อเสนอแนะ

ควรหาแนวทางและวิธีการที่เหมาะสมในการป้องกันไม่ให้หุ่นยนต์ถูกละอองน้ำที่เกิดจากการพ่นหมอกภายในโรงเรือน เพื่อป้องกันความเสียหายและสามารถใช้งานได้ยาวนาน นำผลที่ได้จากการทำ Augmentation ไปทดลองใช้งานเพิ่มเพื่อดูความสามารถในการวิเคราะห์โรคเชื้อรา และทำตารางเปรียบเทียบความถูกต้องในการทดลอง เพิ่มความหลากหลายของโมเดล Convolutional Neural Network (CNN) หรืออาจนำไปทดลองกับเทคนิคอื่น ๆ ด้าน Image processing รวมถึงการนำเทคนิค Faster R-CNN มาปรับใช้เพิ่มเติมเพื่อเพิ่มประสิทธิภาพในการทำงาน

## บรรณานุกรม



### บรรณานุกรม

- [1] Oei P, Nieuwenhuijzen Bv. Small-scale mushroom cultivation. Agromisa/CTA; 2005.
- [2] ชำนาญ พิทักษ์ทอง. เห็ดเศรษฐกิจ. กรุงเทพฯ : สำนักพิมพ์เกษตรสยามบุ๊คส์; 2553.
- [3] วิทยา ทวีนุช. การเพาะเห็ดแบบเศรษฐกิจพอเพียง. กรุงเทพฯ : สกายบุ๊คส์ จำกัด; 2554.
- [4] สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ. มาตรฐานสินค้าเกษตร : เห็ดสกุลนางรม. 3 มีนาคม 2563];  
[https://www.acfs.go.th/standard/download/PLEUROTUS\\_MUSHROOMs.pdf](https://www.acfs.go.th/standard/download/PLEUROTUS_MUSHROOMs.pdf).
- [5] จุลสารโรงพยาบาลมะเร็งอุดรธานี. โรงพยาบาลมะเร็งอุดรธานี. Move on. 12 มิถุนายน 2563]; <https://www.udch.go.th/uploads/doc/journal/2561/v69.pdf>.
- [6] กิจกรรมเห็ด งานศึกษาและพัฒนาเกษตรกรรม ศูนย์ศึกษาการพัฒนาภูพานอันเนื่องมาจากพระราชดำริ. คู่มือการเพาะเห็ดเศรษฐกิจและเห็นพื้นเมือง; 2555 ตุลาคม 2555.
- [7] อภิชาติ ศรีสอาด และพัชรี สำโรงเย็น. แนวคิดและแบบอย่างการสร้างโรงเรือนเพาะเห็ดอย่างง่ายต้นทุนต่ำ. บริษัท นาคา อินเทอร์เน็ต จำกัด; 2556.
- [8] ไทยรัฐออนไลน์. สปอร์ของเห็ดอาจจะสร้างมลพิษในอากาศ. 17 เมษายน 2560 [12 มิถุนายน 2563]; <https://www.thairath.co.th/news/society/914875>.
- [9] Raja SP, Rozario AR, Nagarani S, Kavitha N. Intelligent Mushroom Monitoring System. International Journal of Engineering & Technology 2018; 7[2.33]: 1238-1242.
- [10] Mahmud MSA, Buyamin S, Mokji MM, Abidin MZ. Internet of things based smart environmental monitoring for mushroom cultivation. Indonesian Journal of Electrical Engineering and Computer Science 2018; 10[3]: 847-852.
- [11] Yang K, Han Y, Ma Y, Yang L. The Design and Implement of Monitoring System for Mushroom Greenhouses Based on Intelligent Agriculture. 2017 International Conference on Computer Systems, Electronics and Control (ICCSEC); IEEE; 695-699.
- [12] สมาคมนักวิจัยและเพาะเห็ดแห่งประเทศไทย. สมาคมนักวิจัยและเพาะเห็ดแห่งประเทศไทย. เห็ดไทย. 2010 [<http://www.thaimushroomsoc.com/>].
- [13] Neergheen VS, Kam AH, Pem Y, Ramsaha S, Bahorun T. Regulation of cancer cell signaling pathways as key events for therapeutic relevance of edible and medicinal mushrooms. Seminars in Cancer Biology; Elsevier;
- [14] Chang ST, Wasser SP. Current and future research trends in agricultural and biomedical applications of medicinal mushrooms and mushroom products. International journal of medicinal mushrooms 2018; 20[12]:

- [15] สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ. สรรพคุณของเห็ดนางฟ้า ประโยชน์ในการรักษาโรค. 15 ตุลาคม 2562 [12 มิถุนายน 2563]; <https://warning.acfs.go.th/th/articles-and-research/view/?page=45>.
- [16] Plearn เพลิน. Smart Farming เกษตรอัจฉริยะ ความหวังใหม่ของเกษตรกรไทย. 22 สิงหาคม 2563]; <https://www.krungsri.com/bank/th/plearn-plearn/smart-farming.html>.
- [17] Ghavate S, Joshi H. Smart Farming using IoT and Machine Learning with Image Processing: EasyChair; 2020. Report No.: 2516-2314.
- [18] Muangprathub J, Boonnam N, Kajornkasirat S, Lekbangpong N, Wanichsombat A, Nillaor P. IoT and agriculture data analysis for smart farm. Computers and electronics in agriculture 2019; 156467-474.
- [19] Ghosh A, Chakraborty D, Law A. Artificial intelligence in Internet of things. CAAI Transactions on Intelligence Technology 2018; 3[4]: 208-218.
- [20] Yang LT. Internet of Everything.
- [21] Al-Garadi MA, Mohamed A, Al-Ali A, Du X, Ali I, Guizani M. A survey of machine and deep learning methods for internet of things (IoT) security. IEEE Communications Surveys & Tutorials 2020;
- [22] Gartner I. Gartner Identifies the Top 10 Strategic Technology Trends for 2020. 21 August 2020]; <https://www.gartner.com/en/newsroom/press-releases/2019-10-21-gartner-identifies-the-top-10-strategic-technology-trends-for-2020>.
- [23] Mohammadi M, Al-Fuqaha A, Sorour S, Guizani M. Deep learning for IoT big data and streaming analytics: A survey. IEEE Communications Surveys & Tutorials 2018; 20[4]: 2923-2960.
- [24] Mohammadi M, Al-Fuqaha A. Enabling cognitive smart cities using big data and machine learning: Approaches and challenges. IEEE Communications Magazine 2018; 56[2]: 94-101.
- [25] Chen M, Mao S, Zhang Y, Leung VC. Big data: related technologies, challenges and future prospects. Springer; 2014.
- [26] Chen X-W, Lin X. Big data deep learning: challenges and perspectives. IEEE access 2014; 2514-525.
- [27] Zaharia M, Chowdhury M, Das T, Dave A, Ma J, Mccauley M, et al. Fast and interactive analytics over Hadoop data with Spark. Usenix Login 2012; 37[4]: 45-51.
- [28] Engle C, Luper A, Xin R, Zaharia M, Franklin MJ, Shenker S, et al. Shark: fast data analysis using coarse-grained distributed memory. Proceedings of the

- 2012 ACM SIGMOD International Conference on Management of Data; 689-692.
- [29] Cayenne. Cayenne IoT Ready TM Program for Hardware Manufacturers. 22 August 2020]; <https://developers.mydevices.com/for-hardware-manufacturers/iot-ready-program/>.
- [30] Jin X-B, Yu X-H, Wang X-Y, Bai Y-T, Su T-L, Kong J-L. Deep learning predictor for sustainable precision agriculture based on internet of things system. *Sustainability* 2020; 12[4]: 1433.
- [31] Vecchio Y, Agnusdei GP, Miglietta PP, Capitanio F. Adoption of precision farming tools: the case of italian farmers. *International Journal of Environmental Research and Public Health* 2020; 17[3]: 869.
- [32] Fusco G, Miglietta PP, Porrini D. How drought affects agricultural insurance policies: The case of Italy. 2018;
- [33] Porrini D, Fusco G, Miglietta PP. Post-adversities recovery and profitability: The case of Italian farmers. *International Journal of Environmental Research and Public Health* 2019; 16[17]: 3189.
- [34] Suci G, Marcu I, Balaceanu C, Dobrea M, Botezat E. Efficient IoT system for precision agriculture. 2019 15th International Conference on Engineering of Modern Electric Systems (EMES); IEEE; 173-176.
- [35] Zhiyao Z, Peng Y, Xiaoyi W, Jiping X, Li W, Jiabin Y. Reliable flight performance assessment of multicopter based on interacting multiple model particle filter and health degree. *Chinese Journal of Aeronautics* 2019; 32[2]: 444-453.
- [36] Keswani B, Mohapatra AG, Mohanty A, Khanna A, Rodrigues JJ, Gupta D, et al. Adapting weather conditions based IoT enabled smart irrigation technique in precision agriculture mechanisms. *Neural Computing and Applications* 2019; 31[1]: 277-292.
- [37] Bai Y-t, Jin X-b, Wang X-y, Wang X-k, Xu J-p. Dynamic correlation analysis method of air pollutants in spatio-temporal analysis. *International Journal of Environmental Research and Public Health* 2020; 17[1]: 360.
- [38] Wolfert S, Ge L, Verdouw C, Bogaardt M-J. Big data in smart farming—a review. *Agricultural Systems* 2017; 153:69-80.
- [39] Glaroudis D, Iossifides A, Chatzimisios P. Survey, comparison and research challenges of IoT application protocols for smart farming. *Computer Networks* 2020; 168:107037.

- [40] Walter A, Finger R, Huber R, Buchmann N. Opinion: Smart farming is key to developing sustainable agriculture. *Proceedings of the National Academy of Sciences* 2017; 114[24]: 6148-6150.
- [41] McAndrew A. *Introduction to Digital Image Processing with MATLAB Australia: Thomson course technology*; 2004.
- [42] Khadabadi GC, Rajpurohit VS, Kumar A, Nargund V. Disease Detection in Vegetables Using Image Processing Techniques: A Review. *International Journal of Emerging Technology in Computer science & Eletronics* 2015; 14
- [43] Sannakki SS, Rajpurohit VS, Nargund V, Kulkarni P. Diagnosis and classification of grape leaf diseases using neural networks. 2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT); IEEE; 1-5.
- [44] Padol PB, Yadav AA. SVM classifier based grape leaf disease detection. 2016 Conference on advances in signal processing (CASP); IEEE; 175-179.
- [45] Reza ZN, Nuzhat F, Mahsa NA, Ali MH. Detecting jute plant disease using image processing and machine learning. 2016 3rd International Conference on Electrical Engineering and Information Communication Technology (ICEEICT); IEEE; 1-6.
- [46] Marathe PS. Plant Disease Detection using Digital Image Processing and GSM. *International Journal of Engineering Science and Computing* 2017;
- [47] Gowthami K, Pratyusha M, Somasekhar B, Hemanth B. 'Detection of Diseases in Different Plants Using Digital Image Processing'. *International Journal of Scientific Research in Engineering* 2017; 2[2]:
- [48] Sahithya V, Saivihari B, Vamsi VK, Reddy PS, Balamurugan K. GUI based Detection of Unhealthy Leaves using Image Processing Techniques. 2019 International Conference on Communication and Signal Processing (ICCSP); IEEE; 0818-0822.
- [49] Kumari CU, Prasad SJ, Mounika G. Leaf Disease Detection: Feature Extraction with K-means clustering and Classification with ANN. 2019 3rd International Conference on Computing Methodologies and Communication (ICCMC); IEEE; 1095-1098.
- [50] Amara J, Bouaziz B, Algergawy A. A deep learning-based approach for banana leaf diseases classification. *Datenbanksysteme für Business, Technologie und Web (BTW 2017)-Workshopband* 2017;




- [51] Cui D, Zhang Q, Li M, Hartman GL, Zhao Y. Image processing methods for quantitatively detecting soybean rust from multispectral images. *Biosystems engineering* 2010; 107[3]: 186-193.
- [52] Schor N, Bechar A, Ignat T, Dombrovsky A, Elad Y, Berman S. Robotic disease detection in greenhouses: combined detection of powdery mildew and tomato spotted wilt virus. *IEEE Robotics and Automation Letters* 2016; 1[1]: 354-360.
- [53] Sonka M, Hlavac V, Boyle R. *Image processing, analysis, and machine vision*. Cengage Learning; 2014.
- [54] Goodfellow I, Bengio Y, Courville A, Bengio Y. *Deep learning*. MIT press Cambridge; 2016.
- [55] Hinton G, Deng L, Yu D, Dahl GE, Mohamed A-r, Jaitly N, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal processing magazine* 2012; 29[6]: 82-97.
- [56] Moen E, Bannon D, Kudo T, Graf W, Covert M, Van Valen D. Deep learning for cellular image analysis. *Nature methods* 2019; 1-14.
- [57] Wan J, Wang D, Hoi SCH, Wu P, Zhu J, Zhang Y, et al. Deep learning for content-based image retrieval: A comprehensive study. *Proceedings of the 22nd ACM international conference on Multimedia*; 157-166.
- [58] Pitts W, McCulloch WS. How we know universals the perception of auditory and visual forms. *The Bulletin of mathematical biophysics* 1947; 9[3]: 127-147.
- [59] Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *nature* 1986; 323[6088]: 533-536.
- [60] Cybenko G. Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems* 1989; 2[4]: 303-314.
- [61] Hornik K. Approximation capabilities of multilayer feedforward networks. *Neural networks* 1991; 4[2]: 251-257.
- [62] Hinton GE, Srivastava N, Krizhevsky A, Sutskever I, Salakhutdinov RR. Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:12070580* 2012;
- [63] Lancashire LJ, Rees RC, Ball GR. Identification of gene transcript signatures predictive for estrogen receptor and lymph node status using a stepwise forward selection artificial neural network modelling approach. *Artificial intelligence in medicine* 2008; 43[2]: 99-111.

- [64] Pezzano G, Ripoll VR, Radeva P. CoLe-CNN: Context-learning convolutional neural network with adaptive loss function for lung nodule segmentation. *Computer Methods and Programs in Biomedicine* 2021; 198105792.
- [65] Sun S, Cao Z, Zhu H, Zhao J. A survey of optimization methods from a machine learning perspective. *IEEE transactions on cybernetics* 2019; 50[8]: 3668-3681.
- [66] Valueva M, Nagornov N, Lyakhov P, Valuev G, Chervyakov N. Application of the residue number system to reduce hardware costs of the convolutional neural network implementation. *Mathematics and Computers in Simulation* 2020;
- [67] LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE* 1998; 86[11]: 2278-2324.
- [68] Hubel DH, Wiesel TN. Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology* 1968; 195[1]: 215-243.
- [69] Fukushima K, Miyake S. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. *Competition and cooperation in neural nets*: Springer 1982:267-285.
- [70] Rumelhart DE, Hinton GE, Williams RJ. Learning internal representations by error propagation: California Univ San Diego La Jolla Inst for Cognitive Science; 1985.
- [71] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*; 1097-1105.
- [72] Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, et al. Imagenet large scale visual recognition challenge. *International journal of computer vision* 2015; 115[3]: 211-252.
- [73] Sultana F, Sufian A, Dutta P. Advancements in image classification using convolutional neural network. 2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN); IEEE; 122-129.
- [74] Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 4700-4708.
- [75] Singhal G. PLURALSIGHT. Introduction to DenseNet with TensorFlow. May 6,2020 [<https://www.pluralsight.com/guides/introduction-to-densenet-with-tensorflow>].

- [76] Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the inception architecture for computer vision. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 2818-2826.
- [77] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:14091556* 2014;
- [78] Liu T, Wang Z. HiCNN: a very deep convolutional neural network to better enhance the resolution of Hi-C data. *Bioinformatics* 2019; 35[21]: 4222-4228.
- [79] Deng M, Goy A, Li S, Arthur K, Barbastathis G. Probing shallower: perceptual loss trained phase extraction neural network (plt-phenn) for artifact-free reconstruction at low photon budget. *Optics express* 2020; 28[2]: 2511-2535.
- [80] He K, Gkioxari G, Dollár P, Girshick R. Mask r-cnn. *Proceedings of the IEEE international conference on computer vision*; 2961-2969.
- [81] Cai Z, Vasconcelos N. Cascade r-cnn: Delving into high quality object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 6154-6162.
- [82] Wu M, Yue H, Wang J, Huang Y, Liu M, Jiang Y, et al. Object detection based on RGC mask R-CNN. *IET Image Processing* 2020; 14[8]: 1502-1508.
- [83] Yan J, Wang H, Yan M, Diao W, Sun X, Li H. IoU-adaptive deformable R-CNN: Make full use of IoU for multi-class object detection in remote sensing imagery. *Remote Sensing* 2019; 11[3]: 286.
- [84] Girshick R, Donahue J, Darrell T, Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 580-587.
- [85] Girshick R, Landola F, Darrell T, Malik J. Deformable part models are convolutional neural networks. *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*; 437-446.
- [86] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*; 770-778.
- [87] Kitpo N, Kugai Y, Inoue M, Yokemura T, Satomura S. Internet of Things for Greenhouse Monitoring System Using Deep Learning and Bot Notification Services. *2019 IEEE International Conference on Consumer Electronics (ICCE)*; IEEE; 1-4.
- [88] Lee SH, Chan CS, Wilkin P, Remagnino P. Deep-plant: Plant identification with convolutional neural networks. *2015 IEEE international conference on image processing (ICIP)*; IEEE; 452-456.

- [89] Yalcin H. Plant phenology recognition using deep learning: Deep-Pheno. 2017 6th International Conference on Agro-Geoinformatics; IEEE; 1-5.
- [90] Everingham M, Van Gool L, Williams CK, Winn J, Zisserman A. The pascal visual object classes (voc) challenge. *International journal of computer vision* 2010; 88[2]: 303-338.
- [91] Mohanty SP, Hughes DP, Salathé M. Using deep learning for image-based plant disease detection. *Frontiers in plant science* 2016; 71419.
- [92] Sladojevic S, Arsenovic M, Anderla A, Culibrk D, Stefanovic D. Deep neural networks based recognition of plant diseases by leaf image classification. *Computational intelligence and neuroscience* 2016; 2016
- [93] Dyrmann M, Mortensen AK, Midtby HS, Jørgensen RN. Pixel-wise classification of weeds and crops in images by using a fully convolutional neural network. *Proceedings of the International Conference on Agricultural Engineering, Aarhus, Denmark*; 26-29.
- [94] Grinblat GL, Uzal LC, Larese MG, Granitto PM. Deep learning for plant identification using vein morphological patterns. *Computers and Electronics in Agriculture* 2016; 127418-424.
- [95] Soille P. *Morphological image analysis: principles and applications*. Springer Science & Business Media; 2013.
- [96] Price CA, Symonova O, Mileyko Y, Hilley T, Weitz JS. Leaf extraction and analysis framework graphical user interface: segmenting and analyzing the structure of leaf veins and areoles. *Plant Physiology* 2011; 155[1]: 236-245.
- [97] Hastie T, Tibshirani R, Friedman J. *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media; 2009.
- [98] Gandhi R. July 9, 2018. R-CNN, Fast R-CNN, Faster R-CNN, YOLO Object Detection Algorithms. February 15]; <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>.
- [99] Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. *Journal of Big Data* 2019; 6[1]: 1-48.
- [100] Rice L, Wong E, Kolter Z. Overfitting in adversarially robust deep learning. *International Conference on Machine Learning*; PMLR; 8093-8104.
- [101] Chen J, Chen J, Zhang D, Sun Y, Nanekaran YA. Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture* 2020; 173105393.



ภาคผนวก

พหุณํ ปณฺ ทิโต ชีเว

### แบบประเมินประสิทธิภาพของระบบการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าสำหรับสมาร์ฟาร์ม

คำชี้แจง แบบสอบถามชุดนี้จัดทำขึ้นเพื่อประเมินประสิทธิภาพของระบบการวิเคราะห์โรคเชื้อราของเห็ดนางฟ้าสำหรับสมาร์ฟาร์ม ซึ่งข้อมูลที่ได้จะเป็นประโยชน์อย่างยิ่งต่อการพัฒนาและปรับปรุงระบบให้มีความเหมาะสมต่อไป

กรุณาทำเครื่องหมาย ✓ ในช่องที่ท่านเลือก

ตอนที่ 1 ข้อมูลทั่วไปของผู้ตอบแบบสอบถาม

- เพศ  ชาย  หญิง
- อายุ  ต่ำกว่า 19 ปี  19-24 ปี  25-40 ปี  40 ปีขึ้นไป
- ระดับการศึกษา  ต่ำกว่า ป.ตรี  ป.ตรี  ป.โท  สูงกว่า ป.โท
- ระยะเวลาการทำสมาร์ฟาร์ม  1 - 5 ปี  มากกว่า 5 ปี
- ความถี่ในการเข้าโรงเรียนสมาร์ฟาร์ม  ทุกวัน  2-3 วัน/ครั้ง  สัปดาห์ละครั้ง  อื่น ๆ โปรดระบุ.....

ตอนที่ 2 ความคิดเห็นเกี่ยวกับประสิทธิภาพของระบบ โดยมีเกณฑ์วัดระดับดังนี้

5 = ดีมาก                      4 = ดี                      3 = ปานกลาง                      2 = น้อย                      1 = น้อยที่สุด                      0 = ไม่พึงพอใจ

ประเด็นวัดประสิทธิภาพของระบบ		ระดับความคิดเห็น					ไม่พึงพอใจ
		5	4	3	2	1	
<b>ด้านกระบวนการ/ขั้นตอนการใช้งานระบบ</b>							
1	รูปแบบการใช้งานระบบ ความยาก - ง่าย						
2	กระบวนการทำงานของระบบ						
<b>ด้านประสิทธิภาพของระบบ</b>							
1	ความถูกต้อง แม่นยำของระบบ						
2	ตรงตามวัตถุประสงค์ที่ต้องการ						
3	การออกแบบให้ใช้งานง่าย ไม่ซับซ้อน						
4	ความเป็นปัจจุบันของข้อมูล						
5	ระบบวิเคราะห์โรคเชื้อราได้ถูกต้องแม่นยำ						
<b>ด้านความสะดวก สบายงาม</b>							
1	ความสะดวกในการใช้งานระบบ						
2	ความเหมาะสมในการใช้งานระบบ						
<b>ด้านคุณภาพของระบบ</b>							
1	ความพึงพอใจในการใช้งาน						
2	ความสามารถของระบบ ในการนำไปใช้ประโยชน์						

ตอนที่ 3 ข้อเสนอแนะอื่นๆ

จุดเด่น / จุดที่ควรปรับปรุง

ข้อเสนอแนะเพิ่มเติม

## ประวัติผู้เขียน

ชื่อ	นางสาวพัชรี ศรีพุทธา
วันเกิด	30 มกราคม 2529
สถานที่เกิด	อำเภอกระนวน จังหวัดขอนแก่น
สถานที่อยู่ปัจจุบัน	41 หมู่ 2 ตำบลหนองกุงใหญ่ อำเภอกระนวน จังหวัดขอนแก่น 40170
ประวัติการศึกษา	พ.ศ.2551 ปริญญาบริหารธุรกิจบัณฑิต (บร.บ.) สาขาวิชาคอมพิวเตอร์ธุรกิจ มหาวิทยาลัยมหาสารคาม พ.ศ.2556 ปริญญาวิทยาศาสตรมหาบัณฑิต (วท.ม.) สาขาวิชาเทคโนโลยี สารสนเทศ มหาวิทยาลัยมหาสารคาม พ.ศ.2565 ปริญญาปรัชญาดุษฎีบัณฑิต (ปร.ด.) สาขาวิชาวิทยาการ คอมพิวเตอร์ มหาวิทยาลัยมหาสารคาม

