

ระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียน  
โดยใช้โครงข่ายประสาทเทียม



นายชนกร หอประเสริฐวงศ์

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์  
มหาวิทยาลัยเทคโนโลยีสุรนารี  
ปีการศึกษา 2563

**INTELLIGENT LED LIGHT CONTROL SYSTEMS  
IN GREENHOUSE BASED ON ARTIFICIAL  
NEURAL NETWORKS**



**Thanakorn Hoprasertwong**

**A Thesis Submitted in Partial Fulfillment of the Requirements for  
the Degree of Master of Engineering in  
Telecommunication and Computer Engineering  
Suranaree University of Technology  
Academic Year 2020**

## ระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้โครงข่ายประสาทเทียม

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นำวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา  
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(รศ. ดร.กิติติ อัดถกิจมงคล)

ประธานกรรมการ



(ผศ. ร.อ. ดร.ประ โยชน์ คำสวัสดิ์)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(รศ. ดร.เดชา พวงดาวเรือง)

กรรมการ

มหาวิทยาลัยเทคโนโลยีสุรนารี



(รศ. ร.อ. ดร.กนต์ธร ชำนิประศาสน์)

รองอธิการบดีฝ่ายวิชาการและพัฒนา

ความเป็นสากล



(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

ชนกร หอประเสริฐวงศ์ : ระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้  
โครงข่ายประสาทเทียม (INTELLIGENT LED LIGHT CONTROL SYSTEMS IN  
GREENHOUSE BASED ON ARTIFICIAL NEURAL NETWORKS)

อาจารย์ที่ปรึกษา : ผู้ช่วยศาสตราจารย์ เรืออากาศเอก ดร.ประ โยชน์ คำสวัสดิ์, 256 หน้า.

ในปัจจุบันหลอดไฟแอลอีดี (Light-Emitting Diodes) เป็นแหล่งของพลังงานแสงที่มีข้อดี  
หลายอย่าง เช่น สามารถกำหนดความเข้มแสงได้ อุณหภูมิต่ำ และประหยัดพลังงาน ดังนั้นจึงนำ  
เทคโนโลยีแสงเทียมที่ได้จากหลอดไฟแอลอีดีมาประยุกต์ใช้ร่วมกับการผลิตทางการเกษตร และอีก  
ทั้งเพื่อสร้างนวัตกรรมแหล่งกำเนิดแสงเทียมอัจฉริยะจึงนำปัญญาประดิษฐ์ (Artificial Intelligent)  
เพื่อทำนายค่าความเข้มแสงแอลอีดีที่ได้จากการบันทึกภาพแบบตามเวลาจริงที่ให้ความรวดเร็ว  
และแม่นยำให้กับระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนที่ออกแบบไว้ ในวิทยานิพนธ์นี้  
อันดับแรกได้นำเสนอการตรวจจับความเข้มแสงแอลอีดีอัจฉริยะในพืชสวนเรือนกระจกได้จำลอง  
สถานการณ์ความเข้มแสงต่าง ๆ และใช้กล้องถ่ายรูปเพื่อจับภาพ จากนั้นภาพเหล่านี้จะถูกสกัด  
คุณลักษณะที่สำคัญ แล้งจึงนำไปใช้ในการฝึกฝนในโครงข่ายประสาทเทียม อันดับที่สองนำเสนอ  
ระบบที่ออกแบบไว้เพื่อใช้งานจริงร่วมกับการปลูกผักกาดหอมกรีน โอ๊ค (Green Oak Lettuce) ซึ่ง  
ผลการทดสอบแสดงให้เห็นถึงประสิทธิภาพในการเก็บข้อมูลและเตรียมข้อมูลที่ได้จากการ  
ตรวจจับภาพ เพื่อเพิ่มพูนและเตรียมความพร้อมก่อนนำข้อมูลที่ใช้สำหรับฝึกฝนและทำนายใน  
โครงข่ายประสาทเทียม ทั้งในด้านการจำลองสถานการณ์และด้านใช้งานจริง

สาขาวิชา วิศวกรรมโทรคมนาคม  
ปีการศึกษา 2563

ลายมือชื่อนักศึกษา ชนกร  
ลายมือชื่ออาจารย์ที่ปรึกษา ประ โยชน์ คำสวัสดิ์

THANAKORN HOPRASERTWONG : INTELLIGENT LED LIGHT  
CONTROL SYSTEMS IN GREENHOUSE BASED ON ARTIFICIAL  
NEURAL NETWORK. THESIS ADVISOR : ASST. PROF. FLT. LT.  
PRAYOTH KUMSAWAT, Ph.D., 256 PP.

MACHINE LEARNING/ARTIFICIAL LIGHT/ NEURAL NETWORK

Nowadays, the Light Emitting Diodes (LEDs) are light energy sources that have many advantages such as light intensity adjustment, low temperature operation and energy saving. Therefore, artificial lighting technology derived from LED lamps was applied in conjunction with agricultural production. To create an innovative artificial light source, an artificial intelligent technique is used to predict the intensity of LED light obtained by real-time recording that provides both speed and accuracy to the intelligent LED light control systems in greenhouse designed. This thesis presents artificial light intensity detection in horticulture which simulates different light intensity situations and uses a camera to capture images. Then, we extracted important features which are used for training the neural networks. Next, the research proposed a system designed for use in conjunction with the cultivation of Green Oak Lettuce. The results demonstrate the efficiency of data acquisition and preparation obtained from the captured images. These processes increase the ability of prediction in the neural network in both simulation and implementation.

School of Telecommunication Engineering

Academic Year 2020

Student's Signature



Advisor's Signature



## กิตติกรรมประกาศ

วิทยานิพนธ์นี้ดำเนินการสำเร็จลุล่วงด้วยดี เนื่องจากพระคุณของ บิดาและมารดา คือ คุณพ่อธีระศักดิ์ หอประเสริฐวงศ์ คุณแม่พิสมัย จันทรัมย์ ผู้วิจัยขอบพระคุณท่านทั้งสองที่มอบชีวิต ให้ความรักความห่วงใย และให้การเลี้ยงดูอย่างอบอุ่น ความสำเร็จนี้คือความภาคภูมิใจของท่านทั้งสอง

ขอบพระคุณในการช่วยเหลืออย่างดียิ่ง ทั้งด้านวิชาการและการดำเนินการวิจัยจาก บุคคลและกลุ่มบุคคล อันได้แก่ ผู้ช่วยศาสตราจารย์ เรืออากาศเอก ดร.ประโยชน์ คำสวัสดิ์ ผู้มอบ วิชาความรู้ คอยให้ความช่วยเหลือทางด้านทุนทรัพย์ ค่าปรึกษาทางด้านงานวิจัย การใช้ชีวิต และ เป็นกำลังใจให้ผู้ทำวิจัยมาโดยตลอด รองศาสตราจารย์ ดร.อาทิตย์ ศรีแก้ว รองศาสตราจารย์ ดร. กิตติ อรรถกิจมงคล และ รองศาสตราจารย์ ดร.เดชา พวงดาวเรือง ผู้ให้ความช่วยเหลือในการแก้ไขปัญหา และคอยให้คำปรึกษาในการดำเนินงานวิจัย รวมทั้งคอยชี้แนะแนวทางในการทำงานวิจัยที่ ถูกต้อง

คณาจารย์ประจำสาขาวิชาวิศวกรรมโทรคมนาคม สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัย เทคโนโลยีสุรนารี ที่ให้ความรู้และคำปรึกษาเป็นอย่างดีตลอดระยะเวลาในการเข้าศึกษา และ ขอบขอบคุณบุคลากรศูนย์เครื่องมือวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีสุรนารีทุกท่าน ที่อำนวยความสะดวกในการทำงานของข้าพเจ้า

ขอขอบคุณ นายวงศธร ภาธรสุวรรณ นางสาวณิชมล สว่างไสว นายเกริกฤทธิ์ ศรีเคน ทุก ท่าน พี่ น้อง และเพื่อน รวมถึงมิตรสหายที่คอยให้คำปรึกษา คอยให้กำลังใจและมิตรภาพที่ดีมาโดย ตลอด

ท้ายนี้ขอขอบพระคุณครูบาอาจารย์ทุกท่านตั้งแต่อดีตจนถึงปัจจุบันที่ประสิทธิ์ประสาท วิชาการความรู้ต่าง ๆ กราบขอบพระคุณ คุณพ่อธีระศักดิ์ หอประเสริฐวงศ์ และคุณแม่พิสมัย จันทรัมย์ ที่ให้ความอบอุ่น และอยู่เคียงข้างคอยให้กำลังใจผู้วิจัยเสมอมา ขอขอบคุณ คุณฉัญญาพร วันเพ็ญ ที่ได้มอบความรัก ความห่วงใย และคอยเป็นกำลังใจให้ผู้วิจัยมาโดยตลอด

ธนกร หอประเสริฐวงศ์

# สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ฐ
<b>บทที่ 1 บทนำ.....</b>	<b>1</b>
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตงานวิจัย.....	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.5 ส่วนประกอบของวิทยานิพนธ์.....	3
1.6 สรุป.....	4
<b>บทที่ 2 ทฤษฎีความรู้พื้นฐาน ปรัชสนวัตกรรมและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>5</b>
2.1 บทนำ.....	5
2.2 ทฤษฎีความรู้พื้นฐาน.....	5
2.2.1 ไดโอดเปล่งแสง (Light Emitting Diode).....	5
2.2.2 ความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density).....	6
2.2.3 การประมวลผลภาพดิจิทัล (Digital Image Processing).....	7
2.2.4 ระบบสมองกลฝังตัว (Embedded System).....	11
2.2.5 ปัญญาประดิษฐ์ (Artificial Intelligence).....	11

## สารบัญ (ต่อ)

### หน้า

2.2.6	โครงข่ายประสาทเทียม (Neural Networks) .....	12
2.2.7	เทคนิคการจำแนกข้อมูล (Classification) .....	14
2.2.8	การประเมินประสิทธิภาพสำหรับโครงข่ายประสาทเทียม .....	25
2.3	อุปกรณ์ที่เกี่ยวข้อง .....	27
2.3.1	150-1500 mA Buck Regulator LED Driver for 1-50W High power LED.....	27
2.3.2	Logitech C310 HD Webcam.....	28
2.3.3	เซนเซอร์ควันตัม เอ็มคิว – 200 (MQ – 200 Quantum Sensor) .....	29
2.3.4	Nvidia Jetson Nano Developer Kit .....	29
2.3.5	16 Channel 12-bit PWM Servo Driver PCA9685 .....	30
2.4	ปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง .....	32
2.5	สรุป .....	34
<b>บทที่ 3 วิธีการดำเนินงานวิจัยส่วนที่ 1 การจำลองเหตุการณ์สำหรับการตรวจจับระดับ</b>		
	<b>ความเข้มแสงแอลอีดี .....</b>	<b>35</b>
3.1	บทนำ .....	35
3.2	การออกแบบระบบตรวจจับความเข้มแสงแอลอีดีอัจฉริยะในโรงเรียน ผ่านเหตุการณ์จำลอง .....	36
3.3	การเตรียมข้อมูลในการฝึกฝนและทดสอบกับโครงข่ายประสาทเทียม .....	39
3.3.1	กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี RGB .....	40
3.3.2	กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี HSV .....	49
3.3.3	กระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB .....	57



## สารบัญ (ต่อ)

หน้า

3.3.4	กระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV.....	79
3.4	การทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียม ในการทำนายความเข้มแสงแอลอีดี.....	102
3.4.1	การทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียม โดยใช้ชุดข้อมูลแบบไบนารีอย่างง่าย.....	103
3.4.2	การเปรียบเทียบทดสอบโครงข่ายประสาทเทียมโดยอินพุต ชุดข้อมูลดิบและชุดข้อมูลใหม่ทั้งในปริภูมิสี RGB และ HSV .....	109
3.4.3	ผลการทดสอบการการทำนายด้วยเมทริกซ์คอนฟิวชัน (Confusion Matrix) .....	116
3.4.4	ผลการทดสอบการเลือกสเก็ลลักษณะเฉพาะที่สำคัญสำหรับระบบ ตรวจจับความเข้มแสงแอลอีดีเพื่อนำไปใช้งานจริงได้อย่าง มีประสิทธิภาพ.....	119
3.5	สรุป .....	120
<b>บทที่ 4</b> วิธีการดำเนินงานวิจัยส่วนที่ 2 การสร้างระบบควบคุมแสงแอลอีดีอัจฉริยะใน โรงเรียนโดยใช้เทคนิคปัญญาประดิษฐ์.....		<b>122</b>
4.1	บทนำ .....	122
4.2	การออกแบบระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียน โดย ใช้เทคโนโลยีปัญญาประดิษฐ์ .....	122
4.3	การออกแบบการสร้างระบบควบคุมแสงแอลอีดีอัจฉริยะ โดยใช้ Nvidia Jetson Nano Developer Kit ในการประมวลผลภาพและ ควบคุมความเข้มแสงแอลอีดี .....	125
4.4	การออกแบบโปรแกรมในการควบคุมและตรวจจับความระดับความ เข้มแสงแอลอีดีเพื่อใช้ในการทดสอบการทำงาน .....	134

## สารบัญ (ต่อ)

### หน้า

4.4.1 การออกแบบโปรแกรมการตรวจวัดความเข้มแสงแอลอีดีทั้งสี่แดง และสีน้ำเงินในเงื่อนไขสำหรับการตรวจวัดที่ถูกต้อง .....	140
4.4.2 การออกแบบโปรแกรมการตรวจวัดความเข้มแสงแอลอีดีทั้งสี่แดง และสีน้ำเงินในเงื่อนไขสำหรับการตรวจวัดที่ไม่ถูกต้อง.....	142
4.4.3 การออกแบบโปรแกรมการตรวจวัดความเข้มแสงแอลอีดีทั้งสี่แดง และสีน้ำเงินในเงื่อนไขสำหรับการตรวจวัดที่ไม่สามารถระบุได้.....	146
4.5 การทดลองการควบคุมความสว่างของระบบควบคุมแสงแอลอีดีโดย เปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิทัล (Digital Multimeter Instrument) .....	147
4.6 การควบคุมและตรวจวัดระดับความเข้มแสงแอลอีดีนำไปใช้งานจริงกับพืชผล .....	158
4.6.1 ผลการทดลองการใช้งานจริงกับพืชผลรอบที่ 1.....	169
4.6.2 ผลการทดลองการใช้งานจริงกับพืชผลรอบที่ 2.....	174
4.6.3 ผลการทดสอบโปรแกรมในการควบคุมและการตรวจวัดระดับ ความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผล .....	179
4.7 สรุป .....	187
<b>บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะในการวิจัย .....</b>	<b>189</b>
5.1 สรุปเนื้อหาวิทยานิพนธ์.....	189
5.2 ข้อเสนอแนะและแนวทางในการพัฒนาต่อไป .....	190
รายการอ้างอิง .....	191
ภาคผนวก	
ภาคผนวก ก บทควมวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา.....	193
ประวัติผู้เขียน .....	256

## สารบัญตาราง

ตารางที่	หน้า
2.1 ตัวอย่างฟังก์ชันถ่ายโอนและลักษณะกราฟของฟังก์ชันถ่ายโอนแบบต่าง ๆ .....	13
2.2 งานวิจัยที่เกี่ยวข้องและกล่าวถึง .....	32
3.1 การออกแบบเหตุการณ์จำลองทั้งหมด 40 เหตุการณ์ สำหรับโครงข่ายประสาทเทียม.....	38
3.2 ค่าชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะ ทั้ง 40 เหตุการณ์.....	61
3.3 ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์.....	66
3.4 ค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix).....	70
3.5 ค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) .....	72
3.6 ชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่า คุณลักษณะเฉพาะทั้ง 40 เหตุการณ์.....	76
3.7 ค่าชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะ ทั้ง 40 เหตุการณ์.....	83
3.8 ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะ เฉพาะทั้ง 40 เหตุการณ์ .....	88
3.9 ค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix).....	93
3.10 ค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) .....	94
3.11 ชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่า คุณลักษณะเฉพาะทั้ง 40 เหตุการณ์.....	99
3.12 ชุดข้อมูลสำหรับการฝึกฝนให้กับโครงข่ายประสาทเทียมอย่างง่าย .....	103

## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
3.13 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Perceptron Learning .....	105
3.14 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Logistic Regression .....	105
3.15 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Support Vector Machine with Linear Kernel .....	106
3.16 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Support Vector Machine with Radial Basis Function Kernel.....	106
3.17 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Decision Tree.....	107
3.18 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Random Forest.....	107
3.19 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม K-Nearest Neighbors Model.....	108
3.20 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลดิบในปริภูมิสี RGB .....	111
3.21 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB.....	112

## สารบัญตาราง (ต่อ)

ตารางที่		หน้า
3.22	การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลดิบในปริภูมิ HSV.....	113
3.23	การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV .....	114
3.24	การประเมินประสิทธิภาพของโครงข่ายประสาทเทียมเรณด้อมฟอร์เรสต์ (Random Forest : RF) สำหรับชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV ด้วยค่าความแม่นยำ (Precision) และ ค่ารู้จำ (Recall) .....	118
4.1	ความสัมพันธ์กันระหว่างข้อมูลที่ป้อนในหน่วยเปอร์เซ็นต์และค่าความแสง PPFD.....	131
4.2	แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีน้ำเงิน ดวงที่ 1 – 6.....	151
4.3	แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีน้ำเงิน ดวงที่ 7 – 12.....	152
4.4	แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีน้ำเงิน ดวงที่ 13 – 18.....	153
4.5	แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีแดง ดวงที่ 1 – 8.....	154
4.6	แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีแดง ดวงที่ 9 – 18.....	155
4.7	แสดงค่ากระแสไฟฟ้าเฉลี่ยทั้งหมดจากค่ากระแสไฟฟ้าของแสงแอลอีดีสีน้ำเงิน .....	155
4.8	แสดงค่ากระแสไฟฟ้าเฉลี่ยทั้งหมดจากค่ากระแสไฟฟ้าของแสงแอลอีดีสีแดง.....	157

## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.9 แสดงการเจริญเติบโตของผักกาดหอมกรีน โอ๊ค โดยใช้แสงแอลอีดีปรับค่าได้ รอบที่ 1 .....	171
4.10 แสดงการเจริญเติบโตของผักกาดหอมกรีน โอ๊ค โดยใช้แสงดวงอาทิตย์ รอบที่ 1 .....	172
4.11 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน โอ๊ค จากแสงแอลอีดีปรับค่าได้รอบที่ 1 หลังการเก็บเกี่ยว.....	173
4.12 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน โอ๊ค จากแสงดวงอาทิตย์รอบที่ 1 หลังการเก็บเกี่ยว.....	173
4.13 สรุปผลการทดลองการใช้งานจริงกับผักกาดหอมกรีน โอ๊ครอบที่ 1 หลังการเก็บเกี่ยว.....	173
4.14 แสดงการเจริญเติบโตของผักกาดหอมกรีน โอ๊ค โดยใช้แสงแอลอีดีปรับค่าได้ รอบที่ 2 .....	176
4.15 แสดงการเจริญเติบโตของผักกาดหอมกรีน โอ๊ค โดยใช้แสงดวงอาทิตย์ รอบที่ 2 .....	177
4.16 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน โอ๊คจากแสง แอลอีดีปรับค่าได้รอบที่ 2 หลังการเก็บเกี่ยว.....	178
4.17 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน โอ๊ค จากแสงดวงอาทิตย์รอบที่ 2 หลังการเก็บเกี่ยว.....	178
4.18 สรุปผลการทดลองการใช้งานจริงกับผักกาดหอมกรีน โอ๊ครอบที่ 2 หลังการเก็บเกี่ยว.....	178
4.19 แสดงผลการทดสอบโปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับ ระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 1.....	179
4.20 แสดงผลการทดสอบโปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับ ระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 2.....	183

## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.21 ผลการทดสอบโปรแกรมในการควบคุมและการตรวจจับ ระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผล ตามเงื่อนไขในการตรวจจับ .....	186



## สารบัญรูป

รูปที่	หน้า
2.1	ไดโอดเปล่งแสง.....6
2.2	แสดงระบบสี HSV .....10
2.3	ตัวอย่างพื้นฐานของโครงข่ายประสาทเทียม.....12
2.4	ตัวอย่างโครงข่ายประสาทเทียมหนึ่งหน่วยแบบหลายอินพุต.....13
2.5	การทำงานของเซลล์ประสาททางชีววิทยา.....15
2.6	การทำงานของเซลล์ประสาททางชีววิทยา.....17
2.7	การจำแนกชนิด Logistic Regression Analysis.....18
2.8	การจำแนกประเภทข้อมูลแบบ Support Vector Machine (SVM).....19
2.9	โครงสร้างของรูปแบบต้นไม้ตัดสินใจ.....21
2.10	ตัวอย่างการแบ่งข้อมูลที่เปรียบเทียบกันระหว่างแบบ Decision Tree และ Random Forest.....23
2.11	ตัวอย่างการจำแนกชุดข้อมูลด้วยเทคนิค K-NN.....25
2.12	ตัวอย่างเมตริกซ์คอนฟิวชัน (Confusion Matrix) .....26
2.13	150-1500 mA Buck Regulator LED Driver for 1-50W High power LED.....27
2.14	รายละเอียดของ 150-1500 mA Buck Regulator LED Driver for 1-50W High power LED .....28
2.15	Logitech C310 HD Webcam.....28
2.16	MQ-200 Quantum Sensor .....29
2.17	Nvidia Jetson Nano Developer Kit.....30
2.18	PCA9685 16-Channel 12-bit PWM Servo shield I2C interface .....31
2.19	เครื่องวัดคลอโรฟิลล์ รุ่น SPAD – 502 Plus.....31
3.1	บล็อกไดอะแกรมสำหรับกระบวนการที่ถูกออกแบบ.....36



## สารบัญรูป (ต่อ)

รูปที่	หน้า
3.2	กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบใน ปริภูมิสี RGB .....40
3.3	กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี RGB จากภาพย่อย แอลอีดีสีแดงทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยม ขนาด 125×125 พิกเซล .....41
3.4	กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี RGB จากภาพย่อย แอลอีดีสีน้ำเงินทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยม ขนาด 125×125 พิกเซล .....45
3.5	กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี HSV .....49
3.6	กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี HSV จากภาพย่อย แอลอีดีสีแดงทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยม ขนาด 125×125 พิกเซล .....50
3.7	กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี HSV จากภาพย่อย แอลอีดีสีน้ำเงินทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยม ขนาด 125×125 พิกเซล .....54
3.8	กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการ การสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง .....63
3.9	กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการ การสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวง .....64
3.10	กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิค การกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีแดงทั้งสี่ดวง .....68

## สารบัญรูป (ต่อ)

รูปที่	หน้า
3.11 กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิค การกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีน้ำเงินทั้งสี่ดวง .....	69
3.12 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิค การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีแดงทั้งสี่ดวง .....	78
3.13 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิค การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีน้ำเงินทั้งสี่ดวง .....	79
3.14 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการ การสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง .....	85
3.15 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการ การสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวง .....	86
3.16 กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิค การกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีแดงทั้งสี่ดวง .....	90
3.17 กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิค การกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีน้ำเงินทั้งสี่ดวง .....	91

## สารบัญรูป (ต่อ)

รูปที่	หน้า
3.18 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิค การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีแดงทั้งสี่ดวง .....	101
3.19 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิค การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อย แอลอีดีสีน้ำเงินทั้งสี่ดวง .....	102
3.20 กราฟแสดงประสิทธิภาพความถูกต้อง (Accuracy) ในส่วน ของการฝึกฝน (Training) และการตรวจสอบความถูกต้อง (Validation) ของโครงข่ายประสาทเทียมเร็นด้อมฟอว์เรสต์ (Random Forest : RF) สำหรับชุดข้อมูลใหม่ด้วยเทคนิคการ วิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV .....	115
3.21 เมทริกซ์คอนฟิวชัน (Confusion Matrix) ของโครงข่ายประสาทเทียม เร็นด้อมฟอว์เรสต์ (Random Forest : RF) สำหรับชุดข้อมูลใหม่ ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV .....	116
3.22 กราฟแสดงค่าคุณลักษณะเฉพาะที่สำคัญสำหรับชุดข้อมูลใหม่ ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV ของระบบตรวจจับความเข้มแสงแอลอีดี .....	119
4.1 แผนผังการทำงานของระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียน โดยใช้เทคโนโลยีปัญญาประดิษฐ์ .....	123
4.2 แผนภาพรวมการออกแบบอุปกรณ์ของระบบควบคุมแสงแอลอีดีอัจฉริยะ .....	126
4.3 ภาพอุปกรณ์ฝังควบคุมระบบแสงแอลอีดีทั้งหมด .....	126
4.4 ภาพอุปกรณ์ แผงไฟแอลอีดี LED Driver และหม้อแปลงขนาด 24Vdc 20A .....	127

## สารบัญญรูป (ต่อ)

รูปที่	หน้า
4.5 การเชื่อมต่อวงจรเพื่อทดสอบประสิทธิภาพการควบคุมระดับ ความเข้มแสงแอลอีดี .....	129
4.6 ภาพตัวอย่างการเปิด – ปิดระบบควบคุมแสงแอลอีดี .....	130
4.7 ความสัมพันธ์กันระหว่างข้อมูลที่ป้อนในหน่วยเปอร์เซ็นต์ และค่าความแสง PPFd ของแสงแอลอีดีสีแดงและสีน้ำเงิน .....	133
4.8 ตัวอย่างหน้าต่างแรกๆของ โปรแกรมที่ใช้ในการทดสอบ .....	134
4.9 ตัวอย่างฟังก์ชันการใช้งานการตรวจจับความเข้มแสงแอลอีดี ด้วยปัญญาประดิษฐ์ของ โปรแกรมที่ใช้ในการทดสอบ .....	135
4.10 ตัวอย่างฟังก์ชันการใช้งานควบคุมความเข้มแสงแอลอีดีด้วยผู้ดูแล ระบบของ โปรแกรมที่ใช้ในการทดสอบ .....	136
4.11 ตัวอย่างการใช้งานการจำแนกประเภท/ตรวจจับ ความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ .....	136
4.12 ตัวอย่างหน้าต่างในการป้อนชุดข้อมูลค่าความเข้มแสง PPFd .....	137
4.13 ตัวอย่างหน้าต่างในการป้อนชุดข้อมูลค่าความเข้มแสง PPFd ที่ไม่ถูกต้อง .....	137
4.14 ตัวอย่างหน้าต่างในการป้อนชุดข้อมูลค่าความเข้มแสง PPFd ที่ถูกต้อง .....	138
4.15 ตัวอย่างหน้าต่าง โปรแกรมโดยรวมทั้งหมด .....	138
4.16 แผนภาพแสดงกระบวนการทำงานของ โปรแกรมทั้งสามรูปแบบ .....	139
4.17 ตัวอย่างหน้าต่าง โปรแกรมควบคุมความเข้มแสงแอลอีดี ตามอัตราส่วน 25% : 75% .....	140
4.18 ตัวอย่างหน้าต่าง โปรแกรมเพื่อตรวจจับความเข้มแสงแอลอีดีตาม อัตราส่วน 25% : 75% .....	141
4.19 ตัวอย่างหน้าต่าง โปรแกรมในการป้อนค่าความเข้มแสง PPFd เพื่อตรวจจับ .....	141
4.20 ตัวอย่างหน้าต่าง โปรแกรมแสดงผลลัพธ์ของการตรวจจับความเข้มแสงแอลอีดี .....	142
4.21 ตัวอย่างหน้าต่าง โปรแกรมควบคุมความเข้มแสงแอลอีดีตาม อัตราส่วน 75% : 75% .....	143

## สารบัญรูป (ต่อ)

รูปที่	หน้า
4.22 ตัวอย่างหน้าต่าง โปรแกรมเพื่อตรวจจับความเข้มแสงแอลอีดีตาม อัตราส่วน 75% : 75%.....	143
4.23 ตัวอย่างหน้าต่าง โปรแกรมที่ระบุสถานะและปรับเปลี่ยนความเข้มแอลอีดี เพื่อความเหมาะสม .....	144
4.24 ตัวอย่างหน้าต่าง การปรับเปลี่ยนความเข้มแสงให้เหมาะสมตามช่วงอายุ ของพืชตามเวลาจริง.....	144
4.25 ตัวอย่างหน้าต่าง ฟังก์ชันหลังจากปรับเปลี่ยนความเข้มแสงให้ เหมาะสมตามช่วงอายุของพืชตามเวลาจริง.....	145
4.26 ตัวอย่างหน้าต่าง การตรวจจับความเข้มแสงแอลอีดีหลังจากการปรับเปลี่ยน .....	145
4.27 ตัวอย่างหน้าต่าง โปรแกรมควบคุมความเข้มแสงแอลอีดี ตามอัตราส่วน 19% : 80% .....	146
4.28 ตัวอย่างหน้าต่าง โปรแกรมเพื่อตรวจจับความเข้มแสงแอลอีดี ตามอัตราส่วนที่ไม่สามารถระบุได้.....	147
4.29 การเชื่อมต่อวงจรเพื่อการทดลองการควบคุมความสว่าง ของระบบควบคุมแสงแอลอีดี โดยปรับเทียบกับเครื่องมือวัดค่า ทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument) .....	148
4.30 แสดงการควบคุมระดับความเข้มแสงแอลอีดีผ่านหน้าจอนิเตอร์ .....	149
4.31 แสดงการจับวางอุปกรณ์ควบคุมการส่องสว่างของแผงแสงแอลอีดี .....	149
4.32 แสดงการเชื่อมต่อ Digital Multimeter เพื่อการทดลอง.....	150
4.33 แสดงผลการวัดค่ากระแสไฟฟ้าด้วย Digital Multimeter .....	150
4.34 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 1 - 6 โดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument).....	151
4.35 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 7 - 12 โดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument).....	152

## สารบัญรูป (ต่อ)

รูปที่	หน้า
4.36 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 13 - 18 โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument).....	153
4.37 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีแดงดวงที่ 1 - 8 โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument).....	154
4.38 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีแดงดวงที่ 9 - 16 โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument).....	155
4.39 กราฟแสดงความสัมพันธ์การปรับระดับความสว่างของแสงแอลอีดีสีน้ำเงินกับค่ากระแสไฟฟ้า.....	156
4.40 กราฟแสดงความสัมพันธ์การปรับระดับความสว่างของแสงแอลอีดีสีแดงกับค่ากระแสไฟฟ้า.....	157
4.41 แสดงการเตรียมอุปกรณ์ทั้งหมดในการควบคุมและตรวจจิบระดับความเข้มแสงแอลอีดี.....	158
4.42 แสดงในส่วนการติดตั้งอุปกรณ์กล่องบรรจุไมโครคอนโทรลเลอร์และบอร์ดควบคุมแสง.....	159
4.43 แสดงในส่วนการติดตั้งอุปกรณ์ภายในกล่องบรรจุไมโครคอนโทรลเลอร์และบอร์ดควบคุมแสง.....	159
4.44 แสดงในส่วนการติดตั้งอุปกรณ์ภายในกล่องบรรจุแปลงแหล่งจ่ายกระแสสลับเป็นกระแสตรง.....	160
4.45 แสดงในส่วนการควบคุมด้วยโปรแกรมที่ออกแบบผ่านการแสดงภาพหน้าจอคอมพิวเตอร์.....	160
4.46 ตัวอย่างการแสดงผลความสว่างหลังการควบคุมแสงแอลอีดี.....	161
4.47 ตัวอย่างการเพาะต้นกล้าผักกาดหอมกรีนโอล์ในถาดเพาะต้นกล้าจากแสงดวงอาทิตย์.....	161

## สารบัญรูป (ต่อ)

รูปที่	หน้า
4.48 ตัวอย่างผักกาดหอมกรีน ไอค้ในถาดเพาะต้นกล้าจากแสงดวงอาทิตย์ .....	162
4.49 ตัวอย่างการเพาะต้นกล้าผักกาดหอมกรีน ไอค้ในถาดเพาะต้นกล้า จากแสงแอลอีดีแบบปรับค่าได้ .....	162
4.50 ตัวอย่างผักกาดหอมกรีน ไอค้ในถาดเพาะต้นกล้าจากแสงแอลอีดี แบบปรับค่าได้ .....	163
4.51 ตัวอย่างการวัดขนาดความสูงของลำต้นผักกาดหอมกรีน ไอค้ .....	163
4.52 ตัวอย่างการวัดขนาดความกว้างของลำต้นผักกาดหอมกรีน ไอค้ .....	164
4.53 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) ครั้งที่หนึ่ง .....	164
4.54 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) ครั้งที่สอง .....	165
4.55 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) ครั้งที่สาม .....	165
4.56 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) โดยเฉลี่ยค่าทั้งหมด .....	166
4.57 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) กับลำต้นผักกาดหอมกรีน ไอค้ .....	166
4.58 ตัวอย่างลำต้นและรากของผักกาดหอมกรีน ไอค้โดยส่วนแรก คือผักกาดหอมกรีน ไอค้ที่ได้จากแสงแอลอีดีแบบปรับค่าได้ .....	167
4.59 ตัวอย่างการเก็บข้อมูลน้ำหนักรากของผักกาดหอมกรีน ไอค้ .....	168
4.60 ตัวอย่างการเก็บข้อมูลน้ำหนักลำต้นของผักกาดหอมกรีน ไอค้ .....	168
4.61 ตัวอย่างปลูกผักกาดหอมกรีน ไอค้ด้วยแสงแอลอีดีปรับค่าได้รอบที่ 1 .....	169
4.62 ตัวอย่างปลูกผักกาดหอมกรีน ไอค้ด้วยแสงดวงอาทิตย์ได้รอบที่ 1 ส่วนที่ 1 .....	170
4.63 ตัวอย่างปลูกผักกาดหอมกรีน ไอค้ด้วยแสงดวงอาทิตย์ได้รอบที่ 1 ส่วนที่ 2 .....	170
4.64 ตัวอย่างปลูกผักกาดหอมกรีน ไอค้ด้วยแสงแอลอีดีปรับค่าได้รอบที่ 2 .....	174
4.65 ตัวอย่างปลูกผักกาดหอมกรีน ไอค้ด้วยแสงดวงอาทิตย์ได้รอบที่ 2 ส่วนที่ 1 .....	175
4.66 ตัวอย่างปลูกผักกาดหอมกรีน ไอค้ด้วยแสงดวงอาทิตย์ได้รอบที่ 2 ส่วนที่ 2 .....	175

# บทที่ 1

## บทนำ

เนื้อหาในบทนี้เป็น การอธิบายถึงความเป็นมา และเหตุจูงใจ สำหรับวิทยานิพนธ์ฉบับนี้ ซึ่งประกอบด้วย ความเป็นมา และความสำคัญของปัญหา วัตถุประสงค์ของวิทยานิพนธ์ แนวทางการดำเนินวิทยานิพนธ์ ประโยชน์ที่คาดว่าจะได้รับ และส่วนประกอบของวิทยานิพนธ์

### 1.1 ความเป็นมาและความสำคัญของปัญหา

ภาวะโลกร้อน (Global Warming) หมายถึง การที่อุณหภูมิเฉลี่ยของอากาศบนโลกสูงขึ้น ไม่ว่าจะเป็นภูมิอากาศบริเวณใกล้ผิวโลกและน้ำในมหาสมุทร สาเหตุที่ทำให้เกิดภาวะโลกร้อน เนื่องจากว่าก๊าซเรือนกระจกที่เพิ่มขึ้นจากการทำกิจกรรมต่าง ๆ ของมนุษย์ ไม่ว่าจะเป็น การเผาผลาญถ่านหินและเชื้อเพลิง รวมไปถึงสารเคมีที่มีส่วนผสมของก๊าซเรือนกระจกที่มนุษย์ใช้ และอื่น ๆ อีกมากมาย จึงทำให้ก๊าซเรือนกระจกเหล่านี้ลอยขึ้นไปรวมตัวกันอยู่บนชั้นบรรยากาศของโลก ทำให้รังสีของดวงอาทิตย์ที่ควรจะสะท้อนกลับออกไปในปริมาณที่เหมาะสม กลับถูก ก๊าซเรือนกระจกเหล่านี้กักเก็บไว้ ทำให้อุณหภูมิของโลกค่อย ๆ สูงขึ้นจากเดิม

ปัจจุบันการผลิตพืชเป็นสิ่งที่น่าท้าทายอย่างยิ่ง เนื่องจากพืชต้องเผชิญกับสภาพอากาศและสภาพแวดล้อมที่ไม่เอื้ออำนวยอยู่ตลอดเวลา จากการทำกิจกรรมต่าง ๆ ของมนุษย์ ด้วยเงื่อนไขของสภาพอากาศและสภาพภูมิประเทศที่ปัจจุบันมีส่วนสำคัญในการกำหนดอัตราการผลิตพืชอย่างหลีกเลี่ยงไม่ได้ และการผลิตพืชต้องใช้พลังงานแสงเป็นส่วนสำคัญและจำเป็นสำหรับการเจริญเติบโตของพืช ในบริเวณที่เป็นแหล่งกำเนิดแสงแบบธรรมชาติ (พลังงานแสงจากดวงอาทิตย์) ไม่เพียงพอสำหรับการเพิ่มประสิทธิภาพและการเจริญเติบโตของพืช อย่างไรก็ตามในช่วงเวลาที่อาหารของคนทั้งโลกขึ้นอยู่กับการผลิตพืชอย่างมาก ดังนั้นการวิจัยและค้นคว้าวิธีแก้ไขจึงทำให้เกิดแนวทางการจัดการฟาร์มที่เกี่ยวข้องกับการผลิตพืชผลในสภาพแวดล้อมที่มีการควบคุม หนึ่งในวิธีการแก้ไขปัญหานี้คือพลังงานแสงจาก Light-Emitter Diode (LED) ในโรงเรือน

การปลูกพืชโดยใช้พลังงานแสงจาก Light-Emitter Diode (LED) เป็นสิ่งที่แตกต่างจากการใช้พลังงานแสงจากดวงอาทิตย์และหลอดไฟชนิดที่ต่าง ๆ ที่รู้จักกัน โดยพื้นฐานแล้ว สิ่งที่เหนือกว่าคือการพัฒนาอย่างรวดเร็วของเทคโนโลยีแสงแอลอีดี ทำให้คุณสมบัติประหยัดพลังงานดีกว่าแหล่งกำเนิดแสงแบบเดิม การใช้แสงแอลอีดีในการเกษตรสามารถลดการสิ้นเปลืองพลังงานได้อย่างมีประสิทธิภาพ และยิ่งไปกว่านั้นคือแสงแอลอีดียังสามารถควบคุมเจดสีและสเปกตรัมที่แตก



ต่างกันและปรับแหล่งกำเนิดแสงได้อย่างยืดหยุ่นตามความต้องการสเปกตรัมที่แตกต่างกันในระยะต่าง ๆ ของการเจริญเติบโตของพืชเร่งอัตราการเติบโตและใช้พลังงานอย่างมีประสิทธิภาพมากขึ้น รวมทั้งการมาของ Artificial Intelligence (AI) ที่เป็นเทคโนโลยีที่ถูกรวบรวมให้มีระบบทำงานเหมือนกับการทำงานของสมองมนุษย์ที่แทรกอยู่ในเทคโนโลยีและนวัตกรรมต่าง ๆ ที่นำไปสู่การเพิ่มพูนทางด้านมูลค่าและตอบโจทย์ในทางความต้องการของผู้ใช้งานทั้งในด้านธุรกิจด้านอุตสาหกรรม และด้านงานวิจัย ที่ให้ทั้งความรวดเร็ว และแม่นยำ ดังนั้นจึงได้ทำการคิดค้นเพื่อการปลูกพืชให้มีประสิทธิภาพ ก็คือการนำปัญญาประดิษฐ์มาประยุกต์ร่วมกับชุดอุปกรณ์พลังงานแสงแอลอีดี

สำหรับงานวิจัยในวิทยานิพนธ์ฉบับนี้ โดยอันดับแรกนำเสนอลักษณะเฉพาะที่สำคัญในชุดข้อมูลที่เตรียมไว้จากการตรวจจับแสงจากกล้อง Logitech C310 HD Webcam เพื่อนำมาพัฒนาระบบให้มีประสิทธิภาพและรวดเร็วยิ่งขึ้น จากนั้นนำเสนอการจำลองเหตุการณ์ในการทำนายความเข้มของแสงแอลอีดี ว่าชุดข้อมูลมีประสิทธิภาพเพียงพอต่อการไปใช้ในส่วนของการควบคุมแสงในเหตุการณ์จริง และท้ายที่สุดนำเสนอในส่วนของชุดอุปกรณ์และเหตุการณ์จริงที่นำมาประยุกต์ใช้งานร่วมกับปัญญาประดิษฐ์โดยแสดงความแม่นยำ และค่าความเข้มของแสงให้เหมาะสมกับพืชในแต่ละช่วงอายุ

## 1.2 วัตถุประสงค์ของการวิจัย

1.2.1 เพื่อพัฒนาระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์

1.2.2 เพื่อออกแบบระบบควบคุมแสงแอลอีดี (Light-Emitter Diode : LED) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์ สำหรับการใช้ปลูกพืชให้เหมาะสมต่อการเจริญเติบโตในแต่ละช่วงอายุโดยใช้ปัญญาประดิษฐ์ควบคุมการทำงาน

1.2.3 สามารถใช้เป็นผลิตภัณฑ์ต้นแบบระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์ เพื่อนำไปพัฒนาและต่อยอดให้มีมูลค่าและประสิทธิภาพยิ่งขึ้น

## 1.3 ขอบเขตงานวิจัย

1.3.1 ดำเนินการสืบค้นงานวิจัยที่เกี่ยวข้องหรือสัมพันธ์กับระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์

1.3.2 ดำเนินการเขียนโปรแกรมอัลกอริทึมในการแปลงมิติสีและโมเดลโครงข่ายประสาทเทียมโดยใช้โปรแกรม Visual Studio Code 2019 ในการจำลองผลและเหตุการณ์ของระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือน โดยใช้เทคนิคปัญญาประดิษฐ์

1.3.3 ดำเนินการสร้างชุดอุปกรณ์ควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์โดยประยุกต์ใช้กับวิธีการที่ถูกต้องแบบ

1.3.4 ดำเนินการทดสอบระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์และปรับปรุงแก้ไขเพื่อให้มีประสิทธิภาพมากยิ่งขึ้น

1.3.5 วิเคราะห์และสรุปผลที่ได้จากการทดสอบ พร้อมทั้งปรับปรุงแก้ไขส่วนที่บกพร่อง

1.3.6 จัดทำรูปเล่มวิทยานิพนธ์

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 เพื่อสามารถตรวจจับความเข้มแสงแอลอีดี (Light-Emitter Diode) ได้อย่างถูกต้อง

1.4.2 สามารถเป็นผลิตภัณฑ์ต้นแบบระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์

1.4.3 สามารถนำเทคโนโลยีปัญญาประดิษฐ์มาประยุกต์ใช้กับงานด้านการตรวจจับความเข้มแสงแอลอีดี (Light-Emitter Diode) ได้อย่างถูกต้อง

## 1.5 ส่วนประกอบของวิทยานิพนธ์

สำหรับเนื้อหาของวิทยานิพนธ์ฉบับนี้ นำเสนอการศึกษาค้นคว้า รวบรวมข้อมูล ออกแบบระบบ ทดสอบระบบ วิเคราะห์และสรุปผล โดยประกอบไปด้วยเนื้อหาทั้งหมด 5 บท

**บทที่ 1** กล่าวถึงความเป็นมาและความสำคัญของปัญหา วัตถุประสงค์ของการวิจัย ขอบเขตการวิจัย ประโยชน์ที่คาดว่าจะได้รับ วิธีดำเนินการวิจัยของงานวิจัยนี้

**บทที่ 2** กล่าวถึงแนวคิด ทฤษฎี เอกสารและงานวิจัยที่เกี่ยวข้องกับระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์

**บทที่ 3** กล่าวถึงวิธีดำเนินงานส่วนที่ 1 การจำลองเหตุการณ์สำหรับระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์

**บทที่ 4** กล่าวถึงวิธีดำเนินงานส่วนที่ 2 การสร้างระบบควบคุมแสงแอลอีดี (Light-Emitter Diode) อัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์บนระบบฮาร์ดแวร์

**บทที่ 5** กล่าวถึงการสรุปผลของการวิจัย ข้อเสนอแนะและแนวทางการพัฒนาต่อในอนาคต

## 1.6 สรุป

ปัญหาและความเป็นมาของงานวิจัยนี้ เป็นงานวิจัยที่เกี่ยวข้องกับการปลูกพืชโดยประยุกต์ร่วมกับการใช้พลังงานแสงจากแอลอีดี (Light-Emitter Diode) และเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence) เพื่อควบคุมสีและสเปกตรัมที่แตกต่างกันและปรับแหล่งกำเนิดแสงได้อย่างยืดหยุ่นตามความต้องการสเปกตรัมที่แตกต่างกันในระยะต่าง ๆ ของการเจริญเติบโตของพืช เพื่อเร่งอัตราการเติบโตและใช้พลังงานอย่างมีประสิทธิภาพมากขึ้นและเพิ่มมูลค่าผลิตภัณฑ์ทั้งในด้านธุรกิจ ด้านอุตสาหกรรมและด้านงานวิจัย เป็นต้น



## บทที่ 2

### ทฤษฎีความรู้พื้นฐาน ปรัชญาวรรณกรรมและงานวิจัยที่เกี่ยวข้อง

#### 2.1 บทนำ

ในบทที่ 2 นี้จะแบ่งออกเป็น 3 ส่วนหลัก ๆ โดย อันดับแรกจะอธิบายถึงทฤษฎีความรู้พื้นฐาน หลักการที่เกี่ยวข้องกับงานวิจัย ได้แก่ ทฤษฎีความรู้พื้นฐานของไดโอดเปล่งแสง ความหนาแน่นของโฟตอนพลังค์รังสีเคราะห์ด้วยแสง การประมวลผลภาพดิจิทัล ทฤษฎีระบบสมองกลฝังตัว หลักการของปัญญาประดิษฐ์ โครงข่ายประสาทเทียม ต่อมาอันดับที่สองจะเป็นในส่วนของอุปกรณ์ที่ต้องใช้จะประกอบไปด้วย อุปกรณ์แปลงกระแสไฟสำหรับแสงแอลอีดี อุปกรณ์สมองกลฝังตัว Nvidia Jetson Nano Developer Kit อุปกรณ์เว็บแคม Logitech C310 HD เซนเซอร์ควมตรัมเอ็มคิว – 200 และ โมดูล PCA9685 สำหรับการควบคุมระดับความเข้มแสงแอลอีดีและในท้ายสุดอันดับที่สามจะเป็นปรัชญาวรรณกรรมและงานวิจัยที่เกี่ยวข้อง


#### 2.2 ทฤษฎีความรู้พื้นฐาน

##### 2.2.1 ไดโอดเปล่งแสง (Light Emitting Diode)

ไดโอดเปล่งแสง (Light Emitting Diode) เป็นอุปกรณ์สารกึ่งตัวนำอย่างหนึ่งจัดอยู่ในจำพวกไดโอด ที่สามารถเปล่งแสงในช่วงสเปกตรัมแคบ เมื่อถูกไบอัสทางไฟฟ้าในทิศทางไปข้างหน้า ปรากฏการณ์นี้อยู่ในรูปของ electroluminescence สีของแสงที่เปล่งออกมานั้นขึ้นอยู่กับองค์ประกอบทางเคมีของวัสดุกึ่งตัวนำที่ใช้ และเปล่งแสงได้ใกล้ช่วงอัลตราไวโอเล็ต ช่วงแสงที่มองเห็น และช่วงอินฟราเรด ผู้พัฒนาไดโอดเปล่งแสงขึ้นเป็นคนแรก คือ นิก โฮโลยัก (Nick Holonyak Jr.) แห่งบริษัทเจเนรัล อิเล็กทริก (General Electric Company) โดยได้พัฒนาไดโอดเปล่งแสงในช่วงแสงที่มองเห็น และสามารถใช้งานได้เชิงปฏิบัติเป็นครั้งแรก เมื่อ ค.ศ. 1962

ไดโอดเปล่งแสงมีโครงสร้างประกอบด้วยสารกึ่งตัวนำสองชนิด คือ สารกึ่งตัวนำชนิดเอ็น (N-type semiconductor) และสารกึ่งตัวนำชนิดพี (P-type semiconductor) ประคบเข้าด้วยกัน มีผิวข้างหนึ่งเรียบคล้ายกระจก เมื่อส่งไฟฟ้ากระแสตรงผ่านไดโอดเปล่งแสง โดยจ่ายไฟบวกให้ขาแอนโนด (A) และจ่ายไฟลบให้ขาแคโทด (K) ทำให้อิเล็กตรอนที่สารกึ่งตัวนำชนิดเอ็นมีพลังงานสูงขึ้นจนสามารถวิ่งข้ามรอยต่อจากสารชนิดเอ็นไปรวมกับโฮล (Hole) ในสารกึ่งตัวนำชนิด

ฟิสิกส์ที่อิเล็กตรอนเคลื่อนที่ผ่านรอยต่อพี-เอ็น จะทำให้เกิดกระแสไฟฟ้าไหล ส่งผลให้ระดับพลังงานของอิเล็กตรอนเปลี่ยนไปและจะคายพลังงานออกมาในรูปคลื่นแสง โครงสร้างและการทำงานของไดโอดเปล่งแสงแสดงดังรูปที่ 2.1



รูปที่ 2.1 ไดโอดเปล่งแสง

(ก) ตัวอย่างแอลอีดี

(ข) P-N junction และ

(ค) สัญลักษณ์ของไดโอดเปล่งแสง

## 2.2.2 ความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง

### (Photosynthetic Photon Flux Density)

ความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density - PPF) เป็นปริมาณโฟตอนที่สังเคราะห์ด้วยแสง (400-700 นาโนเมตร) ที่กระทบพื้นผิวต่อหน่วยพื้นที่ต่อหน่วยเวลา หน่วยคือ  $\mu\text{mol}$  (ของโฟตอน)  $\cdot \text{m}^{-2} \cdot \text{s}^{-1}$  ซึ่งแสงสว่างสำหรับพืชแตกต่างจากการให้แสงสว่างสำหรับมนุษย์ พลังงานแสงสำหรับมนุษย์มีหน่วยวัดเป็นลูเมนส์ (lumens) โดยแสงที่ตกลงบนพื้นผิวที่วัดเป็นความสว่างมีหน่วยเป็นลักซ์ (lux) (ลูเมนต่อตารางเมตร – lumens per square meter) หรือฟุตแคนเดิล (footcandels) (ลูเมนต่อตารางฟุต – lumens per square foot) ในทางกลับกันพลังงานแสงสำหรับพืชถูกวัดเป็นรังสีแอกทีฟสังเคราะห์ด้วยแสง (Photosynthetically Active Radiation - PAR) โดยแสงที่ตกลงบนพื้นผิวที่วัดเป็นความหนาแน่นฟลักซ์โฟตอนสังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density - PPF) ด้วยหน่วย  $\mu\text{mol}/(\text{s} \cdot \text{m}^2)$

### 2.2.3 การประมวลผลภาพดิจิทัล (Digital Image Processing)

ความพยายามทางด้านการประมวลผลภาพได้เริ่มขึ้นในปี 2564 ณ ห้องแล็บ Jet Propulsion (Pasadena California) ซึ่งได้นำการบวนการประมวลผลภาพมาใช้ในการพิจารณาภาพถ่ายดาวเทียมของดวงจันทร์ ต่อมาได้มีการตั้งสาขาทางวิทยาศาสตร์สาขาใหม่มีชื่อว่า Digital image processing หลังจากนั้นงานทางด้านการประมวลผลภาพก็พัฒนาขึ้นเรื่อย ๆ และใช้กันอย่างกว้างขวางสำหรับงานในหลาย ๆ ด้านตัวอย่างเช่นทางได้สื่อสารโทรคมนาคม การสื่อสารทางโทรทัศน์ ทางด้านการพิมพ์ ทางด้านกราฟฟิก การแพทย์ และการค้นคว้าทางวิทยาศาสตร์

Digital image processing จะเกี่ยวกับการแปลงข้อมูลภาพให้อยู่ในรูปแบบข้อมูลดิจิทัล(Digital format) ซึ่งสามารถที่จะนำเอาข้อมูลนี้จัดผ่านกระบวนการต่าง ๆ ด้วยดิจิทัลคอมพิวเตอร์ได้ ในระบบของดิจิทัล อินพุตและเอาพุตของระบบจะอยู่ในรูปแบบดิจิทัลเท่านั้น

Digital image analysis จะเกี่ยวกับวิธีการอธิบายและการจดจำข้อมูลภาพดิจิทัล ซึ่งอินพุตของระบบจะเป็นข้อมูลภาพดิจิทัลและเอาพุตจะเป็นเครื่องหมายที่ใช้แทนข้อมูลภาพดิจิทัลเหล่านั้น ในการวิเคราะห์ภาพมีอยู่หลายวิธีด้วยกันที่ได้นำมาจากการทำงานของตามนุษย์ (human vision) นั่นก็คืองานทางด้าน Computer Vision เป็นลักษณะเดียวกับ Digital image analysis นั่นเอง การมองเห็นของมนุษย์นับว่าเป็นกระบวนการที่ซับซ้อนซึ่งลักษณะเทคนิคโดยทั่ว ๆ ไปในกระบวนการ Digital image analysis และ Computer Vision จะค่อนข้างซับซ้อนเช่นกัน

#### 1. รูปร่างของภาพ (Image Shape)

วัตถุที่มีอยู่ตามธรรมชาติและที่มนุษย์สร้างขึ้นมีรูปร่างที่แตกต่างกันไป ทั้งที่เป็นรูปทรงเรขาคณิตและไม่เป็นรูปทรงเรขาคณิต ในศาสตร์ของการประมวลผลภาพนั้น การกำหนดขอบเขตของภาพทุกภาพให้อยู่ในรูปสี่เหลี่ยม (Rectangular image model) เป็นวิธีที่นิยมใช้กันมากที่สุด เนื่องจากการอ่านภาพ การจัดเก็บข้อมูลภาพในหน่วยความจำ และการแสดงผลภาพออกทางอุปกรณ์ต่าง ๆ เป็นไปได้โดยมีประสิทธิภาพ

การเก็บข้อมูลภาพลงหน่วยความจำของคอมพิวเตอร์สามารถทำได้โดยการจองหน่วยความจำของเครื่องไว้ในรูปของตัวแปรอะเรย์ (array) โดยค่าในแต่ละช่องของอะเรย์แสดงถึงคุณสมบัติของจุดภาพ (pixel) และตำแหน่งของช่องอะเรย์เป็นตัวกำหนดตำแหน่งของจุดภาพ

สมมติให้ Image เป็นตัวแปรแบบอะเรย์ขนาด  $M \times N$  ( $M$  แถว และ  $N$  คอลัมน์) ที่ใช้เก็บภาพขนาด  $M \times N$  จุด ( $M$  จุดในแนวนอน และ  $N$  จุดในแนวตั้ง) ค่าสี (หรือความสว่าง ในกรณีที่เป็นภาพ grey level) ของจุดภาพในแถวที่ 5 คอลัมน์ที่ 4 จะตรงกับค่าของ Image(5,4) จะเห็นว่าเราใช้ตำแหน่งของจุดภาพทั้งสองแกนเป็นตัวชี้ค่าข้อมูลในอะเรย์ จากการใช้หน่วยความจำเพื่อการเก็บภาพในลักษณะที่กล่าวมา เนื้อที่ในการเก็บภาพสามารถคำนวณได้จาก  $M \times N \times g$  เมื่อ  $g$  เป็น

จำนวนเต็มที่แทนจำนวนบิตของข้อมูลในแต่ละจุดภาพ ตัวอย่างถ้า  $g$  มีค่าเท่ากับ 8 บิต เราจะสามารถเก็บความแตกต่างของระดับสีที่เป็นไปสูงสุด

256 ระดับ ค่า  $M$  และ  $N$  จะเป็นตัวบอกถึงความละเอียดของภาพ สำหรับคอมพิวเตอร์ทั่วไปในระบบ VGA (Video Graphic Array) จะมีขนาด 640x480, 800x600 และ 1024x768 จุด เป็นต้น การกำหนดความละเอียดจะขึ้นอยู่กับงานที่จะใช้ ในงานบางอย่างใช้ความละเอียดแค่ 30 x 50 จุด ก็พอแล้วแต่ในงานบางชนิด ใช้ความละเอียดถึง 1000 x 1000 จุด ก็ยังไม่พอ

ปกติแล้วในการเก็บข้อมูลภาพโดยเครื่องมือต่าง ๆ จะเก็บตามมาตรฐานของโทรทัศน์ซึ่งมีอัตราส่วน  $x$  ต่อ  $y$  เท่ากับ 4:3 สำหรับเครื่องมือเก็บข้อมูลภาพที่ไม่เป็นไปตามอัตราส่วน 4:3 เมื่อนำภาพนี้ไปแสดงในจอภาพมาตรฐานจะทำให้ภาพที่แสดงนั้นมีขนาดของจุดภาพไม่เป็นสี่เหลี่ยมจัตุรัสเช่นในบางระบบอาจจะใช้ความละเอียดในการแสดงเท่ากับ 640 x 512 ซึ่งจะทำให้ขนาดของจุดภาพที่ได้มีขนาดของด้านกว้างมีความยาวมากกว่าด้านสูง ซึ่งลักษณะดังกล่าวนี้เป็นหัวข้อที่ต้องสนใจสำหรับการเขียน โปรแกรมทางด้านกราฟฟิกและการจัดการข้อมูล

จำนวนสีสูงสุดที่เป็นไปได้ของแต่ละจุดภาพขึ้นอยู่กับจำนวนบิตที่ใช้ เมื่อมีการกำหนดให้ขนาดของบิตต่อจุด มากขึ้นจะทำให้จำนวนของสีมากขึ้นด้วย ตัวอย่างเช่น

$$1 \text{ บิต} = 2^1 = 2 \text{ สี}$$

$$2 \text{ บิต} = 2^2 = 4 \text{ สี}$$

$$4 \text{ บิต} = 2^4 = 16 \text{ สี}$$

$$8 \text{ บิต} = 2^8 = 256 \text{ สี}$$

$$16 \text{ บิต} = 2^{16} = 65536 \text{ สี}$$

สำหรับการแสดงข้อมูลภาพที่มีขนาด 1 บิตและ 8 บิตนั้นจะมีความทำงานที่จะใกล้เคียงกันเนื่องจากหน่วยประมวลผลจะไม่สามารถจัดการกับข้อมูลที่เป็นบิตเดี่ยว ๆ ได้ดังนั้นในการแสดงข้อมูลออกทางจอภาพตัวโปรเซสเซอร์จะทำการก๊อปปี้ข้อมูลทั้ง 8 บิต(1 Byte) ส่งให้กับจอภาพซึ่งในกรณีที่มีขนาด 1 บิต เมื่อโปรเซสเซอร์จะทำงานกับบิตแรกที่ต้องการแล้วก็จะทำการก๊อปปี้ข้อมูลชุดใหม่ทันทีโดยที่ไม่เกี่ยวกับข้อมูลอีก 7 บิตที่เหลือส่วนในกรณี Pixel ที่มีขนาด 8 บิต โปรเซสเซอร์จะทำการก๊อปปี้ข้อมูลชุดใหม่ก็ต่อเมื่อโปรเซสเซอร์ทำงานกับทุกบิตแล้ว

ตัวอย่างสำหรับระบบที่มีความละเอียดเท่ากับ 800x600 และมีขนาด 16 บิตต่อ Pixel จะสามารถแสดงสีได้ทั้งหมด 65536 ระดับและต้องใช้เนื้อที่ในการเก็บเท่ากับ 800x600x16 บิต

## 2. มาตรฐานของสี

มาตรฐานของสีที่ใช้อยู่ในปัจจุบันมีอยู่หลายระบบด้วยกัน ทั้งนี้จะขึ้นอยู่กับ การนำไปใช้ แต่โดยทั่วไปแล้วทุกมาตรฐานจะมีแนวคิดเดียวกันคือ การแทนจุดสีด้วยจุดที่อยู่ ภายในสเปส 3 มิติ โดยจะมีแกนอ้างอิงสำหรับจุดสีนั้นในสเปสซึ่งแต่ละแกนจะมีความเป็นอิสระ ต่อกัน ตัวอย่างระบบสีที่นิยมใช้กัน ได้แก่ ระบบ RGB และ HSV (Hue Saturation Value)

## 3. ระบบสี RGB

ระบบสี RGB เป็นระบบสีที่เกิดจากการรวมกันของแสงสีแดง เขียวและน้ำเงิน โดยมี การรวมกันแบบ Additive ซึ่งโดยปกติจะนำไปใช้ในจอภาพแบบ CRT (Cathode ray tube) ใน การใช้งานระบบสี RGB ยังมีการสร้างมาตรฐานที่แตกต่างกันออกไปที่นิยมใช้งานได้แก่ RGBCIE และ RGBNTSC

ระบบสีแบบ RGB ของ CIE เป็นระบบสีที่พัฒนาขึ้นโดย CIE (Commission International l'Eclairage) ซึ่งอ้างอิงสีด้วยสีแดงที่ 700 nm สีเขียวเท่ากับ 546.1 nm และสีน้ำเงิน 435.8 nm

ระบบสีแบบ RGB ของ NTSC เป็นระบบที่พัฒนาโดย NTSC (National Television System Committee) เพื่อใช้สำหรับการแสดงภาพของจอภาพแบบ CRT เป็นมาตรฐาน สำหรับผู้ผลิตแบบ CRT ให้มีลักษณะเดียวกัน

## 4. ระบบสี HSV


ระบบสี HSV (Hue Saturation Value) เป็นการพิจารณาสี โดยใช้ Hue Saturation และ Value ซึ่ง Hue คือค่าสีของสีหลัก(แดง เขียวและน้ำเงิน)ในทางปฏิบัติจะอยู่ระหว่าง 0 และ 255 ซึ่งถ้า Hue มีค่าเท่ากับ 0 จะแทนสีแดงและเมื่อ Hue มีค่าเพิ่มขึ้นเรื่อย ๆ สีก็จะ เปลี่ยนแปลงไปตามสเปกตรัมของสีจนถึง 256 จึงจะกลับมาเป็นสีแดงอีกครั้ง ซึ่งสามารถแทนให้อยู่ ในรูปขององศาได้ ดังนี้คือ สีแดง = 0 องศา สีเขียวเท่ากับ 120 องศา สีน้ำเงินเท่ากับ 240 องศา Hue สามารถคำนวณได้จากระบบสี RGB ได้ดังนี้

$$red_h = red - \min(red, green, blue) \quad (2.1)$$

$$green_h = green - \min(red, green, blue) \quad (2.2)$$

$$blue_h = blue - \min(red, green, blue) \quad (2.3)$$





รูปที่ 2.2 แสดงระบบสี HSV ที่มา : fivedots.coe.psu.ac.th

จากลักษณะโมเดลของระบบ Hue พบว่าจะมีค่าอย่างน้อยหนึ่งค่าที่จะเท่ากับ 0 แต่ถ้ามีสองค่าเท่ากับ 0 แล้ว hue จะเป็นมุมของสี(ค่าสี)มีค่าเป็นไปตามสีที่สามและถ้าทั้งสามสีมีค่าเท่ากับ 0 แล้วจะทำให้ไม่มีค่าของ Hue หรือสีที่ได้จะมีค่าเท่ากับสีขาวนั่นเอง ตัวอย่างเช่น จอภาพขาว-ดำ ถ้าเกิดมีสีแดงหนึ่งมีค่าเท่ากับ 0 จะทำให้ค่าสีที่ได้เป็นไปตามสีที่เหลือ การให้นำหนักในการพิจารณาเมื่อสีแดงมีค่าเท่ากับ 0

$$\frac{(240 \times blue_h) + (120 \times green_h)}{blue_h + green_h} \quad (2.4)$$

Saturation คือความบริสุทธิ์ของสีซึ่งถ้า Saturation มีค่าเท่ากับ 0 แล้วสีที่ได้จะไม่มี Hue ซึ่งจะเป็นสีขาวล้วนแต่ถ้า Saturation มีค่าเท่ากับ 255 แสดงว่าจะไม่มีแสงสีขาวผสมอยู่เลย

Saturation สามารถคำนวณได้ดังนี้

$$Saturation = \frac{\max(red, green, blue) - \min(red, green, blue)}{\max(red, green, blue)} \quad (2.5)$$

Value คือความสว่างของสี ซึ่งสามารถวัดได้โดยค่าความเข้มของความสว่างของแต่ละสีที่ประกอบกันสามารถคำนวณได้จาก

$$Value = \max(red, green, blue) \quad (2.6)$$

### 2.2.4 ระบบสมองกลฝังตัว (Embedded System)

ระบบสมองกลฝังตัว (Embedded System) เปรียบเสมือนเครื่องคอมพิวเตอร์ส่วนบุคคล (Personal Computer) หรือคอมพิวเตอร์วางตั้ง (Notebook) ที่คนส่วนใหญ่รู้จักและใช้งานทุกวันนี้ แต่ระบบสมองกลฝังตัวจะเป็นการย่อเครื่องคอมพิวเตอร์ให้เล็กลงโดยเหลือเพียงแผงวงจรอิเล็กทรอนิกส์ขนาดเล็กและมีขีดความสามารถน้อยกว่า วัตถุประสงค์หลักของการใช้งานระบบสมองกลฝังตัวคือนำไปใส่ในอุปกรณ์ที่ต้องการให้ทำงานได้เองโดยอัตโนมัติ เหมือนมีสมองกลฝังตัวอยู่ใน ไม่ว่าจะเป็นอุปกรณ์พื้นฐานในชีวิตประจำวัน เช่น หม้อหุงข้าว เครื่องซักผ้า ตู้เย็น (รุ่นอัจฉริยะ) โทรศัพท์มือถือ กล้องดิจิทัล กล้องวิดีโอ หรืออุปกรณ์ควบคุมที่มีความซับซ้อน เช่น ระบบควบคุมการจ่ายน้ำมันหรือก๊าซในรถยนต์ อากาศยานไร้คนขับ เป็นต้น ระบบสมองกลฝังตัวได้รับความนิยมในการประยุกต์ใช้กับระบบควบคุมต่าง ๆ เนื่องจากมีขนาดเล็กและมีประสิทธิภาพ

### 2.2.5 ปัญญาประดิษฐ์ (Artificial Intelligence)

ปัญญาประดิษฐ์ (Artificial Intelligence - AI) เป็นศาสตร์แขนงหนึ่งของสาขาวิทยาศาสตร์คอมพิวเตอร์ที่หลากหลาย ซึ่งเกี่ยวข้องกับวิธีการสร้างคอมพิวเตอร์ให้มีความฉลาดเพื่อให้สามารถคิด ทำงาน และเรียนรู้ได้ด้วยตัวเอง โดยมีจุดประสงค์หลักก็เพื่อให้มันสามารถทำงานแทนมนุษย์ได้ แต่ความก้าวหน้าในการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกกำลังก่อให้เกิดการเปลี่ยนแปลงกระบวนทัศน์ในแทบทุกภาคส่วนของอุตสาหกรรมเทคโนโลยี ในตอนนี้เทคโนโลยีปัญญาประดิษฐ์ยังอยู่ในช่วงเริ่มต้นของการพัฒนา และมีการคาดว่าจะมันจะมีความสามารถเหนือมนุษย์ในช่วง Strong AI โดยการที่จะเปลี่ยนผ่านไปสู่วางนั้น Machine จำเป็นต้องเรียนรู้วิธีการคิดของมนุษย์ทั้งในด้านเทคนิคและกระบวนการจัดเก็บข้อมูลในสมอง ซึ่งชนิดของปัญญาประดิษฐ์ถูกแบ่งออกเป็น 2 ส่วนย่อยได้แก่

1. การเรียนรู้ของเครื่อง (Machine learning) เป็นส่วนที่ถูกใช้งานเสมือนเป็นสมองของปัญญาประดิษฐ์ ซึ่งเป็นการสอนให้ระบบคอมพิวเตอร์ทำการเรียนรู้ได้โดยตนเองโดยการใช้ข้อมูลในการฝึกฝนหรือการสอนอัลกอริทึมให้เรียนรู้ทำความเข้าใจและตัดสินใจได้ด้วยตัวเองจากข้อมูลที่ป้อนให้ การเรียนรู้ของเครื่องสามารถถูกแบ่งออกเป็นการเรียนรู้ได้ 2 แบบใหญ่ ๆ ได้แก่ การเรียนรู้แบบผู้สอน (Supervised Learning) และ การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

การเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นอัลกอริทึมที่จำเป็นต้องใช้ข้อมูลในส่วนสำหรับฝึกฝน (training data) และส่วนที่รับกลับมาเพื่อปรับปรุง (feedback) จากมนุษย์เพื่อที่จะเรียนรู้ความสัมพันธ์ระหว่างข้อมูลที่ถูกป้อนเข้ามาสู่ข้อมูลที่ออกไป ส่วนการเรียนรู้โดยไม่มีผู้ช่วยสอน (Unsupervised) นั้น อัลกอริทึมจะตรวจสอบเฉพาะข้อมูลที่ป้อนเข้ามาเท่านั้น


โดยปราศจากการให้ผลลัพธ์ที่จะเกิดขึ้น เมื่อทำนายผลลัพธ์จากชุดข้อมูลจำนวนมากได้มากเท่าไร ก็ จะยิ่งแสดงความสามารถในการเรียนรู้เชิงลึก (Deep Learning) มากเท่านั้น

2. การเรียนรู้เชิงลึก (Deep Learning) เป็นซับเซตของการเรียนรู้ของเครื่อง ซึ่งการ เรียนรู้เชิงลึกเป็นเทคนิคในการสร้างปัญญาประดิษฐ์ โดยใช้โครงข่ายประสาทเทียมหรือข่ายงาน ประสาทเทียมหลายๆ ชั้นเลียนแบบระบบเซลล์ประสาทในสมองของมนุษย์ (Neural Network) ซึ่ง โครงข่ายนี้เรียกว่า “โครงข่ายประสาทเทียม” (Artificial Neural Networks - ANN)

### 2.2.6 โครงข่ายประสาทเทียม (Neural Networks)


โครงข่ายประสาทเทียม คือระบบคอมพิวเตอร์จากโมเดลทางคณิตศาสตร์ที่จำลอง การทำงานของระบบประสาทในสมองของมนุษย์ โครงข่ายประสาทเทียมสามารถเรียนรู้ที่จะ ทำหน้าที่มอบหมายจากการเรียนรู้ผ่านตัวอย่าง โดยโครงข่ายประสาทเทียมประกอบไปด้วยโหนด และเส้นเชื่อมระหว่างโหนด โดยแบ่งชั้นในการทำงาน 3 ชั้นดังนี้

1. ชั้นอินพุต (Input Layer) คือชั้นที่รับข้อมูลเข้ามาในโครงข่ายประสาท โดยชั้นนี้ มีเพียงหนึ่งชั้นเท่านั้นละจำนวน โหนดจะมีเท่ากับจำนวนคุณลักษณะ (Attribute) ของชุดข้อมูล
2. ชั้นซ่อน (Hidden Layer) คือชั้นที่รับข้อมูลต่อมาจากชั้นอินพุตหรือชั้นซ่อนก่อน หน้า โดยในชั้นนี้มีการทำงานเปรียบเสมือนส่วนที่เรียนรู้ ซึ่งในชั้นนี้สามารถมีจำนวนชั้นที่ซ่อนกัน ได้มากกว่าหนึ่ง
3. ชั้นเอาต์พุต (Output Layer) คือชั้นผลลัพธ์ที่ได้จากชั้นซ่อน จำนวนของโหนด ในชั้นนี้ ขึ้นอยู่กับจำนวนข้อมูลที่ต้องการจำแนก



รูปที่ 2.3 ตัวอย่างพื้นฐานของโครงข่ายประสาทเทียม ที่มา : [guopai.github.io/ml-blog14.html](http://guopai.github.io/ml-blog14.html)

จากรูปที่ 2.3 แสดงให้เห็นถึงตัวอย่าง โครงข่ายประสาทเทียมที่ภายในมีการเชื่อมต่อระหว่างกันทั้ง 3 ระดับคือ ชั้นอินพุตหนึ่งชั้น จำนวน 3 โหนด ชั้นซ่อนหนึ่งชั้น จำนวน 4 โหนดและชั้นเอาต์พุตหนึ่งชั้น จำนวน 2 โหนด ซึ่งโครงข่ายประสาทเทียมในตัวอย่างนี้จะมีอินพุต 3 ค่าเข้ามาในโครงข่าย  $X(n)$  และแต่ละอินพุตจะถูกคูณด้วยค่าน้ำหนัก (Weight) จากนั้นจะถูกนำมา รวมและส่งผ่านฟังก์ชัน (Transfer Function) เพื่อหาเอาต์พุต ซึ่งแสดงได้ดังรูป 2.4



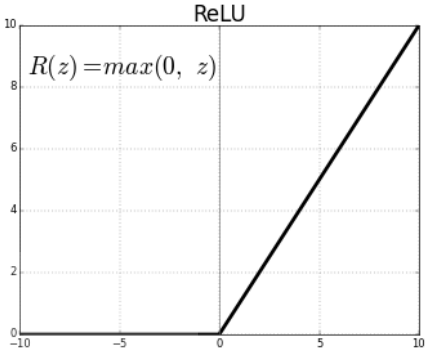
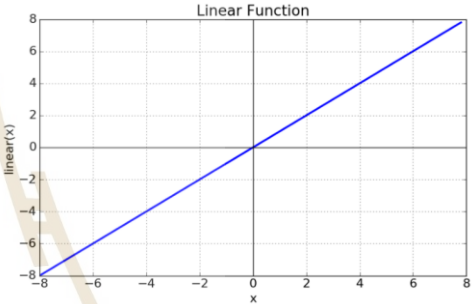
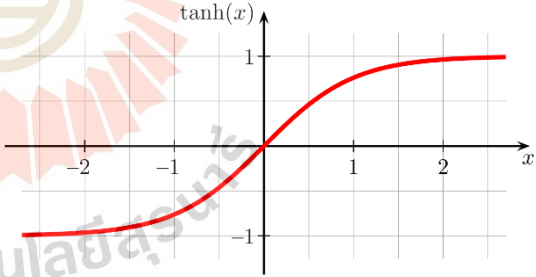
รูปที่ 2.4 ตัวอย่าง โครงข่ายประสาทเทียมหนึ่งหน่วยแบบหลายอินพุต  
ที่มา : [guopai.github.io/ml-blog14.html](http://guopai.github.io/ml-blog14.html)

ซึ่งฟังก์ชันที่ใช้ในการส่งผ่าน เพื่อหาเอาต์พุตนั้นเรียกว่า ฟังก์ชันถ่ายโอน (Activation Function) โดยเป็นฟังก์ชันที่รับผลรวมการประมวลผลทั้งหมดจากทุกอินพุตและเป็นตัวกำหนดค่าของผลลัพธ์ ซึ่งสามารถเป็นฟังก์ชันในทางคณิตศาสตร์ใดก็ได้ และสามารถเลือกฟังก์ชันได้ตามความเหมาะสม ซึ่งฟังก์ชันการถ่ายโอนมีหลายแบบด้วยกัน ดังแสดงในตารางที่ 2.1

ตารางที่ 2.1 ตัวอย่างฟังก์ชันถ่ายโอนและลักษณะกราฟของฟังก์ชันถ่ายโอนแบบต่าง ๆ

	ฟังก์ชัน	กราฟ
1	<p>Sigmoid Function โดยมีสมการดังนี้</p> $f(x) = \frac{1}{1 + e^{-x}}$	<p>The graph shows the Sigmoid function, also known as the logistic function. The curve is S-shaped, starting near 0 for negative values and approaching 1 for positive values. The equation <math>\sigma(z) = \frac{1}{1 + e^{-z}}</math> is displayed above the curve. The x-axis ranges from -10 to 10, and the y-axis ranges from 0.0 to 1.0.</p>

ตารางที่ 2.1 ตัวอย่างฟังก์ชันถ่ายโอนและลักษณะกราฟของฟังก์ชันถ่ายโอนแบบต่าง ๆ (ต่อ)


	ฟังก์ชัน	กราฟ
2	<p>Rectified Linear Unit Function (ReLU Function) โดยมีสมการดังนี้</p> $f(x) = \max(0, x) = \begin{cases} 0 & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases}$	
3	<p>Linear Function โดยมีสมการดังนี้</p> $f(x) = x$	
4	<p>Tanh or Hyperbolic Tangent Function โดยมีสมการดังนี้</p> $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	

### 2.2.7 เทคนิคการจำแนกข้อมูล (Classification)

เป็นหนึ่งในเทคนิคสำหรับการจำแนกประเภทของข้อมูล คือการจัดแบ่งข้อมูลให้อยู่ในประเภทที่กำหนดเป้าหมาย (Target) เป็นลักษณะของคำตอบ (Class) หรือลาเบล (Label) โดยจะทำการแบ่งชุดข้อมูล (Dataset) ออกเป็น 2 ชุด คือชุดข้อมูลสำหรับการฝึกฝน (Training Data) และชุดข้อมูลสำหรับการทดสอบ (Testing Data) โดยมีการแบ่งอัตราส่วนที่ 70 ต่อ 30 หรือ 80 ต่อ 20 ขึ้นอยู่กับความเหมาะสมของชุดข้อมูล จากนั้นนำชุดข้อมูลสำหรับการฝึกฝนป้อนเข้าโครงข่ายประสาทเทียม เพื่อให้โครงข่ายประสาทเทียมทำการเรียนรู้ การสร้างระบบหรือจำแนกข้อมูลในการ

เรียนรู้ว่าจะเลือกใช้เรนด้อมฟอร์เรสต์ (Random Forest : RF) จากนั้นทำการทดสอบระบบจำแนกข้อมูลโดยชุดข้อมูลสำหรับการทดสอบ ซึ่งเป็นชุดข้อมูลคนละชุดกับชุดข้อมูลสำหรับการฝึกฝน และในท้ายที่สุดทำการเปรียบเทียบผลลัพธ์ที่ได้ โดยในงานวิจัยนี้ได้เลือกใช้เทคนิคการจำแนกข้อมูลดังนี้

1. อัลกอริทึมการเรียนรู้แบบเพอร์เซปตรอน (Perceptron Learning Algorithm) เป็นส่วนสร้างของโครงข่ายประสาทเทียมซึ่งเป็นแบบจำลองที่เรียบง่ายของเซลล์ประสาททางชีววิทยาในสมอง เพอร์เซปตรอนเป็นโครงข่ายประสาทที่ง่ายที่สุดซึ่งประกอบด้วยเซลล์ประสาทเพียงเซลล์เดียว อัลกอริทึม เพอร์เซปตรอนถูกประดิษฐ์ขึ้นในปีพ. ศ. 2501 โดย Frank Rosenblatt โดยรูปที่ 2.5 เป็นภาพประกอบเพื่อแสดงการทำงานของเซลล์ประสาททางชีววิทยา



รูปที่ 2.5 การทำงานของเซลล์ประสาททางชีววิทยา

ที่มา : [ichi.pro/th/perceptron-kha-xthibay-karna-pi-chi-laea-tawxyang-phaph-66582574588625](http://ichi.pro/th/perceptron-kha-xthibay-karna-pi-chi-laea-tawxyang-phaph-66582574588625)

สัญญาณอินพุตส่วนใหญ่ไปยังเซลล์ประสาทได้รับผ่านเดนไดรต์ มีการเชื่อมต่อประมาณ 1,000 ถึง 10,000 ที่เกิดจากเซลล์ประสาทอื่น ๆ กับเดนไดรต์เหล่านี้ สัญญาณจากการเชื่อมต่อที่เรียกว่า synapses แพร่กระจายผ่านเดนไดรต์เข้าสู่ร่างกายของเซลล์ ศักยภาพในร่างกายเพิ่มขึ้นและเมื่อถึงเกณฑ์เซลล์ประสาทจะส่งเข็มไปตามแอกซอนที่เชื่อมต่อกับเซลล์ประสาทอื่น ๆ ประมาณ 100 เซลล์ผ่านขั้วแอกซอน

เพอร์เซปตรอนเป็นแบบจำลองที่เรียบง่ายของเซลล์ประสาทจริงที่พยายามเลียนแบบโดยกระบวนการต่อไปนี้จะรับสัญญาณอินพุตเรียกว่า  $x_1, x_2, \dots, x_n$  คำนวณผลรวม  $z$  ที่ถ่วงน้ำหนักของอินพุตเหล่านั้นแล้วส่งผ่าน ฟังก์ชัน threshold  $\phi$  และแสดงผลลัพธ์


$$Z = \sum_{i=1}^n x_i w_i \quad (2.7)$$

$$\phi(z) = \begin{cases} -1 & z \leq w_0 \\ 1 & z > w_0 \end{cases} \quad (2.8)$$

แต่การมี  $w_0$  เป็น Threshold ก็เหมือนกับการเพิ่ม  $w_0$  เข้าไปใน sum เป็น bias และมี threshold เป็น 0 แทนนั้นคือเราพิจารณาสัญญาณอินพุตเพิ่มเติม  $x_0$  ที่ตั้งค่าเป็น 1 เสมอ

$$Z = \sum_{i=0}^n x_i w_i \quad (2.9)$$

$$\phi(z) = \begin{cases} -1 & z \leq 0 \\ 1 & z > 0 \end{cases} \quad (2.10)$$



รูปที่ 2.6 แผนภาพไดอะแกรมของเพอร์เซปตรอน

ที่มา : [ichi.pro/th/perceptron-kha-xthibay-karna-pi-chi-laea-tawxyang-phaph-66582574588625](http://ichi.pro/th/perceptron-kha-xthibay-karna-pi-chi-laea-tawxyang-phaph-66582574588625)

จากรูปที่ 2.6 เป็นภาพแสดงการทำงานของเพอร์เซปตรอน ซึ่งการใช้สัญญาณเวกเตอร์เราสามารถใส่อินพุต  $x_0, x_1, \dots, x_n$  และน้ำหนักทั้งหมด  $w_0, w_1, \dots, w_n$  เป็นเวกเตอร์  $x$  และ  $w$  และเอาต์พุต 1 เมื่อผลิตภัณฑ์คอตเป็นบวกและ -1 เมื่อผลิตภัณฑ์คอตเป็นลบ

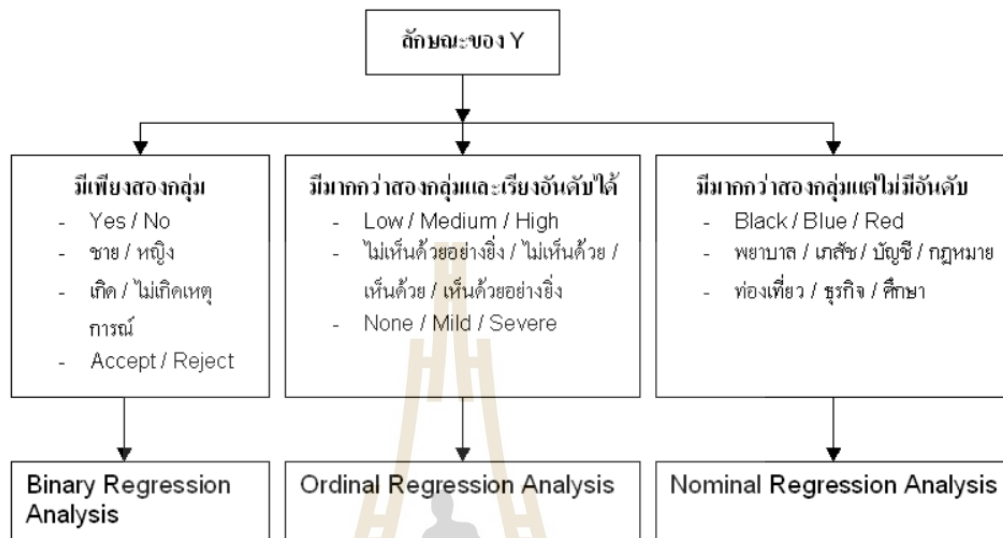
$$x = \begin{bmatrix} 1 \\ x_1 \\ \dots \\ x_n \end{bmatrix}; w = \begin{bmatrix} w_0 \\ w_1 \\ \dots \\ w_n \end{bmatrix} \quad (2.11)$$

$$z = x \cdot w \quad (2.12)$$

2. การถดถอยแบบโลจิสติก (Logistic Regression) ถูกนำมาใช้เพื่อทำนายว่า จะเกิดเหตุการณ์หนึ่งขึ้นหรือไม่หรือมี โอกาสเกิดขึ้นมากน้อยเพียงใด โดยมีการกำหนดค่าตัวแปรตัวหนึ่งหรือหลายตัวที่คาดว่าจะส่งผลต่อการเกิดเหตุการณ์นั้นๆ และในที่สุดก็จะทำให้เราเข้าใจสาเหตุการเกิดเหตุ การณ์นั้น ๆ ได้ในที่สุด



การแบ่งชนิดของการวิเคราะห์ จะใช้ลักษณะหรือธรรมชาติของตัวแปรตอบสนอง (Response) เป็นตัวกำหนด ดังแผนภาพต่อไปนี้



รูปที่ 2.7 การจำแนกชนิด Logistic Regression Analysis

ที่มา : [sites.google.com/site/mystatistics01/chapter7/logistic-regression](https://sites.google.com/site/mystatistics01/chapter7/logistic-regression)

ถึงแม้ตัวแปรตอบสนองจะเป็นแบบไม่ต่อเนื่อง แต่ Logistic Regression ก็ไม่กำหนดว่าตัวแปรอิสระจะต้องเป็นแบบไม่ต่อเนื่อง สามารถเป็นได้ทั้งแบบค่าต่อเนื่องที่วัดได้โดยเครื่องมือวัดและแบบไม่ต่อเนื่อง (Category) ก็ได้

$$g(x) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (2.13)$$


$g(x)$  จะถูกเรียกว่า Link function และ  $X_1, X_2, \dots, X_k$  จะเรียกว่า Predictors

กรณี  $X_1, X_2, \dots, X_k$  เป็นค่าแบบต่อเนื่อง เราเรียกว่า Covariates และหากเป็นตัวแปรแบบไม่ต่อเนื่องเราจะเรียกว่า Risk factors

เช่นเดียวกันกับการวิเคราะห์กรณีตัวแปรตอบสนองเป็นค่าต่อเนื่องในบทที่ 6 Logistic Regression ที่มีตัวแปรอิสระหรือ Predictor (X) เพียงหนึ่งตัว ก็จะเรียกว่า Simple logistic regression เช่น Simple binary logistic regression และ Simple nominal logistic regression เป็นต้น และถ้ามีตัวแปรอิสระ (Predictor) หลายตัว ก็จะเรียกว่า Multiple logistic regression แต่ทั้งนี้ทั้งนั้น

ขั้นตอนในการวิเคราะห์ของทั้งกรณีในตัวแปรตอบสนองเป็นค่าต่อเนื่องหรือเป็น Category ก็ยังมีขั้นตอนหลักๆในการวิเคราะห์ที่เหมือนกัน คือ (1.) วิเคราะห์ผ่านทางกราฟฟิก เช่น Scatter plot หรือ Fit line plot เพื่อให้สามารถมองภาพออก (2.) การวิเคราะห์ความคลาดเคลื่อนของ Model ที่ได้ ซึ่งเราจะใช้วิธี Least square method สำหรับกรณีที่ตัวแปรตอบสนองเป็น ค่าต่อเนื่อง และใช้วิธี Maximum likelihood estimation สำหรับกรณีที่ตัวแปรตอบสนองเป็นค่าต่อเนื่องหรือเป็น Category

3. ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) เป็นที่เทคนิคการเรียนรู้ที่มีลักษณะทำงานคล้ายกับ ANN (Artificial Neural Network) แต่มีลักษณะความเสี่ยงในเชิงโครงสร้างและการทดสอบที่น้อยกว่า โดยซัพพอร์ตเวกเตอร์แมชชีนสามารถทำงานได้ทั้งในลักษณะของแบบการถดถอย (Regression) และการจำแนกประเภท (Classification)



รูปที่ 2.8 การจำแนกประเภทข้อมูลแบบ Support Vector Machine (SVM)

ที่มา : [guopai.github.io/ml-blog08.html](http://guopai.github.io/ml-blog08.html)

จากรูปที่ 2.8 เป็นปัญหา Binary classification ต้องการจำแนกข้อมูลออกเป็นสองฝั่ง คือสีน้ำเงินและสีแดง สิ่งที่ SVM ทำ คือการหาเส้นแบ่งการตัดสินใจที่เป็นเส้นทึบ ซึ่งเส้นนี้จะเกิดขึ้นระหว่างกลางของเส้นประด้านซ้ายและขวา โดยมีเงื่อนไขว่าจะต้องหาจุดของเส้นประที่กว้างที่สุดเท่าที่จะเป็นไปได้

SVM ใช้ Hypothesis function แบบเส้นตรง เหมือนกับ Linear regression ดังนั้น

$$h_{\theta}(x) = w^T x + b \quad (2.14)$$

โดย  $w$  คือค่าน้ำหนัก  $x$  คือค่าคุณลักษณะเฉพาะ และ  $b$  คือ bias ซึ่งถ้าผลลัพธ์เป็นบวก จะทำนาย Class  $\hat{y}$  ว่าเป็น 1 ส่วนถ้าเป็นลบ ทำนายว่าเป็น 0 สามารถเขียนวิธีการตัดสินใจตามเงื่อนไขดังกล่าวได้ดังนี้

$$\hat{y} = \begin{cases} 0 & ; w^T x + b \\ 1 & ; w^T x + b \end{cases} \quad (2.15)$$

เมื่อนิยามเส้นแบ่งการตัดสินใจแล้ว (เส้นทึบ) จะทำการกำหนดเส้นประทั้งสองด้านของเส้นทึบ โดยเส้นประแต่ละด้านคือตำแหน่งที่  $h_{\theta}(x)$  เท่ากับ -1 และ 1

ต่อมาลองพิจารณาว่า ความชันของฟังก์ชันการตัดสินใจ เท่ากับ Norm ของ Vector ค่าน้ำหนัก

$$\frac{\partial}{\partial x} h_{\theta}(x) = \sum_{i=1}^m |w_i| = \|w\|_1 \quad (2.16)$$

จากข้อเท็จจริงนี้ ก็จะได้เป้าหมายว่าต้องการลด  $\|w\|$  เพื่อให้ได้ขอบเขตเส้นแบ่งที่กว้างที่สุดเท่าที่จะเป็นไปได้ อย่างไรก็ตามถ้าขอบเขตของเส้นแบ่งนั้นกว้างเกินไป จะทำให้ครอบคลุมข้อมูลที่ไม่ใช่เป้าหมายซึ่งมีผลต่อความผิดพลาดในการจำแนกข้อมูล ดังนั้นจึงเกิดฟังก์ชันการตัดสินใจที่มากกว่า 1 ยกตัวอย่าง เช่น กำหนดเป็นค่า  $t^{(i)} = 1$  สำหรับ  $\hat{y} = 1$  และ  $t^{(i)} = -1$  สำหรับ  $\hat{y} = 0$  ดังนั้นจะได้เป้าหมายสำหรับการจำแนกด้วย SVM ดังนี้

$$t^{(i)}(w^T x^{(i)} + b) \geq 1 \quad (2.17)$$

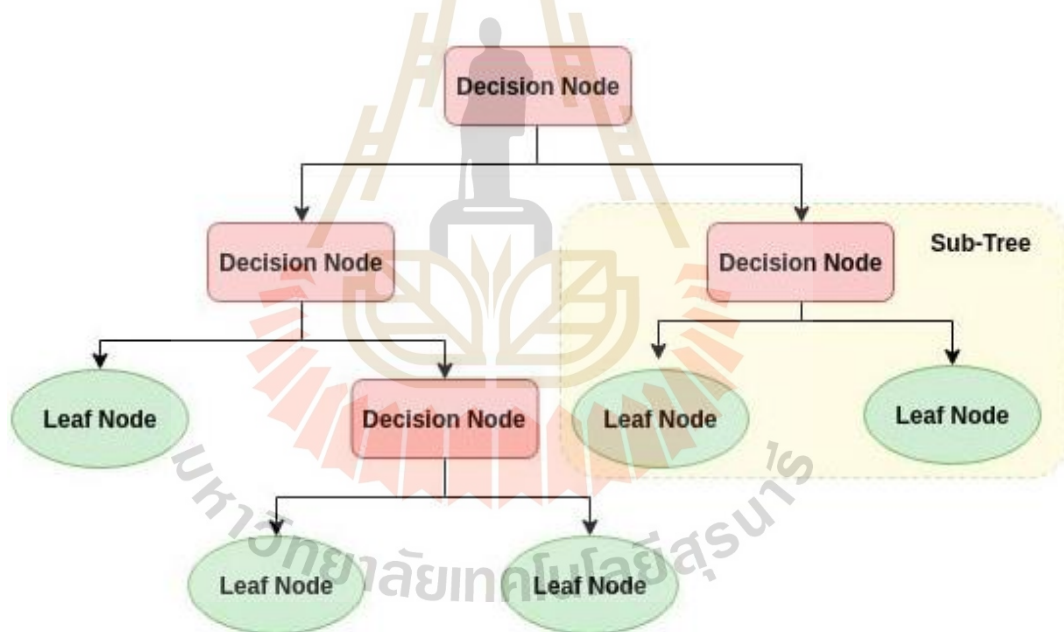
SVM algorithm ดังกล่าวเป็นเพียงขอบเขตการตัดสินใจแบบเส้นตรงเท่านั้น ดังนั้นถ้าหากในกรณีที่ชุดข้อมูลมีความซับซ้อนหรือไม่เป็นเชิงเส้น โดยสรุปผู้วิจัยเลือกใช้การจำแนกข้อมูลสองแบบที่เหมาะสมกับชุดข้อมูล ดังนี้

$$\text{Linear: } K(a,b) = a^T b \quad (2.18)$$

$$\text{Gaussian RBF: } K(a,b) = e^{(-\gamma\|a-b\|^2)} \quad (2.19)$$

4. การเรียนรู้แบบต้นไม้ตัดสินใจ (Decision Tree Learning) เป็นเทคนิคสำหรับการ Classification ชนิดหนึ่ง จัดอยู่ในเทคนิคจำพวก Supervised learning ใช้สำหรับจำแนกข้อมูลต่างๆ โดยข้อมูลจะมีทั้ง X และ Y ไว้สำหรับการสร้างโมเดล โดยค่า Y(Label class) จะเป็นตัวแปรประเภท Categorical

อัลกอริทึมการเรียนรู้แบบต้นไม้ตัดสินใจ มีแผนผังการทำงานที่รูปร่างเหมือนโครงสร้างต้นไม้ โดยกำหนดโหนดภายใน (Internal Node) เป็นค่าคุณลักษณะเฉพาะ (Feature) แต่ละกิ่ง (Branch) แทนด้วยขอบเขตการตัดสินใจ (Decision Rule) แต่ละโหนดเป้าหมาย (Leaf Node) แทนด้วยผลลัพธ์ (Outcomes) และสุดท้ายจุดบนสุดของการตัดสินใจของต้นไม้หรือเรียกว่าโหนดราก (Root Node)



รูปที่ 2.9 โครงสร้างของรูปแบบต้นไม้ตัดสินใจ

ที่มา : [medium.com/equinox-blog/decision-tree-101-scikit-learn-afed3bf414a2](https://medium.com/equinox-blog/decision-tree-101-scikit-learn-afed3bf414a2)

ในปัจจุบันนั้นมีการพัฒนาขั้นตอนวิธี (Algorithm) ในการสอน (Training) ต้นไม้ การตัดสินใจมากมาย ซึ่งส่วนมากมาจากวิธีพื้นฐานวิธีหนึ่งซึ่งเป็นการค้นหาแบบละโมภ (Greedy search) จากบนลงล่าง (Top-Down) ชื่อว่า ID3 ซึ่งถูกพัฒนาโดย John Ross Quinlan ในปี 1986

ID3 นั้นสร้างต้นไม้การตัดสินใจจากบนลงล่างด้วยการถามว่าลักษณะใด (ขอใช้คำว่าลักษณะแทนตัวแปรต้น) ควรจะเป็นรากของต้นไม้การตัดสินใจต้นนี้ และถามซ้ำๆ ไปเรื่อยๆ เพื่อหาต้นไม้ทั้งต้นด้วยการเขียนโปรแกรมด้วยความสัมพันธ์แบบเวียนเกิด (Recursion) โดยในการเลือกว่าลักษณะใดดีที่สุดนั้นดูจากค่าของลักษณะเรียกว่าเกนความรู้ (Information Gain) ก่อนที่จะรู้จักเกนความรู้จะต้องนิยามค่าหนึ่งที่ใช้บอกความไม่บริสุทธิ์ของข้อมูลก่อน เรียกว่าเอนโทรปี (Entropy) โดยนิยามเอนโทรปีของต้นไม้การตัดสินใจในตัวในเซตของตัวอย่าง  $S$  คือ  $E(S)$  ดังนี้

$$E(S) = - \sum_{j=1}^n p_s(j) \log_2 p_s(j) \quad (2.20)$$

เมื่อ  $S$  คือตัวอย่างที่ประกอบด้วยชุดของตัวแปรต้นและตัวแปรตามหลาย ๆ กรณี  $p_s(j)$  คืออัตราส่วนของกรณีใน  $S$  ที่ตัวแปรตามหรือผลลัพธ์มีค่า  $j$

โดยสำหรับต้นไม้การตัดสินใจที่มีผลลัพธ์เป็นแค่เพียงค่าตรรกะ (boolean) ใช่กับไม่ใช่เหมือนกับที่ยกมาตอนต้นของบทความนั้น จะมีเอนโทรปีคือ

$$E(S) = -p_{yes} \log_2(p_{yes}) - p_{no} \log_2(p_{no}) \quad (2.21)$$

เมื่อพิจารณาเอนโทรปีแล้วจะเห็นว่าเอนโทรปีจะมีค่าอยู่ระหว่าง 0 กับ 1 โดยจะมีค่าเป็นศูนย์เมื่อทุกๆกรณีมีผลลัพธ์เพียงแบบเดียว เช่น ใช่ทั้งหมด หรือ ไม่ใช่ทั้งหมด และจะมีค่ามากขึ้นเมื่อเริ่มมีค่าที่แตกต่างกันมากขึ้น หรือจะพูดอีกนัยหนึ่งก็คือเอนโทรปีจะมีค่ามากขึ้นหากข้อมูลไม่บริสุทธิ์ และจะตัดสินใจได้ว่าผลลัพธ์จะเป็นอะไรเมื่อเอนโทรปีเป็น 0 เท่านั้น

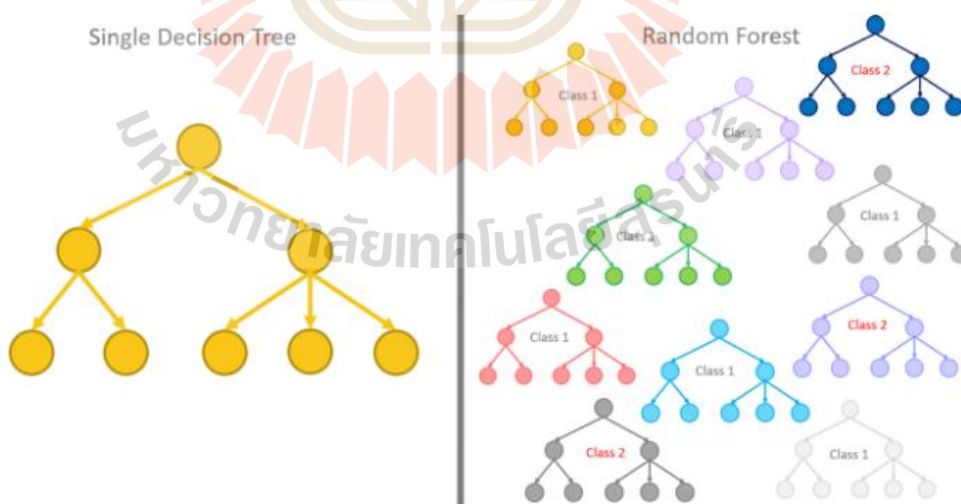
ซึ่งจากการนิยามเอนโทรปีข้างต้น ทำให้เราสามารถนิยามลักษณะของตัวแปรต้นที่ดีได้ โดยตัวแปร  $A$  จะเป็นตัวแปรต้นที่ดีก็ต่อเมื่อหากว่าแบ่งข้อมูลตัวอย่าง (Example) ออกเป็นชุดๆ มีจำนวนชุดตามจำนวนค่าของ  $A$  ที่เป็นไปได้เพื่อให้แต่ละกรณี (Instance) ในชุดนั้นมีค่า  $A$  เพียงค่าเดียวและค่าเฉลี่ยของเอนโทรปีของชุดข้อมูลที่ถูกแบ่งออก (partition) มานั้นต่ำที่สุด เรียกว่าคาดหวังของการลดลงของเอนโทรปีหลังจากข้อมูลถูกแบ่งด้วย  $A$  ว่าเกนความรู้ของ  $A$  นิยามโดย

$$Gain(S, A) = E(S) - \sum_{v= \text{value}(A)} \frac{|S_v|}{|S|} E(S_v) \tag{2.22}$$

เมื่อ  $S$  คือตัวอย่างที่ประกอบด้วยชุดของตัวแปรต้นและตัวแปรตามหลาย ๆ กรณี  $E$  คือเอนโทรปีของตัวอย่าง  $A$  คือตัวแปรต้นที่พิจารณา  $\text{value}(A)$  คือเซตของค่าของ  $A$  ที่เป็นไปได้  $S_v$  คือตัวอย่างที่  $A$  มีค่า  $v$  ทั้งหมด

จะเห็นว่าหากเอนโทรปีของ  $A$  ยิ่งมากแสดงว่าหลังจากแบ่งตัวอย่าง  $S$  ด้วย  $A$  แล้วในแต่ละชุดที่แบ่งได้จะมี Entropy เข้าใกล้ศูนย์มากยิ่งขึ้น ทำให้ใกล้ที่จะตัดสินใจได้มากขึ้น เอนโทรปีจึงเป็นค่าที่ดีที่จะบอกความดีของตัวแปรต้นที่นำมาพิจารณา

5. แรนด้อมฟอเรสต์ (Random Forest : RF) เป็นเทคนิคที่ถูกต่อยอดมาจากการเรียนรู้แบบต้นไม้ตัดสินใจ (Decision Tree Learning) ซึ่งมีหลักการโดยใช้เทคนิคการสุ่มเลือกค่าคุณลักษณะเฉพาะ ออกมาจากชุดข้อมูลหลาย ๆ ชุดข้อมูล จากนั้นนำเอาชุดข้อมูลเหล่านั้นมาจำลองเป็นเทคนิคต้นไม้ตัดสินใจหลาย ๆ ต้น (จากเดิม 2 ต้นอาจจะเป็น 4 ต้น เป็นต้น) โดยเทคนิคแรนด้อมฟอเรสต์ถูกนำเสนอครั้งแรกในปี ค.ศ. 1995 โดย Tin Kam ซึ่งต่อมาเทคนิคนี้ถูกต่อยอดโดย Leo Breiman โดยตามรูปที่ 2.10 จะเป็นตัวอย่างการแบ่งข้อมูลที่เปรียบเทียบกันระหว่างแบบ Decision Tree และ Random Forest



รูปที่ 2.10 ตัวอย่างการแบ่งข้อมูลที่เปรียบเทียบกันระหว่างแบบ Decision Tree และ Random Forest ที่มา : [towardsdatascience.com/from-a-single-decision-tree-to-a-random-forest-b9523be65147](https://towardsdatascience.com/from-a-single-decision-tree-to-a-random-forest-b9523be65147)

จากรูปที่ 2.10 จะเห็นได้ชัดเจนว่า Random Forest เป็นการเพิ่มจำนวนลำต้น (Tree) เป็นลำต้น หลาย ๆ ต้น ทำให้ประสิทธิภาพในการทำงานสูงขึ้น แม่นยำมากขึ้น ดังนั้นวิธีการของ Random Forest จึงมีวิธีการที่คล้ายคลึงกัน แต่จะมีเทคนิคที่เพิ่มเข้ามาเรียกว่า Bagging ซึ่งเป็นเทคนิคในการแบ่งข้อมูลออกเป็น Tree หลายๆ ต้นซึ่งส่วนนี้จะมีส่วนสำคัญในสำหรับอัลกอริทึมการฝึกฝนของ Random Forest ซึ่งมีวิธีการดังนี้


$$\hat{f} = \frac{1}{B} \sum_{b=1}^B f_b(x') \quad (2.23)$$

เมื่อ ชุดข้อมูลสำหรับการฝึกฝนคือ  $X = x_1, \dots, x_n$  และค่าการตอบสนองคือ  $Y = y_1, \dots, y_n$  ซึ่งจะทำการฝึกฝนตามการ Bagging หรือตามจำนวนลำต้นที่ถูกแบ่ง คือ  $B$  แสดงจะมีจำนวนทั้งหมดคือ  $b = 1, \dots, B$  ดังนั้นตัวอย่างชุดข้อมูลสำหรับการฝึกฝนจะแทนเป็น  $X_b, Y_b$  ฟังก์ชันสำหรับการเรียนรู้ของลำต้นในการจำแนกประเภทชุดข้อมูลหรือการถดถอยแทนเป็น และท้ายที่สุดหลังจากการฝึกฝน การทำนายสำหรับตัวอย่างที่มองไม่เห็น ( $x'$ ) สามารถทำได้โดยการหาค่าเฉลี่ยของการคาดการณ์จากต้นไม้การถดถอยแต่ละต้นบน  $x'$

นอกจากนี้การประมาณค่าความไม่แน่นอนของการทำนายสามารถทำได้เป็นค่าเบี่ยงเบนมาตรฐานของการคาดการณ์จากต้นไม้การถดถอยแต่ละต้นบน  $x'$

$$\sigma = \sqrt{\frac{\sum_{b=1}^B (f_b(x') - \hat{f})^2}{B-1}} \quad (2.24)$$

6. การหาเพื่อนบ้านที่ใกล้ที่สุด (K - Nearest Neighbor : KNN) เป็นวิธีการแบ่งคลาสสำหรับใช้จัดหมวดหมู่ข้อมูล (Classification) ใช้หลักการเปรียบเทียบข้อมูลที่สนใจกับข้อมูลอื่นว่ามีความคล้ายคลึงมากน้อยเพียงใด หากข้อมูลที่กำลังสนใจนั้นอยู่ใกล้ข้อมูลใดมากที่สุด ระบบจะให้คำตอบเป็นเหมือนคำตอบของข้อมูลที่อยู่ใกล้ที่สุดนั้นลักษณะการทำงานแบบไม่ได้ใช้ข้อมูลชุดเรียนรู้ (Training data) ในการสร้างแบบจำลองแต่จะใช้ข้อมูลนี้มาเป็นตัวแบบจำลองเลย



รูปที่ 2.11 ตัวอย่างการจำแนกชุดข้อมูลด้วยเทคนิค K-NN

ที่มา : kongruksiamza.medium.com

ในเทคนิคจำเป็นอย่างยิ่งสำหรับการกำหนดค่าตัวเลขจำนวนเพื่อนบ้านหรือค่า K ซึ่งค่านี้เป็นค่าจำนวนเต็มบวกที่ระบุคือกรณีหรือเหตุการณ์ (Case) ที่ต้องการค้นหาในการทำนายกรณีใหม่ ได้แก่ 1-NN, 2-NN, ..., K-NN ซึ่งสมการที่อธิบายได้ดีที่สุดถึงการทำงานของ K-NN คือ

$$dist = \sqrt{\sum_{k=1}^n (p_k - q_k)^2} \quad (2.25)$$

เมื่อ  $dist$  คือค่าระยะห่างระหว่างจุด 2 จุด เพื่อวัดความคล้ายคลึงของชุดข้อมูล

### 2.2.8 การประเมินประสิทธิภาพสำหรับโครงข่ายประสาทเทียม

มาตรวัดประสิทธิภาพที่เกี่ยวข้องกับ โครงข่ายประสาทเทียม เพื่อใช้ในการวิเคราะห์ความแม่นยำมีดังนี้

1. ตารางวัดความถูกต้องหรือเมทริกซ์คอนฟิวชัน (Confusion Matrix) คือตารางที่แสดงผลลัพธ์ในการวัดที่ได้จากการฝึกฝนหรือการจำแนกข้อมูล โดยเทียบระหว่างผลลัพธ์จริงและผลลัพธ์ในการทำนาย ดังรูปที่ 2. แสดงเมทริกซ์ขนาด  $2 \times 2$  ซึ่งเป็นผลลัพธ์ที่จำแนกข้อมูล 2 คลาส คือคลาสบวก (Positive Class) และคลาสลบ (Negative Class)



		PREDICTIVE VALUES	
		POSITIVE (1)	NEGATIVE (0)
ACTUAL VALUES	POSITIVE (1)	TP	FN
	NEGATIVE (0)	FP	TN

รูปที่ 2.12 ตัวอย่างเมทริกซ์คอนฟิวชัน (Confusion Matrix)

จากรูปที่ 2.12 ค่าที่ได้จากเมทริกซ์วัดประสิทธิภาพในกรณีที่มีข้อมูล 2 คลาส สามารถแบ่งออกเป็น 4 กรณีได้ดังนี้

True Positive (TP) คือ ผลที่ทำนายว่าจริงแล้วตรงกับผลลัพธ์ที่เกิดขึ้นจริง

True Negative (TN) คือ ผลที่ทำนายว่าไม่จริงแล้วตรงกับผลลัพธ์ที่เกิดขึ้นไม่จริง

False Positive (FP) คือ ผลที่ทำนายว่า ไม่จริงแต่ผลลัพธ์ที่เกิดขึ้นจริง

False Negative (FN) คือ ผลที่ทำนายว่าจริงแต่ผลลัพธ์ที่เกิดขึ้นไม่จริง

2. ค่าความถูกต้อง (Accuracy) คือค่าความแม่นยำในการจำแนกข้อมูลว่าถูกต้องอยู่ในระดับใด ซึ่งสามารถคำนวณได้ดังสมการที่ 2.26

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.26)$$

3. ค่าความแม่นยำ (Precision) คือค่าที่วัดความแม่นยำของข้อมูล โดยพิจารณาแยกทีละคลาส ซึ่งสามารถคำนวณได้ดังสมการที่ 2.27

$$Precision = \frac{TP}{TP + FP} \quad (2.27)$$

4. ค่ารู้จำ (Recall) คือค่าที่โมเดลทำนายได้ว่าจริงเป็นอัตราส่วนเท่าไรของจริงทั้งหมด ซึ่งสามารถคำนวณได้ดังสมการที่ 2.28

$$Recall = \frac{TP}{TP + FN} \quad (2.28)$$

## 2.3 อุปกรณ์ที่เกี่ยวข้อง

### 2.3.1 150-1500 mA Buck Regulator LED Driver for 1-50W High power LED

อุปกรณ์ชิ้นนี้เป็นตัวแปลง DC / DC ทั้งแบบกระแสคงที่และแบบ step-down มีการล๊อคเอาต์แรงดันไฟฟ้า (UVLO) การรักษาอุณหภูมิ การป้องกันการเปิดวงจร (Open circuit) ของ LED และการป้องกันการลัดวงจร (Short circuit) ของ LED และไดรเวอร์ของอุปกรณ์นี้ซึ่งมีขนาดเล็ก มีประสิทธิภาพสูง มีเสถียรภาพ มีอายุการใช้งานที่ยาวนานและติดตั้งง่าย การปรับค่าแสง LED สามารถควบคุมด้วยการมอดูเลตแบบความกว้างของพัลส์ (Pulse Width Modulation - PWM) ผ่านพิน EN



รูปที่ 2.13 150-1500 mA Buck Regulator LED Driver for 1-50W High power LED

Pin	Description
VIN	Positive terminal for 10V -45V DC Power supply
GND	Power Ground
LED+	Positive of LED terminal
LED-	Negative of LED terminal
EN	PWM terminal. When applied with ground or suspended, full amount of current will be output and when connected with +5v or VIN, output current will be 0.

รูปที่ 2.14 รายละเอียดของ 150-1500 mA Buck Regulator LED Driver for 1-50W High power LED

### 2.3.2 Logitech C310 HD Webcam

Logitech C310 HD Webcam เป็นกล้องที่ส่งสัญญาณภาพผ่านทางคอมพิวเตอร์ สำหรับใช้งานผ่านทางเว็ลด์ไวด์เว็บ ทางเมสเซนเจอร์หรือทางซอฟต์แวร์อื่น ๆ ขึ้นอยู่กับการนำไปประยุกต์การใช้งาน



รูปที่ 2.15 Logitech C310 HD Webcam

### คุณสมบัติของ Logitech C310 HD Webcam

1. การสนทนาผ่านวิดีโอ HD (1280 X 720 พิกเซล) ด้วยระบบที่แนะนำ
2. การจับภาพวิดีโอ HD: สูงสุด 1280 X 720 พิกเซล
3. เทคโนโลยี Logitech Fluid Crystal™
4. ภาพถ่าย: สูงสุด 5 ล้านพิกเซล (ปรับปรุงด้วยซอฟต์แวร์)

### 2.3.3 เซนเซอร์ควอนตัม เอ็มคิว – 200 (MQ – 200 Quantum Sensor)

MQ – 200 เป็นเซนเซอร์เครื่องมือวัดขนาดเล็กที่สามารถพกพาได้ โดยต่อผ่านสายเคเบิลและหน้าจอแสดงค่าที่วัดได้ หัวเซนเซอร์มีการออกแบบรูปโดมที่มีวัสดุคลุมอยู่ทำให้กันน้ำได้อย่างเต็มที่ ทนต่อสามารถแวดล้อมที่ไม่ปกติทั้งเวลาที่มีฝนและแดด และสามารถถอดออกทำความสะอาดได้ การใช้งานทั่วไปสามารถวัดได้ในสภาพแวดล้อมกลางแจ้ง เรือนกระจก และห้องเพาะเลี้ยงอนุบาลพืช ที่ยี่ห้อเซ็นเซอร์ควอนตัมยังใช้ในการวัด PAR/PPFD ในสภาพแวดล้อมทางน้ำรวมถึงตู้ปลาน้ำเค็มที่มีการปลูกปะการัง



รูปที่ 2.16 MQ-200 Quantum Sensor

### 2.3.4 Nvidia Jetson Nano Developer Kit

Nvidia Jetson Nano Developer Kit คือชุดสำหรับพัฒนาปัญญาประดิษฐ์ (AI) และ Machine Learning โดย Jetson Nano เปรียบเสมือนเครื่องคอมพิวเตอร์ขนาดเล็กที่มีพลังการประมวลผลมหาศาลผ่าน GPU ของค่าย Nvidia สามารถรัน neural networks ได้หลายๆ ตัวพร้อมกัน หากใครต้องการทำงานประเภท image classification, object detection, speech processing สามารถทำได้บน Jetson Nano




รูปที่ 2.17 Nvidia Jetson Nano Developer Kit

### 2.3.5 16 Channel 12-bit PWM Servo Driver PCA9685

Module PCA9685 ขับ Servo 16 ช่อง ความละเอียด 12 bit แบบ PWM Servo การติดต่อสื่อสารแบบ I2C Interface ใช้ IC เบอร์ PCA9685 ในการควบคุม สามารถขับ Servo ได้สูงสุดถึง 16 ตัว ด้วยการเชื่อมต่อ ด้วย 2 สาย I2C และยังสามารถใช้ Module ตัวนี้ได้หลายตัวโดยการอ้างอิงด้วยวิธีการ I2C อ้างอิง Address รองรับ Address ในช่วงระหว่าง 0x40 - 0x70

รายละเอียดเพิ่มเติม

- Module นี้ใช้ IC เบอร์ PCA9685
- รองรับแหล่งจ่ายไฟ Power supply : 2.3V ถึง 5.5V
- การเชื่อมต่อแบบ I2C Interface SAL SCL
- สามารถทำงานได้ในช่วง อุณหภูมิ -40 ถึง 85 องศา
- ขนาดของบอร์ด (62.5mm x 25.4mm x 3 mm)
- น้ำหนักประมาณ 5 กรัม



รูปที่ 2.18 PCA9685 16-Channel 12 - bit PWM Servo shield I2C interface

### 2.3.6 เครื่องวัดคลอโรฟิลล์ รุ่น SPAD – 502 Plus

เครื่องวัดคลอโรฟิลล์ SPAD-502Plus สามารถตรวจวัดปริมาณคลอโรฟิลล์ของใบได้อย่างรวดเร็วโดยไม่ทำลายใบพืชหรือตัวอย่าง เนื่องจากใบไม้ได้ถูกตัดออกเพียงแค่วางใบบนหัววัดแล้วปิดทำให้สามารถวัดใบเดิมได้ตลอดการเติบโตของพืช เครื่องมีน้ำหนักเบา สามารถใช้กับถ่าน AA ได้ทำให้เหมาะกับงานภาคสนาม



รูปที่ 2.19 เครื่องวัดคลอโรฟิลล์ รุ่น SPAD – 502 Plus

## 2.4 ปรัชญ์นัรรมกรรมและงานวิจัยที่เกี่ยวข้อง

ตารางที่ 2.2 งานวิจัยที่เกี่ยวข้องและกล่าวถึง

ปีที่ตีพิมพ์	ชื่อผู้แต่ง	ชื่อบทความ	รายละเอียดเบื้องต้น
1993	Martin Fodslette Møller	A Scaled Conjugate Gradient Algorithm For Fast Supervised Learning	นำเสนออัลกอริทึมการเรียนรู้แบบ ผู้ช่วยสอน วิธีการและประสิทธิภาพ ที่ชื่อ Scaled Conjugate Gradient
1995	Corinna Cortes and Vladimir Vapnik	Support-vector networks	นำเสนอวิธีการแบบใหม่สำหรับ ปัญหาการจำแนกสองกลุ่ม แสดง ประสิทธิภาพ และวิธีการเรียนรู้ของ เครื่องวิธีการนี้
1995	Paul L. Rosin and Freddy Fierens	Improving neural network generalization.	นำเสนอปัญหาของการเกิด Overfitting ในเครือข่ายประสาท เทียม และเสนอวิธีการเพิ่มพูน ประสิทธิภาพเครือข่ายประสาท เทียม
1999	Yoav Freund and Llew Mason	The alternating decision tree learning algorithm	นำเสนอการประยุกต์ใช้ด้วยวิธีการ อัลกอริทึมแบ่งฟังก์ชันตัดสินใจ (Decision tree algorithm) ถึง ประสิทธิภาพ การใช้งาน และ วิธีการต่าง ๆ
1999	Stanley J. Reeves and Zhao Zhe	Sequential algorithms for observation selection	นำเสนอการพัฒนาวิธีการ Sequential algorithms สำหรับการ เลือกการสังเกตและวิเคราะห์ ประสิทธิภาพทั้งในเชิงการคำนวณ และในแง่ของ SSE

ตารางที่ 2.2 งานวิจัยที่เกี่ยวข้องและกล่าวถึง (ต่อ)

ปีที่ตีพิมพ์	ชื่อผู้แต่ง	ชื่อบทความ	รายละเอียดเบื้องต้น
2001	Leo Breiman	Random forests	นำเสนอวิธีการที่มีประสิทธิภาพในการทำนายรวมถึงวิเคราะห์วิธีการนี้
2010	Wes McKinney	Data structures for statistical computing in python	นำเสนอเครื่องมือชนิดหนึ่งที่ชื่อ Pandas ในแพลตฟอร์ม Python ที่ใช้กับชุดข้อมูลทั่วไปสำหรับการเงิน สถิติ และสาขาอื่น ๆ ที่เกี่ยวข้อง เพื่อให้ง่ายต่อการจัดการข้อมูล เหล่านี้และเพื่อจัดเตรียมข้อมูล สำหรับการ ใช้แบบจำลองทางสถิติ
2011	Fabian Pedregosa, Et al.	Scikit-learn: Machine learning in Python	นำเสนออัลกอริทึมการเรียนรู้ของ เครื่องที่หลากหลายทั้งแบบการ เรียนรู้แบบผู้ช่วยสอนและการ เรียนรู้แบบ ไม่มีผู้ช่วยสอน
2011	Abdul Kaleem, Khawaja M. Ghorı, Zahra Khanzada and M. Noman Malik	Address Standardization using Supervised Machine Learning	นำเสนอแบบจำลองความน่าจะเป็น Hidden Markov Model (HMM) เพื่อแบ่งกลุ่มชุดข้อมูลของที่อยู่ใน เอเชียเป็นหน่วยอะตอม และใช้ Viterbi algorithm เพื่อหาความเป็นไปได้ที่สุดในส่วนการทดสอบหาที่อยู่
2013	Margit Olle and Akvile Viršile	The effects of light-emitting diode lighting on greenhouse plant growth and quality	นำเสนอเทคโนโลยี ไดโอดเปล่งแสง (LED) สำหรับ แสงพืชเรือนกระจกและเพื่อให้ ภาพรวมเกี่ยวกับผลกระทบของแสง LED ที่มีต่อดัชนีการสังเคราะห์แสง การเจริญเติบโตต่อพืชผล



ตารางที่ 2.2 งานวิจัยที่เกี่ยวข้องและกล่าวถึง (ต่อ)

ปีที่ตีพิมพ์	ชื่อผู้แต่ง	ชื่อบทความ	รายละเอียดเบื้องต้น
2017	Jwo-Huei Jou, Hui-Huan Yu, Fu Ching Tung, Cheng-I. Chiang, Zhe-Kai He and Mao-Kuo Wei	A replacement for incandescent bulbs: high-efficiency blue- hazard free organic light-emitting diodes	นำเสนอการศึกษาเกี่ยวกับ ไดโอดเปล่งแสงอินทรีซ์รูปแบบ หลอดไส้ที่มีประสิทธิภาพสูง ซึ่ง เกิดจากการใช้วัสดุที่มีประสิทธิภาพ สูงและมีความคล่องตัวสูง สถาปัตยกรรมอุปกรณ์ที่มี ประสิทธิภาพและเทคนิคการสกัด ด้วยแสง
2018	Partha Pratim Banik, Rappy Saha, Tae-Ho Kwon, and Ki-Doo Kim	LED Color Detection of Visual-MIMO System Using Boosting Neural Network Algorithm	นำเสนอการส่งเสริมเครือข่าย ประสาทเทียม (Boosting Neural Network) อัลกอริทึมการเรียนรู้เพื่อ ทำนายสีของสัญลักษณ์
2018	Celina Gómez and Luigi Gennaro Izzo	Increasing efficiency of crop production with LEDs	นำเสนอการพัฒนาเทคโนโลยี แอลอีดี (Light Emitting Diode) เพื่อ เพิ่มประสิทธิภาพในการผลิตพืช

## 2.5 สรุป

ทฤษฎีความรู้พื้นฐาน หลักการที่เกี่ยวข้อง รวมทั้งปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้องได้นำเสนอเนื้อหาในบทที่ 2 เป็นหลักการทฤษฎีความรู้พื้นฐานของอุปกรณ์ที่เรามาใช้ทำงานในระบบคือ ไดโอดเปล่งแสง (Light Emitting Diode) ความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density) และปัญญาประดิษฐ์ (Artificial Intelligence) ต่อมาได้นำเสนออุปกรณ์สำคัญที่เกี่ยวข้องและใช้ในระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ และท้ายที่สุดในบทนี้ได้กล่าวถึงปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

## บทที่ 3

### วิธีการดำเนินงานวิจัยส่วนที่ 1

#### การจำลองเหตุการณ์สำหรับการตรวจจับระดับความเข้มแสงแอลอีดี

##### 3.1 บทนำ

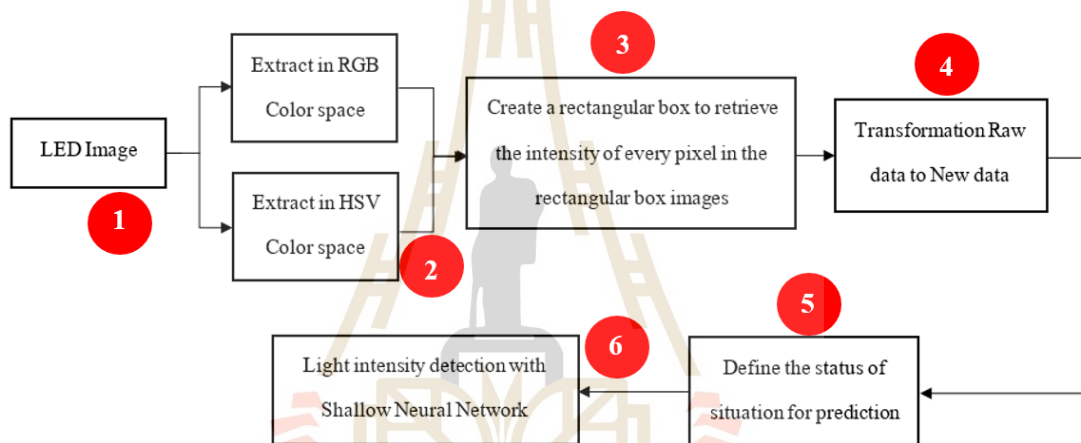
สำหรับการศึกษาระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียน โดยใช้เทคนิคปัญญาประดิษฐ์ ผู้วิจัยนำอุปกรณ์แสงแอลอีดีมาเก็บข้อมูล โดยที่เป็นอุปกรณ์ที่ถูกออกแบบและนำเสนออย่างละเอียดในบทที่ 4 ซึ่งเป็นวิธีการดำเนินงานวิจัยในส่วนของฮาร์ดแวร์ ดังนั้นในบทนี้ จะไม่ได้มุ่งเน้นในรายละเอียดการสร้างอุปกรณ์แสงแอลอีดี แต่มุ่งเน้นในการนำเสนอรายละเอียดสำหรับการเตรียมชุดข้อมูลที่ได้จากการสกัดค่าคุณลักษณะเฉพาะ และการออกแบบเหตุการณ์เพื่อจำลองสถานการณ์และกำหนดเป้าหมายของเหตุการณ์จำลอง เพื่อให้โครงข่ายประสาทเทียมสามารถสะดวกต่อการเรียนรู้ในด้านการฝึกฝน มีประสิทธิภาพ ถูกต้องแม่นยำให้มากที่สุด และให้สามารถประมวลผลได้รวดเร็วในการทำนายความเข้มแสงแอลอีดี

ในการดำเนินงานวิจัยในส่วนที่ 1 จะนำเสนอการดำเนินงานวิจัยและผลการดำเนินงานวิจัยระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียน โดยใช้เทคโนโลยีปัญญาประดิษฐ์ ซึ่งเป็นการจำลองเหตุการณ์สำหรับการตรวจจับระดับความเข้มแสงแอลอีดี โดยในงานวิจัยนี้ได้ใช้โปรแกรม Visual Studio Code 2019 สำหรับการออกแบบการเก็บข้อมูลเพื่อสกัดค่าลักษณะที่เหมาะสมสำหรับการจำลองเหตุการณ์ เพื่อพร้อมสำหรับการนำไปใช้งานจริง และง่ายต่อการวางแผน ออกแบบ พัฒนา วิธีการและความสะดวกในการวิเคราะห์ข้อมูล ซึ่งโมเดลที่ใช้สำหรับฝึกฝนและทดสอบ ผู้วิจัยเลือกใช้สถาปัตยกรรมโครงข่ายประสาทเทียมทั้งหมดเจ็ด โมเดลจากไลบรารี Scikit – learn ได้แก่ 1. Perceptron Learning Model 2. Logistic Regression Model 3. Support Vector Machine with Linear Kernel Model 4. Support Vector Machine with Radial Basis Function Kernel Model 5. Decision Tree Model 6. Random Forest Model และ 7. K-Nearest Neighbors Model

ดังนั้น ผู้วิจัยจะนำเสนอโดยแบ่งออกเป็น 3 ส่วนหลัก ๆ โดยอันดับแรก การออกแบบระบบตรวจจับความเข้มแสงแอลอีดีอัจฉริยะในโรงเรียนผ่านเหตุการณ์จำลอง อันดับสองการเตรียมข้อมูลในการฝึกฝนและทดสอบกับโครงข่ายประสาทเทียม และส่วนสุดท้ายคือการทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมในการทำนายความเข้มแสงแอลอีดี

### 3.2 การออกแบบระบบตรวจจับความเข้มแสงแอลอีดีอัจฉริยะในโรงเรียน ผ่านเหตุการณ์จำลอง

ในหัวข้อนี้นำเสนอการออกแบบระบบตรวจจับความเข้มแสงแอลอีดีอัจฉริยะในโรงเรียนผ่านเหตุการณ์จำลอง โดยออกแบบเหตุการณ์การเก็บข้อมูลเพื่อสกัดคุณลักษณะเฉพาะและการออกแบบเหตุการณ์ของเป้าหมายเพื่อนำข้อมูลที่ได้นี้ ไปวิเคราะห์และพัฒนาต่อด้านฮาร์ดแวร์ของระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียน โดยการทำงานของระบบทั้งหมดมีรายละเอียดดังนี้



รูปที่ 3.1 บล็อกไดอะแกรมสำหรับกระบวนการที่ถูกออกแบบ

จากรูปที่ 3.1 แสดงบล็อกไดอะแกรมวิธีการที่นำเสนอจะถูกแบ่งออกเป็น 6 ขั้นตอน ได้แก่

(1) จำลองเหตุการณ์ต่าง ๆ ด้วยแสงแอลอีดีสีแดงและสีน้ำเงิน ผู้วิจัยทำการถ่ายภาพแอลอีดีจากการจำลองโดยใช้กล้อง Logitech C310 HD Webcam

(2) นำรูปภาพที่ได้มาสกัดค่าคุณลักษณะเฉพาะในทั้งปริภูมิสี RGB และ HSV โดยใช้เครื่องมืออัลกอริทึมการประมวลผลภาพใน Visual Studio Code 2019 ซึ่งทั้งปริภูมิสี RGB และ HSV ผู้วิจัยจะนำทั้งสองปริภูมินี้มาเปรียบเทียบกันในด้านของการสกัดคุณลักษณะเด่น ว่าปริภูมิสีทั้งสองแบบนี้ แบบใดสามารถให้ผลลัพธ์ในแง่ของประสิทธิภาพแก่โครงข่ายประสาทเทียมของการฝึกฝนและทำนายได้อย่างถูกต้องแม่นยำมากที่สุด

(3) ผู้วิจัยทำการกำหนดและสร้างกล่องสี่เหลี่ยมเพื่อแยกภาพย่อยทั้งในปริภูมิสี RGB และ HSV ออกจากภาพปริภูมิสี RGB และ HSV ดั้งเดิม ต่อมาเมื่อทำการสกัดข้อมูลจากภาพที่กำหนด

ขอบเขตด้วยกรอบสี่เหลี่ยมเรียบร้อยแล้ว จากนั้นจึงเพิ่มชุดข้อมูลที่สำคัญอย่างหน่วยมาตรฐาน สำหรับการวัดระดับความแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density) ด้วยเครื่องมือวัดเซนเซอร์แยกควอนตัมเอ็มคิว-200 (MQ-200 quantum separate sensor) ผู้วิจัยทำการคำนวณค่าเฉลี่ยของข้อมูลภาพจากการสแกนลักษณะเฉพาะ

(4) ทำการแปลงข้อมูลจากข้อมูลดิบเป็นข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis : PCA) และเก็บไว้เป็นข้อมูลแบบอาร์เรย์

(5) ผู้วิจัยใช้อัลกอริทึมการไล่ระดับสีคอนจูเกตแบบปรับขนาด เพื่อฝึกฝนการเรียนรู้ความเข้มของสีจากแสงแอลอีดี

(6) ท้ายที่สุดจำแนกรูปแบบโดยเป็นการทำนายหรือตรวจจับความเข้มแสงแอลอีดีด้วยชุดเครื่องมือโครงข่ายประสาท (Neural Network) จากชุดเครื่องมือใน Visual Studio Code 2019

โดยก่อนที่จะลงลึกถึงรายละเอียดระบบต่าง ๆ ที่ถูกออกแบบ ผู้วิจัยจะนำเสนอถึงแนวคิดการออกแบบเหตุการณ์จำลองการตรวจจับระดับความเข้มแสงแอลอีดี ผู้วิจัยใช้ชุดข้อมูล 40 ชุดข้อมูล ผู้วิจัยออกแบบเหตุการณ์ทั้งหมด 40 เหตุการณ์ที่คงระดับความเข้มของสีน้ำเงินไว้ที่ 0%, 25%, 50%, 75% และ 100% และคงระดับความเข้มของสีแดงไว้ที่ 0%, 25%, 50%, 75% และ 100% ตามลำดับ จากนั้นในแต่ละเหตุการณ์ที่ยกมาทั้งหมด 40 เหตุการณ์ ผู้วิจัยจะรักษาระดับความเข้มของแสงสีน้ำเงินและเพิ่มความระดับเข้มของสีแดง โดยจะเพิ่มสีแดงขึ้น 25% => 50% => 75% => 100% ตามลำดับ ในกรณีที่รักษาระดับความเข้มของสีแดงผู้วิจัยจะเพิ่มขึ้นในลักษณะเดียวกัน เริ่มแรกผู้วิจัยสนใจหนึ่งเหตุการณ์ที่มีแสงแอลอีดีสีดวง ซึ่งหมายความว่าในหนึ่งภาพแอลอีดีมีทั้งหมดแปดดวง ประกอบไปด้วยแสงแอลอีดีสีดวงสี่ดวงและแสงแอลอีดีสีน้ำเงินสี่ดวง ตัวอย่างเช่นเหตุการณ์ที่คงระดับความเข้มของสีน้ำเงินไว้ที่ 25% แล้วเพิ่มสีแดงขึ้น 25% แสดงว่าผู้วิจัยจะสนใจแสงแอลอีดีสีดวงสี่ดวงหรือเหตุการณ์ที่รักษาความเข้มของสีแดงเป็น 50% และเพิ่มสีน้ำเงินขึ้น 75% แสดงว่าผู้วิจัยสนใจแสงแอลอีดีสีน้ำเงินสี่ดวง ท้ายที่สุดผู้วิจัยต้องการหรือออกแบบเป้าหมายของข้อมูลโดยกำหนดเป็น 8 กลุ่มเป้าหมายคือ ความเข้มสีแดง 25%, 50%, 75%, 100% และความเข้มสีน้ำเงิน 25%, 50%, 75%, 100% เป็นกลุ่มที่ 1, 2, 3, 4, 5, 6, 7 และ 8 ตามลำดับ

โดยสรุปแล้วผู้วิจัยรวบรวมภาพแอลอีดี หนึ่งภาพต่อหนึ่งเหตุการณ์ โดยมีทั้งหมด 40 เหตุการณ์จำลอง ซึ่งท้ายที่สุดจะได้ชุดข้อมูลที่ออกแบบไว้คือ

$$(1 \text{ ภาพ} = 4 \text{ ภาพ LED}) / 4 \times 1 \text{ ภาพต่อหนึ่งเหตุการณ์} \times 40 \text{ เหตุการณ์} = 40 \text{ ชุดข้อมูล}$$

เพื่อให้ง่ายยิ่งขึ้นต่อการอธิบายและทำความเข้าใจในแนวความคิดของผู้วิจัย ผู้วิจัยจึงทำการอธิบายในรูปแบบของตารางที่ 3.1

ตารางที่ 3.1 การออกแบบเหตุการณ์จำลองทั้งหมด 40 เหตุการณ์ สำหรับโครงข่ายประสาทเทียม

ลำดับเหตุการณ์	เหตุการณ์ระดับความเข้มแสงแอลอีดี		กลุ่มเป้าหมาย
1	สีน้ำเงิน 0%	สีแดง 25%	1
2		สีแดง 50%	2
3		สีแดง 75%	3
4		สีแดง 100%	4
5	สีน้ำเงิน 25%	สีแดง 25%	1
6		สีแดง 50%	2
7		สีแดง 75%	3
8		สีแดง 100%	4
9	สีน้ำเงิน 50%	สีแดง 25%	1
10		สีแดง 50%	2
11		สีแดง 75%	3
12		สีแดง 100%	4
13	สีน้ำเงิน 75%	สีแดง 25%	1
14		สีแดง 50%	2
15		สีแดง 75%	3
16		สีแดง 100%	4
17	สีน้ำเงิน 100%	สีแดง 25%	1
18		สีแดง 50%	2
19		สีแดง 75%	3
20		สีแดง 100%	4
21	สีแดง 0%	สีน้ำเงิน 25%	5
22		สีน้ำเงิน 50%	6
23		สีน้ำเงิน 75%	7
24		สีน้ำเงิน 100%	8
25	สีแดง 25%	สีน้ำเงิน 25%	5
26		สีน้ำเงิน 50%	6
27		สีน้ำเงิน 75%	7
28		สีน้ำเงิน 100%	8

ตารางที่ 3.1 การออกแบบเหตุการณ์จำลองทั้งหมด 40 เหตุการณ์  
สำหรับโครงข่ายประสาทเทียม (ต่อ)

ลำดับเหตุการณ์	เหตุการณ์ระดับความเข้มแสงแอลอีดี	กลุ่มเป้าหมาย
29	สีแดง 50%	สีน้ำเงิน 25%
30		สีน้ำเงิน 50%
31		สีน้ำเงิน 75%
32		สีน้ำเงิน 100%
33	สีแดง 75%	สีน้ำเงิน 25%
34		สีน้ำเงิน 50%
35		สีน้ำเงิน 75%
36		สีน้ำเงิน 100%
37	สีแดง 100%	สีน้ำเงิน 25%
38		สีน้ำเงิน 50%
39		สีน้ำเงิน 75%
40		สีน้ำเงิน 100%


ในหัวข้อถัดไปจะเป็นนำเสนอถึงรายละเอียดต่าง ๆ เพิ่มขึ้น เพื่อให้มองเห็นภาพรวมได้  
อย่างภาพชัดเจนยิ่งขึ้นถึงระบบที่ผู้วิจัยออกแบบไว้ ซึ่งจะอยู่ในส่วนหัวข้อที่ 3.3 การเตรียมข้อมูลใน  
การฝึกฝนและทดสอบกับ โครงข่ายประสาทเทียม และ 3.4 การทดสอบประสิทธิภาพการทำงานของ  
ของโครงข่ายประสาทเทียมในการทำนายความเข้มแสงแอลอีดี

### 3.3 การเตรียมข้อมูลในการฝึกฝนและทดสอบกับโครงข่ายประสาทเทียม

ในหัวข้อนี้จะอธิบายถึงรายละเอียดของการเตรียมชุดข้อมูลในการฝึกฝนกับทดสอบโดย  
แบ่งการเตรียมชุดข้อมูลหลัก ๆ ออกเป็น 2 ปริภูมิสี RGB และ ปริภูมิสี HSV เพื่อเปรียบเทียบถึงค่า  
คุณลักษณะเฉพาะแบบใดมีประสิทธิภาพ มีความเหมาะสมและสามารถนำไปใช้งานได้จริง โดยจะ  
เริ่มต้นจากใช้ภาพจากการบันทึกภาพด้วยกล้อง Logitech C310 HD Webcam เป็นภาพที่ได้จากการ  
ควบคุมระดับความเข้มแสงแอลอีดี ซึ่งจะเป็นการยกตัวอย่าง การจำลองเหตุการณ์จาก 1 ใน 40  
เหตุการณ์ที่ออกแบบไว้ คือเหตุการณ์จำลองในการควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่  
100% และแสงแอลอีดีสีน้ำเงินที่ 100% ซึ่งการเตรียมข้อมูลในการฝึกฝนและทดสอบกับโครงข่าย  
ประสาทเทียม จะประกอบไปด้วยหลักการทำงานหลัก ๆ 2 ส่วน ประกอบไปด้วย ส่วนที่หนึ่งเป็น

กระบวนการเก็บข้อมูลโดยภาพรวมกระบวนการเก็บข้อมูลมีรายละเอียดตามหัวข้อย่อยที่ 3.3.1 คือกระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี RGB และ 3.3.2 คือกระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี HSV ถัดมาในส่วนที่สองเป็นการแปลงจากข้อมูลดิบ (Raw data) และข้อมูลใหม่ (New data) ด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) โดยภาพรวมกระบวนการแปลงข้อมูลมีรายละเอียดตามหัวข้อย่อยที่ 3.3.3 คือกระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB และ 3.3.4 คือกระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV

### 3.3.1 กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี RGB



รูปที่ 3.2 กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี RGB

จากรูปที่ 3.2 เป็นภาพแสงแอลอีดีในปริภูมิสีดั้งเดิมของภาพคือปริภูมิสี RGB ซึ่งจะประกอบไปด้วยภาพย่อยทั้งหมด 4 ภาพ ได้แก่

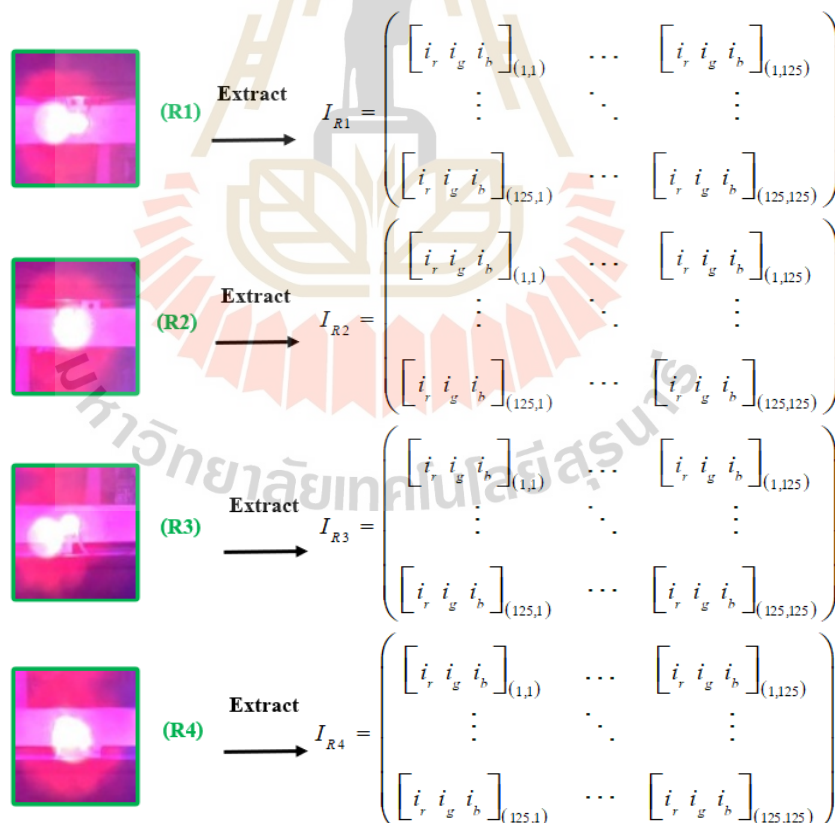
ภาพย่อยหมายเลข (1) คือภาพแสงแอลอีดีที่บันทึกภาพจากกล้อง Logitech C310 HD Webcam ณ จากภาพย่อยจะเป็นการยกตัวอย่างการจำลองเหตุการณ์ การควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสงแอลอีดีสีน้ำเงินที่ 100% เช่นเดียวกัน

ภาพย่อยหมายเลข (2) คือภาพแสงแอลอีดีที่ถูกกำหนดขอบเขตด้วยกล่องสี่เหลี่ยม ซึ่งจะประกอบไปด้วยกล่องสี่เหลี่ยมสีเขียว R1, R2, R3, R4 ที่เป็นกล่องสี่เหลี่ยมสำหรับเตรียมทำการสกัดค่าคุณลักษณะเฉพาะของแสงแอลอีดีสีแดง และ กล่องสี่เหลี่ยมสีเขียว B1, B2, B3, B4 ที่เป็นกล่องสี่เหลี่ยมสำหรับเตรียมทำการสกัดค่าคุณลักษณะเฉพาะของแสงแอลอีดีสีน้ำเงิน โดยหลักการพิจารณาถึงขอบเขตของกล่องสี่เหลี่ยมจะพิจารณาจากบริเวณของแสงสว่างทั้งแสงแอลอีดีสีแดงและแสงแอลอีดีสีน้ำเงิน โดยใช้กล่องสี่เหลี่ยมกำหนดขอบเขตตามแสงสว่างให้มาก

ที่สุดและต้องไม่มากจนขอบเขตไปทับกับขอบเขตกล่องสี่เหลี่ยมของแสงแอลอีดีที่อยู่บริเวณรอบข้าง

ภาพย่อยหมายเลข (3) คือภาพแสงแอลอีดีย่อยที่ถูกแยกออกมาจากภาพดั้งเดิมจากหมายเลข (2) ที่ทำการกำหนดขอบเขตกล่องสี่เหลี่ยม โดยหมายเลข (3) จะทำการแยกภาพแสงแอลอีดีย่อยสีแดงทั้งหมด 4 ดวงของภาพแสงแอลอีดีสีแดงดั้งเดิม คือ R1 คือแสงแอลอีดีสีแดงดวงที่ 1, R2 คือแสงแอลอีดีสีแดงดวงที่ 2, R3 คือแสงแอลอีดีสีแดงดวงที่ 3 และ R4 คือแสงแอลอีดีสีแดงดวงที่ 4 จากนั้นทั้งหมด 4 ดวงแสงแอลอีดีจะถูกทำการสกัดค่าคุณลักษณะเฉพาะ

ภาพย่อยหมายเลข (4) คือภาพแสงแอลอีดีย่อยที่ถูกแยกออกมาจากภาพดั้งเดิมจากหมายเลข (2) ที่ทำการกำหนดขอบเขตกล่องสี่เหลี่ยม โดยหมายเลข (4) จะทำการแยกภาพแสงแอลอีดีย่อยสีน้ำเงินทั้งหมด 4 ดวงของแสงแอลอีดีสีน้ำเงินดั้งเดิม คือ B1 คือแสงแอลอีดีสีน้ำเงินดวงที่ 1, B2 คือแสงแอลอีดีสีน้ำเงินดวงที่ 2, B3 คือแสงแอลอีดีสีน้ำเงินดวงที่ 3 และ B4 คือแสงแอลอีดีสีน้ำเงินดวงที่ 4 จากนั้นทั้งหมด 4 ดวงแสงแอลอีดีจะถูกทำการสกัดค่าคุณลักษณะเฉพาะ



รูปที่ 3.3 กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี RGB จากภาพย่อยแอลอีดีสีแดง ทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด 125×125 พิกเซล



จากรูปที่ 3.3 เป็นกระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี RGB จากภาพย่อยแอสลอีดีสีแดงทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด  $125 \times 125$  พิกเซล ผู้วิจัยได้พยายามนำภาพย่อยเหล่านี้มาสกัดค่าคุณลักษณะเฉพาะด้วยวิธีการที่ออกแบบขึ้น ผู้วิจัยจะเลือกค่าคุณลักษณะเฉพาะของภาพย่อยเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ ของภาพย่อยที่มีปริภูมิย่อยสี RGB ที่ประกอบไปด้วย

$r$  คือ ปริภูมิย่อยสีแดง (Red) ของปริภูมิสี RGB

$g$  คือ ปริภูมิย่อยสีเขียว (Green) ของปริภูมิสี RGB

$b$  คือ ปริภูมิย่อยสีน้ำเงิน (Blue) ของปริภูมิสี RGB

ด้วยขอบเขตของกล่องสี่เหลี่ยมที่กำหนดไว้ที่  $125 \times 125$  พิกเซล ซึ่งหมายความว่ากล่องสี่เหลี่ยมที่กำหนดไว้มีขนาดกว้างและยาวเท่ากันที่ 125 พิกเซล ทำให้ได้ข้อมูลเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ จำนวนทั้งหมด 15,625 ชุดข้อมูล จากนั้นเมื่อได้ชุดข้อมูลจากการสกัดค่าคุณลักษณะเฉพาะเรียบร้อยแล้ว และท้ายที่สุดผู้วิจัยจะทำการเฉลี่ยชุดข้อมูลทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอสลอีดีสีแดง ซึ่งผู้วิจัยสามารถนำเสนอเพื่อสามารถให้รายละเอียดเพิ่มเติมสมการดังต่อไปนี้

$$I_{R1} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \dots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \dots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.1)$$

จากสมการ (3.1) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพย่อยแสงแอสลอีดีสีแดงดวงที่หนึ่ง

$$I_{R2} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \dots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \dots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.2)$$

จากสมการ (3.2) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพย่อยแสงแอสลอีดีสีแดงดวงที่สอง

$$I_{R3} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \cdots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \cdots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.3)$$

จากสมการ (3.3) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูล ที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีแดงดวงที่สาม

$$I_{R4} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \cdots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \cdots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.4)$$

จากสมการ (3.4) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูล ที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีแสดดวงที่สี่

จากสมการที่ (3.1), (3.2), (3.3) และ (3.4) จะประกอบด้วยตัวแปรต่าง ๆ ดังนี้

$i_r$  คือ ค่าสีแดงที่อยู่ในช่วง  $[0,255]$  ซึ่งมีจำนวน 256 ระดับในปริภูมิย่อยสีแดง

$i_g$  คือ ค่าสีเขียวที่อยู่ในช่วง  $[0,255]$  ซึ่งมีจำนวน 256 ระดับในปริภูมิย่อยสีเขียว

$i_b$  คือ ค่าสีน้ำเงินที่อยู่ในช่วง  $[0,255]$  ซึ่งมีจำนวน 256 ระดับในปริภูมิย่อยสีน้ำเงิน

จากนั้นทำการเฉลี่ยชุดข้อมูลทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสง แอลอีดีสีแสด โดยเป็นไปตามดังสมการที่ 3.5, 3.6, 3.7 และ 3.8

$$I_{R1} = [\text{Average}(i_r) \ \text{Average}(i_g) \ \text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.5)$$

$$I_{R2} = [\text{Average}(i_r) \ \text{Average}(i_g) \ \text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.6)$$

$$I_{R3} = [\text{Average}(i_r) \ \text{Average}(i_g) \ \text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.7)$$

$$I_{R4} = [\text{Average}(i_r) \ \text{Average}(i_g) \ \text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \ \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.8)$$

จากสมการที่ 3.5, 3.6, 3.7 และ 3.8 เมื่อทำการเฉลี่ยชุดข้อมูลที่อยู่ในปริภูมิสี RGB ทั้งหมดที่เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอลอีดีสีแดงเรียบร้อยแล้ว ผู้วิจัยจะทำการเพิ่มข้อมูลที่สำคัญอย่างหน่วยมาตรฐานสำหรับการวัดระดับความเข้มแสง โดยความหนาแน่นของโฟตอน ฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density) ด้วยเครื่องมือวัดเซนเซอร์แยกควอนตัมเอ็มคิว-200 (MQ-200 quantum separate sensor) โดยเป็นไปตามดังสมการที่ 3.9, 3.10, 3.11 และ 3.12

$$I_{R1} = [ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPF} ] \quad (3.9)$$

$$I_{R2} = [ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPF} ] \quad (3.10)$$

$$I_{R3} = [ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPF} ] \quad (3.11)$$

$$I_{R4} = [ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPF} ] \quad (3.12)$$

จากสมการที่ 3.9, 3.10, 3.11 และ 3.12 จะเป็นชุดข้อมูลดิบขาเข้าที่เกิดจากขดตัวอย่างการจำลองเหตุการณ์การควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสงแอลอีดีสีน้ำเงินที่ 100% โดยเป็นการพิจารณาความแสงแอลอีดีสีแดงเป็นเป้าหมายหลัก ซึ่งตรงกับกลุ่มเป้าหมายที่ออกแบบไว้คือ กลุ่มเป้าหมายที่ 4 และท้ายที่สุดสมการข้างต้นที่กล่าวขึ้นจะประกอบด้วยตัวแปรต่าง ๆ ดังนี้

$I_{R1}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีแดงดวงที่หนึ่ง

$I_{R2}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีแดงดวงที่สอง

$I_{R3}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีแดงดวงที่สาม


$I_{R4}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีแดงดวงที่สี่

$\text{Average}(i_r)$  คือ ค่าเฉลี่ยในปริภูมิย่อยสีแดงของปริภูมิสี RGB

$\text{Average}(i_g)$  คือ ค่าเฉลี่ยในปริภูมิย่อยสีเขียวของปริภูมิสี RGB

$\text{Average}(i_b)$  คือ ค่าเฉลี่ยในปริภูมิย่อยสีน้ำเงินของปริภูมิสี RGB

PPFD คือ ค่าที่วัดได้จากเครื่องมือวัดระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density : PPFD)



รูปที่ 3.4 กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี RGB จากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด 125×125 พิกเซล

จากรูปที่ 3.4 เป็นกระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี RGB จากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด 125×125 พิกเซล ผู้วิจัยได้พยายามนำภาพย่อยเหล่านี้มาสกัดค่าคุณลักษณะเฉพาะด้วยวิธีการที่ออกแบบขึ้น ผู้วิจัยจะเลือกค่าคุณลักษณะเฉพาะของภาพย่อยเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ ของภาพย่อยที่มีปริภูมิย่อยสี RGB ที่ประกอบไปด้วย

$r$  คือปริภูมิย่อยสีแดง (Red) ของปริภูมิสี RGB

$g$  คือปริภูมิย่อยสีเขียว (Green) ของปริภูมิสี RGB

$b$  คือปริภูมิย่อยสีน้ำเงิน (Blue) ของปริภูมิสี RGB

ด้วยขอบเขตของกล่องสี่เหลี่ยมที่กำหนดไว้ที่ 125 x 125 พิกเซล ซึ่งหมายความว่ากล่องสี่เหลี่ยมที่กำหนดไว้มีขนาดกว้างและยาวเท่ากันที่ 125 พิกเซล ทำให้ได้ข้อมูลเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ จำนวนทั้งหมด 15,625 ชุดข้อมูล จากนั้นเมื่อได้ชุดข้อมูลจากการสกัดค่าคุณลักษณะเฉพาะเรียบร้อยแล้ว และท้ายที่สุดผู้วิจัยจะทำการเฉลี่ยชุดข้อมูลทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอลอีดีสีน้ำเงิน ซึ่งผู้วิจัยสามารถนำเสนอเพื่อสามารถให้รายละเอียดเพิ่มเติมสมการดังต่อไปนี้

$$I_{B1} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \cdots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \cdots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.13)$$

จากสมการ (3.13) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพถ่ายแสงแอลอีดีสีน้ำเงินดวงที่หนึ่ง

$$I_{B2} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \cdots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \cdots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.14)$$

จากสมการ (3.14) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพถ่ายแสงแอลอีดีสีน้ำเงินดวงที่สอง

$$I_{B3} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \cdots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \cdots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.15)$$

จากสมการ (3.15) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพถ่ายแสงแอลอีดีสีน้ำเงินดวงที่สาม

$$I_{B4} = \begin{pmatrix} [i_r \ i_g \ i_b]_{(1,1)} & \cdots & [i_r \ i_g \ i_b]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_r \ i_g \ i_b]_{(125,1)} & \cdots & [i_r \ i_g \ i_b]_{(125,125)} \end{pmatrix} \quad (3.16)$$

จากสมการ (3.16) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุด ข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี RGB จากภาพถ่ายแสงแอลอีดีสีน้ำเงินดวงที่สี่ จากสมการที่ (3.13), (3.14), (3.15) และ (3.16) จะประกอบด้วยตัวแปรต่าง ๆ ดังนี้  
 $i_r$  คือค่าสีแดงที่อยู่ในช่วง [0,255] ซึ่งมีจำนวน 256 ระดับในปริภูมิย่อยสีแดง  
 $i_g$  คือค่าสีเขียวที่อยู่ในช่วง [0,255] ซึ่งมีจำนวน 256 ระดับในปริภูมิย่อยสีเขียว  
 $i_b$  คือค่าสีน้ำเงินที่อยู่ในช่วง [0,255] ซึ่งมีจำนวน 256 ระดับในปริภูมิย่อยสีน้ำเงิน  
จากนั้นทำการเฉลี่ยชุดข้อมูลทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสง แอลอีดีสีน้ำเงิน โดยเป็นไปตามดังสมการที่ 3.17, 3.18, 3.19 และ 3.20

$$I_{B1} = [\text{Average}(i_r)\text{Average}(i_g)\text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.17)$$

$$I_{B2} = [\text{Average}(i_r)\text{Average}(i_g)\text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.18)$$

$$I_{B3} = [\text{Average}(i_r)\text{Average}(i_g)\text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.19)$$

$$I_{B4} = [\text{Average}(i_r)\text{Average}(i_g)\text{Average}(i_b)] = \left[ \sum_{n=1}^{15,625} \frac{(i_r)_n}{N} \sum_{n=1}^{15,625} \frac{(i_g)_n}{N} \sum_{n=1}^{15,625} \frac{(i_b)_n}{N} \right] \quad (3.20)$$

จากสมการที่ 3.17, 3.18, 3.19 และ 3.20 เมื่อทำการเฉลี่ยชุดข้อมูลที่อยู่ในปริภูมิสี RGB ทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอลอีดีสีน้ำเงินเรียบร้อยแล้ว ผู้วิจัยจะทำการเพิ่มข้อมูลที่สำคัญอย่างหน่วยมาตรฐานสำหรับการวัดระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density) ด้วยเครื่องมือวัดเซนเซอร์แยกควอนตัมเอ็มคิว-200 (MQ-200 quantum separate sensor) โดยเป็นไปตามดังสมการที่ 3.21, 3.22, 3.23 และ 3.24

$$I_{B1} = \left[ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPFDF} \right] \quad (3.21)$$

$$I_{B2} = \left[ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPFDF} \right] \quad (3.22)$$

$$I_{B3} = \left[ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPFDF} \right] \quad (3.23)$$

$$I_{B4} = \left[ \text{Average}(i_r) \text{ Average}(i_g) \text{ Average}(i_b) \text{ PPFDF} \right] \quad (3.24)$$

จากสมการที่ 3.21, 3.22, 3.23 และ 3.24 จะเป็นชุดข้อมูลดิบขาเข้าที่เกิดจากยกตัวอย่างการจำลองเหตุการณ์การควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสงแอลอีดีสีน้ำเงินที่ 100% โดยเป็นการพิจารณาความเข้มแสงแอลอีดีสีน้ำเงินเป็นเป้าหมายหลัก ซึ่งตรงกับกลุ่มเป้าหมายที่ออกแบบไว้คือ กลุ่มเป้าหมายที่ 8 และทำที่ชุดสมการข้างต้นที่กล่าวขึ้นจะประกอบด้วยตัวแปรต่าง ๆ ดังนี้

$I_{B1}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่หนึ่ง

$I_{B2}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สอง

$I_{B3}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สาม

$I_{B4}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี RGB จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สี่


$\text{Average}(i_r)$  คือ ค่าเฉลี่ยในปริภูมิย่อยสีแดงของปริภูมิสี RGB

$\text{Average}(i_g)$  คือ ค่าเฉลี่ยในปริภูมิย่อยสีเขียวของปริภูมิสี RGB

$\text{Average}(i_b)$  คือ ค่าเฉลี่ยในปริภูมิย่อยสีน้ำเงินของปริภูมิสี RGB

PPFD คือ ค่าที่วัดได้จากเครื่องมือวัดระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density : PPFDF)

### 3.3.2 กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี HSV



รูปที่ 3.5 กระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบในปริภูมิสี HSV

จากรูปที่ 3.5 เป็นภาพแสงแอลอีดีที่ทำการแปลงปริภูมิสีจากดั้งเดิมคือปริภูมิสี RGB เป็นปริภูมิสี HSV ซึ่งจะประกอบไปด้วยภาพย่อยทั้งหมด 4 ภาพ ได้แก่

ภาพย่อยหมายเลข (5) คือภาพแสงแอลอีดีที่บันทึกภาพจากกล้อง Logitech C310 HD Webcam ณ จากภาพย่อยจะเป็นการยกตัวอย่างการจำลองเหตุการณ์ การควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสงแอลอีดีสีน้ำเงินที่ 100% เช่นเดียวกัน

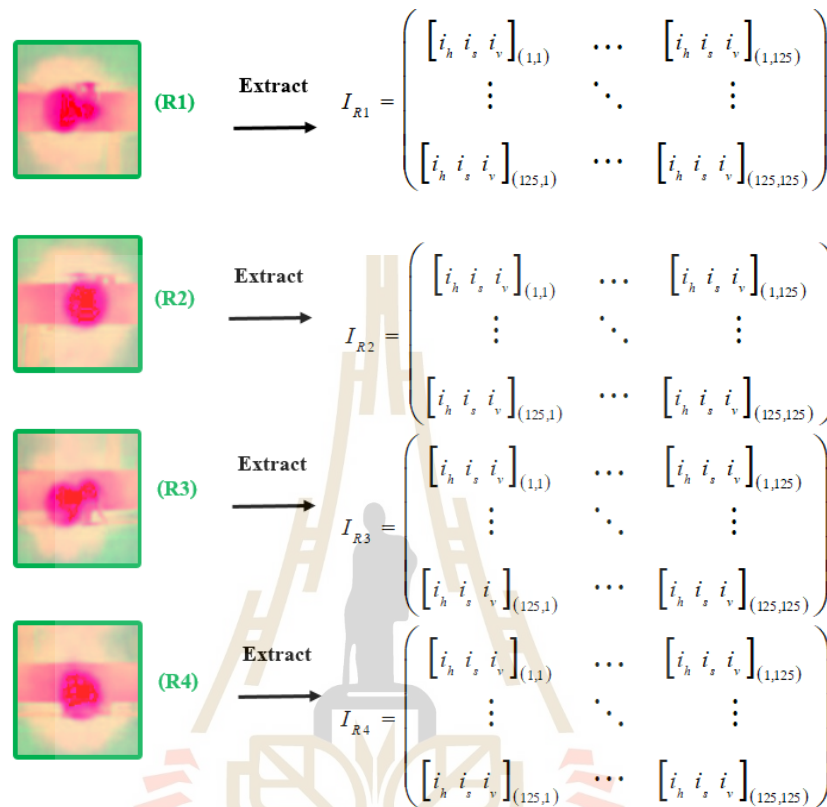
ภาพย่อยหมายเลข (6) คือภาพแสงแอลอีดีที่ถูกกำหนดขอบเขตด้วยกล่องสี่เหลี่ยม ซึ่งจะประกอบไปด้วยกล่องสี่เหลี่ยมสีเขียว R1, R2, R3, R4 ที่เป็นกล่องสี่เหลี่ยมสำหรับเตรียมทำการสกัดค่าคุณลักษณะเฉพาะของแสงแอลอีดีสีแดง และ กล่องสี่เหลี่ยมสีเขียว B1, B2, B3, B4 ที่เป็นกล่องสี่เหลี่ยมสำหรับเตรียมทำการสกัดค่าคุณลักษณะเฉพาะของแสงแอลอีดีสีน้ำเงิน โดยหลักการพิจารณาถึงขอบเขตของกล่องสี่เหลี่ยมจะพิจารณาจากบริเวณของแสงสว่างทั้งแสงแอลอีดีสีแดงและแสงแอลอีดีสีน้ำเงินโดยใช้กล่องสี่เหลี่ยมกำหนดขอบเขตตามแสงสว่างให้มากที่สุดและต้องไม่มากจนขอบเขตไปทับกับขอบเขตกล่องสี่เหลี่ยมของแสงแอลอีดีที่อยู่บริเวณรอบข้าง

ภาพย่อยหมายเลข (7) คือภาพแสงแอลอีดีย่อยที่ถูกแยกออกมาจากภาพดั้งเดิมจากหมายเลข (2) ที่ทำการกำหนดขอบเขตกล่องสี่เหลี่ยม โดยหมายเลข (3) จะทำการแยกภาพแสงแอลอีดีย่อยสีแดงทั้งหมด 4 ดวงของภาพแสงแอลอีดีสีแดงดั้งเดิม คือ R1 คือแสงแอลอีดีสีแดงดวงที่ 1, R2 คือแสงแอลอีดีสีแดงดวงที่ 2, R3 คือแสงแอลอีดีสีแดงดวงที่ 3 และ R4 คือแสงแอลอีดีสีแดงดวงที่ 4 จากนั้นทั้งหมด 4 ดวงแสงแอลอีดีจะถูกทำการสกัดค่าคุณลักษณะเฉพาะ

ภาพย่อยหมายเลข (8) คือภาพแสงแอลอีดีย่อยที่ถูกแยกออกมาจากภาพดั้งเดิมจากหมายเลข (2) ที่ทำการกำหนดขอบเขตกล่องสี่เหลี่ยม โดยหมายเลข (4) จะทำการแยกภาพแสงแอลอีดีย่อยสีน้ำเงินทั้งหมด 4 ดวงของแสงแอลอีดีสีน้ำเงินดั้งเดิม คือ B1 คือแสงแอลอีดีสีน้ำเงิน



ดวงที่ 1, B2 คือแสงแอลอีดีสีน้ำเงินดวงที่ 2 , B3 คือแสงแอลอีดีสีน้ำเงินดวงที่ 3 และ B4 คือแสงแอลอีดีดวงสีน้ำเงินที่ 4 จากนั้นทั้งหมด 4 ดวงแสงแอลอีดีจะถูกทำการสกัดค่าคุณลักษณะเฉพาะ



รูปที่ 3.6 กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี HSV จากภาพย่อยแอลอีดีสีแดง ทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด  $125 \times 125$  พิกเซล

จากรูปที่ เป็น 3.6 กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี HSV จากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด  $125 \times 125$  พิกเซล ผู้วิจัยได้พยายามนำภาพย่อยเหล่านี้มาสกัดค่าคุณลักษณะเฉพาะด้วยวิธีการที่ออกแบบขึ้น ผู้วิจัยจะเลือกค่าคุณลักษณะเฉพาะของภาพย่อยเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ ของภาพย่อยที่มีปริภูมิย่อยสี HSV ที่ประกอบไปด้วย

$h$  คือปริภูมิย่อย Hue ของปริภูมิสี HSV

$s$  คือปริภูมิย่อย Saturation ของปริภูมิสี HSV

$v$  คือปริภูมิย่อยสีน้ำเงิน Value ของปริภูมิสี HSV

ด้วยขอบเขตของกล่องสี่เหลี่ยมที่กำหนดไว้ที่ 125 x 125 พิกเซล ซึ่งหมายความว่ากล่องสี่เหลี่ยมที่กำหนดไว้มีขนาดกว้างและยาวเท่ากันที่ 125 พิกเซล ทำให้ได้ชุดข้อมูลเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ จำนวนทั้งหมด 15,625 ชุดข้อมูล จากนั้นเมื่อได้ชุดข้อมูลจากการสกัดค่าคุณลักษณะเฉพาะเรียบร้อยแล้ว และท้ายที่สุดผู้วิจัยจะทำการเฉลี่ยชุดข้อมูลทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอลอีดีสีแดง ซึ่งผู้วิจัยสามารถนำเสนอเพื่อสามารถให้รายละเอียดเพิ่มเติมสมการดังต่อไปนี้

$$I_{R1} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.25)$$

จากสมการ (3.25) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีแดงดวงที่หนึ่ง

$$I_{R2} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.26)$$

จากสมการ (3.26) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีแดงดวงที่สอง

$$I_{R3} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.27)$$

จากสมการ (3.27) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุดข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีแดงดวงที่สาม

$$I_{R4} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.28)$$

จากสมการ (3.28) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุด ข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีแดงดวงที่สี่

จากสมการที่ (3.25), (3.26), (3.27) และ (3.28) จะประกอบด้วยตัวแปรต่าง ๆ ดังนี้

$i_h$  คือ ค่าเฉลี่ยที่อยู่ในช่วง  $[0,360]$  ซึ่งอยู่ในรูปแบบขององศาในปริภูมิย่อย

Hue

$i_s$  คือ ค่าความบริสุทธิ์ของสีที่อยู่ในช่วง  $[0,255]$  ซึ่งมีจำนวน 256 ระดับ

ในปริภูมิย่อย Saturation

$i_v$  คือ ค่าความสว่างของสีที่อยู่ในช่วง  $[0,255]$  ซึ่งมีจำนวน 256 ระดับ

ในปริภูมิย่อย Value

จากนั้นทำการเฉลี่ยชุดข้อมูลทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสง แอลอีดีสีแดง โดยเป็นไปตามดังสมการที่ 3.29, 3.30, 3.31 และ 3.32

$$I_{R1} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.29)$$

$$I_{R2} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.30)$$

$$I_{R3} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.31)$$

$$I_{R4} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.32)$$

จากสมการที่ 3.29, 3.30, 3.31 และ 3.32 เมื่อทำการเฉลี่ยชุดข้อมูลที่อยู่ในปริภูมิสี HSV ทั้งหมดให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอลอีดีสีแดงเรียบร้อยแล้ว ผู้วิจัยจะทำการเพิ่มข้อมูลที่สำคัญอย่างหน่วยมาตรฐานสำหรับการวัดระดับความแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density) ด้วยเครื่องมือวัดเซนเซอร์แยกควอนตัมเอ็มคิว-200 (MQ-200 quantum separate sensor) โดยเป็นไปตามดังสมการที่ 3.33, 3.34, 3.35 และ 3.36

$$I_{R1} = [\text{Average}(i_h) \text{Average}(i_s) \text{Average}(i_v) \text{PPFD}] \quad (3.33)$$

$$I_{R2} = [\text{Average}(i_h) \text{ Average}(i_s) \text{ Average}(i_v) \text{ PPF}] \quad (3.34)$$

$$I_{R3} = [\text{Average}(i_h) \text{ Average}(i_s) \text{ Average}(i_v) \text{ PPF}] \quad (3.35)$$

$$I_{R4} = [\text{Average}(i_h) \text{ Average}(i_s) \text{ Average}(i_v) \text{ PPF}] \quad (3.36)$$

จากสมการที่ 3.33, 3.34, 3.35 และ 3.36 จะเป็นชุดข้อมูลดิบขาเข้าที่เกิดจาก ยกตัวอย่างการจำลองเหตุการณ์การควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสง แอลอีดีสีน้ำเงินที่ 100% โดยเป็นการพิจารณาความแสงแอลอีดีสีแดงเป็นเป้าหมายหลัก ซึ่งตรงกับ กลุ่มเป้าหมายที่ออกแบบไว้คือ กลุ่มเป้าหมายที่ 4 และท้ายที่สุดสมการข้างต้นที่กล่าวขึ้นจะ ประกอบด้วยตัวแปรต่าง ๆ ดังนี้

$I_{R1}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสง แอลอีดีสีแดงดวงที่หนึ่ง

$I_{R2}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสง แอลอีดีสีแดงดวงที่สอง

$I_{R3}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสง แอลอีดีสีแดงดวงที่สาม

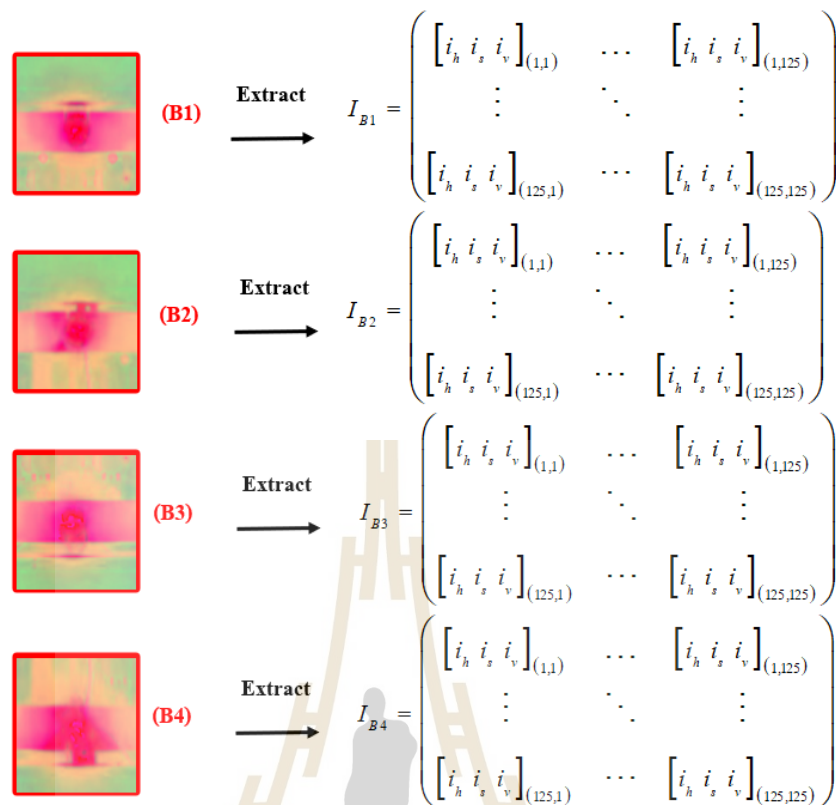
$I_{R4}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสง แอลอีดีสีแดงดวงที่สี่

$\text{Average}(i_h)$  คือ ค่าเฉลี่ยในปริภูมิย่อย Hue ของปริภูมิสี HSV

$\text{Average}(i_s)$  คือ ค่าเฉลี่ยในปริภูมิ Saturation ของปริภูมิสี HSV

$\text{Average}(i_v)$  คือ ค่าเฉลี่ยในปริภูมิย่อย Value ของปริภูมิสี HSV

PPFD คือ ค่าที่วัดได้จากเครื่องมือวัดระดับความเข้มแสงโดยความหนาแน่น ของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density : PPF)



รูปที่ 3.7 กระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี HSV จากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด  $125 \times 125$  พิกเซล

จากรูปที่ 3.7 เป็นกระบวนการสกัดค่าคุณลักษณะเฉพาะที่เป็นปริภูมิสี HSV จากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวงที่ถูกกำหนดขอบเขตเป็นกล่องสี่เหลี่ยมขนาด  $125 \times 125$  พิกเซล ผู้วิจัยได้พยายามนำภาพย่อยเหล่านี้มาสกัดค่าคุณลักษณะเฉพาะด้วยวิธีการที่ออกแบบขึ้น ผู้วิจัยจะเลือกค่าคุณลักษณะเฉพาะของภาพย่อยเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ ของภาพย่อยที่มีปริภูมิย่อยสี HSV ที่ประกอบไปด้วย

$h$  คือปริภูมิย่อย Hue ของปริภูมิสี HSV

$s$  คือปริภูมิย่อย Saturation ของปริภูมิสี HSV

$v$  คือปริภูมิย่อยสีน้ำเงิน Value ของปริภูมิสี HSV

ด้วยขอบเขตของกล่องสี่เหลี่ยมที่กำหนดไว้ที่  $125 \times 125$  พิกเซล ซึ่งหมายความว่ากล่องสี่เหลี่ยมที่กำหนดไว้มีขนาดกว้างและยาวเท่ากันที่ 125 พิกเซล ทำให้ได้ข้อมูลเป็นพิกเซล ณ ตำแหน่งเล็ก ๆ จำนวนทั้งหมด 15,625 ชุดข้อมูล จากนั้นเมื่อได้ชุดข้อมูลจากการสกัดค่าคุณลักษณะเฉพาะเรียบร้อยแล้ว และท้ายที่สุดผู้วิจัยจะทำการเฉลี่ยชุดข้อมูลทั้งหมดที่เหลือเพียง

หนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอลอีดีสีน้ำเงิน ซึ่งผู้วิจัยสามารถนำเสนอเพื่อสามารถให้รายละเอียดเพิ่มเติมสมการดังต่อไปนี้

$$I_{B1} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.37)$$

จากสมการ (3.37) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุด ข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่หนึ่ง

$$I_{B2} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.38)$$

จากสมการ (3.38) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุด ข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สอง

$$I_{B3} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.39)$$

จากสมการ (3.39) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุด ข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สาม

$$I_{B4} = \begin{pmatrix} [i_h \ i_s \ i_v]_{(1,1)} & \cdots & [i_h \ i_s \ i_v]_{(1,125)} \\ \vdots & \ddots & \vdots \\ [i_h \ i_s \ i_v]_{(125,1)} & \cdots & [i_h \ i_s \ i_v]_{(125,125)} \end{pmatrix} \quad (3.40)$$

จากสมการ (3.40) เป็นสมการที่อธิบายถึงชุดข้อมูลจำนวนทั้งหมด 15,625 ชุด ข้อมูลที่สกัดค่าคุณลักษณะเฉพาะซึ่งอยู่ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สี่

จากสมการที่ (3.37), (3.38), (3.39) และ (3.40) จะประกอบด้วยตัวแปรต่าง ๆ ดังนี้

$i_h$  คือ ค่าเฉลี่ยที่อยู่ในช่วง  $[0,360]$  ซึ่งอยู่ในรูปแบบขององศาในปริภูมิย่อย

Hue

$i_s$  คือ ค่าความบริสุทธิ์ของสีที่อยู่ในช่วง  $[0,255]$  ซึ่งมีจำนวน 256 ระดับ  
ในปริภูมิย่อย Saturation

$i_v$  คือ ค่าความสว่างของสีที่อยู่ในช่วง  $[0,255]$  ซึ่งมีจำนวน 256 ระดับ  
ในปริภูมิย่อย Value

จากนั้นทำการเฉลี่ยชุดข้อมูลทั้งหมดที่เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสง  
แอลอีดีสีน้ำเงิน โดยเป็นไปตามดังสมการที่ 3.41, 3.42, 3.43 และ 3.44

$$I_{B1} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.41)$$

$$I_{B2} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.42)$$

$$I_{B3} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.43)$$

$$I_{B4} = [\text{Average}(i_h)\text{Average}(i_s)\text{Average}(i_v)] = \left[ \sum_{n=1}^{15,625} \frac{(i_h)_n}{N} \sum_{n=1}^{15,625} \frac{(i_s)_n}{N} \sum_{n=1}^{15,625} \frac{(i_v)_n}{N} \right] \quad (3.44)$$

จากสมการที่ 3.41, 3.42, 3.43 และ 3.44 เมื่อทำการเฉลี่ยชุดข้อมูลที่อยู่ในปริภูมิสี  
HSV ทั้งหมดที่เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งดวงแสงแอลอีดีสีน้ำเงินเรียบร้อยแล้ว ผู้วิจัยจะทำการ  
เพิ่มข้อมูลที่สำคัญอย่างหน่วยมาตรฐานสำหรับการวัดระดับความเข้มแสงโดยความหนาแน่น  
ของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density) ด้วยเครื่องมือวัด  
เซนเซอร์แยกควอนตัมเอ็มคิว-200 (MQ-200 quantum separate sensor) โดยเป็นไปตามดังสมการที่  
3.45, 3.46, 3.47 และ 3.48

$$I_{B1} = [\text{Average}(i_h) \text{Average}(i_s) \text{Average}(i_v) \text{PPFD}] \quad (3.45)$$

$$I_{B2} = [\text{Average}(i_h) \text{Average}(i_s) \text{Average}(i_v) \text{PPFD}] \quad (3.46)$$

$$I_{B3} = [\text{Average}(i_h) \text{Average}(i_s) \text{Average}(i_v) \text{PPFD}] \quad (3.47)$$

$$I_{B4} = [\text{Average}(i_h) \text{ Average}(i_s) \text{ Average}(i_v) \text{ PPF D}] \quad (3.48)$$

จากสมการที่ 3.45, 3.46, 3.47 และ 3.48 จะเป็นชุดข้อมูลดิบขาเข้าที่เกิดจากยกตัวอย่างการจำลองเหตุการณ์การควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสงแอลอีดีสีน้ำเงินที่ 100% โดยเป็นการพิจารณาความเข้มแสงแอลอีดีสีน้ำเงินเป็นเป้าหมายหลัก ซึ่งตรงกับกลุ่มเป้าหมายที่ออกแบบไว้คือ กลุ่มเป้าหมายที่ 8 และท้ายที่สุดสมการข้างต้นที่กล่าวขึ้นจะประกอบด้วยตัวแปรต่าง ๆ ดังนี้

$I_{B1}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่หนึ่ง

$I_{B2}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สอง

$I_{B3}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สาม

$I_{B4}$  คือ ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินดวงที่สี่

$\text{Average}(i_h)$  คือ ค่าเฉลี่ยในปริภูมิย่อย Hue ของปริภูมิสี HSV

$\text{Average}(i_s)$  คือ ค่าเฉลี่ยในปริภูมิ Saturation ของปริภูมิสี HSV

$\text{Average}(i_v)$  คือ ค่าเฉลี่ยในปริภูมิย่อย Value ของปริภูมิสี HSV

PPFD คือ ค่าที่วัดได้จากเครื่องมือวัดระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (Photosynthetic Photon Flux Density : PPFD)

### 3.3.3 กระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB

ในส่วนของหัวข้อย่อยนี้ ผู้วิจัยจะนำเสนอถึงการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB เพื่อนำชุดข้อมูลที่ได้เหล่านี้ เตรียมพร้อมสำหรับชั้นข้อมูลขาเข้า (Input data class) และชั้นข้อมูลเป้าหมาย (Target data class) ซึ่งกระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลักในปริภูมิสี RGB ผู้วิจัยนำเสนอถึงชุดข้อมูล 3 ส่วนหลัก ๆ ได้แก่ 1) นำเสนอชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงิน 2) นำเสนอชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงิน 3) นำเสนอชุดข้อมูล



ใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายอัลตราไวท์แดงและสีน้ำเงิน

### 1. ชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายอัลตราไวท์แดงและสีน้ำเงิน

การสกัดค่าคุณลักษณะเฉพาะทั้งหมด 40 เหตุการณ์จะมีชุดข้อมูลทั้งหมด 160 ชุดข้อมูล จากเดิมในหนึ่งเหตุการณ์จำลองจะประกอบไปด้วยสี่ชุดข้อมูล ผู้วิจัยจะทำการเฉลี่ยทั้งสี่ชุดข้อมูลให้เหลือหนึ่งชุดข้อมูล จากสมการ 3.9, 3.10, 3.11 และ 3.12 ที่เป็นสมการชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี RGB จากภาพถ่ายแสงอัลตราไวท์แดงจะถูกเฉลี่ยซึ่งเป็นไปตามสมการที่ 3.49 และจากสมการ 3.21, 3.22, 3.23 และ 3.24 ที่เป็นชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี RGB จากภาพถ่ายแสงอัลตราไวท์สีน้ำเงินจะถูกเฉลี่ยซึ่งเป็นไปตามสมการที่ 3.50

$$I_{avg(R)} = \frac{I_{R1} + I_{R2} + I_{R3} + I_{R4}}{4} \quad (3.49)$$

จากสมการที่ 3.49 เป็นสมการที่เกิดจากเฉลี่ยทั้ง 4 ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี RGB ให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งเหตุการณ์ เช่นเดียวกัน

$$I_{avg(B)} = \frac{I_{B1} + I_{B2} + I_{B3} + I_{B4}}{4} \quad (3.50)$$

สมการที่ 3.50 เป็นสมการที่เกิดจากเฉลี่ยทั้ง 4 ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี RGB ให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งเหตุการณ์

ค่าชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ ผู้วิจัยจะทำการเตรียมชุดข้อมูลด้วยเทคนิคการเฉลี่ยชุดข้อมูล (Average) ทั้งปริภูมิอัลตราไวท์แดง ปริภูมิอัลตราไวท์เขียว ปริภูมิอัลตราไวท์สีน้ำเงิน และค่าระดับความเข้มแสงโดยความหนาแน่นของฟอตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ตามสมการที่ 3.51, 3.52, 3.53 และ 3.54 ตามลำดับ และผู้วิจัยทำการคำนวณเพื่อหาค่าส่วนเบี่ยงเบนมาตรฐาน (Standard deviation) ตามสมการที่ 3.55, 3.56, 3.57 และ 3.58 ตามลำดับ

$$Avg(i_r) = \sum_{n=1}^{40} \frac{(i_r)_n}{N} \quad (3.51)$$

จากสมการที่ 3.51 เป็นการเฉลี่ยเฉพาะค่าสีแดงในปฏิภูมีย่อยสีแดงทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 195.1217 ตามตารางที่ 3.2

$$Avg(i_g) = \sum_{n=1}^{40} \frac{(i_g)_n}{N} \quad (3.52)$$

จากสมการที่ 3.52 เป็นการเฉลี่ยเฉพาะค่าระดับในปฏิภูมีย่อยสีเขียวทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 204.6726 ตามตารางที่ 3.2

$$Avg(i_b) = \sum_{n=1}^{40} \frac{(i_b)_n}{N} \quad (3.53)$$

จากสมการที่ 3.53 เป็นการเฉลี่ยเฉพาะค่าระดับในปฏิภูมีย่อยสีน้ำเงินทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 205.1655 ตามตารางที่ 3.2

$$Avg(PPFD) = \sum_{n=1}^{40} \frac{(PPFD)_n}{N} \quad (3.54)$$

จากสมการที่ 3.54 เป็นการเฉลี่ยเฉพาะค่าระดับความเข้มแสงโดยความหนาแน่นของฟोटอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 56.7 ตามตารางที่ 3.2

$$\sigma(i_r) = \sqrt{\sum_{n=1}^{40} \frac{[(i_r)_n - Avg(i_r)]^2}{(N - 1)}} \quad (3.55)$$

จากสมการที่ 3.55 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับในปฏิภูมีย่อยสีแดงทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 18.67553 ตามตารางที่ 3.2

$$\sigma(i_g) = \sqrt{\frac{\sum_{n=1}^{40} [(i_g)_n - Avg(i_g)]^2}{(N - 1)}} \quad (3.56)$$

จากสมการที่ 3.56 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับในปริภูมีย่อยสีเขียวทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 27.02116 ตามตารางที่ 3.2

$$\sigma(i_b) = \sqrt{\frac{\sum_{n=1}^{40} [(i_b)_n - Avg(i_b)]^2}{(N - 1)}} \quad (3.57)$$

จากสมการที่ 3.57 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับในปริภูมีย่อยสีน้ำเงินทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 19.49005 ตามตารางที่ 3.2

$$\sigma(PPFD) = \sqrt{\frac{\sum_{n=1}^{40} [(PPFD)_n - Avg(PPFD)]^2}{(N - 1)}} \quad (3.58)$$

จากสมการที่ 3.58 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับความเข้มแสงโดยความหนาแน่นของฟोटอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 23.02641 ตามตารางที่ 3.2

โดยสรุปแล้วจากสมการที่ 3.1 จนถึงสมการที่ 3.50 เป็นการยกยกตัวอย่างเหตุการณ์จำลองเพียงหนึ่งเหตุการณ์ คือเหตุการณ์จำลองในการควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสงแอลอีดีสีน้ำเงินที่ 100% โดยวัตถุประสงค์ที่ผู้วิจัยยกตัวอย่างมาเพียงตัวอย่างเดียว เป็นเพราะถ้าหากจะต้องยกตัวอย่างเหตุการณ์จำลองทั้งหมด 40 เหตุการณ์จะมีเนื้อหาที่มากเกินไป ดังนั้นจากสมการทั้งหมดนี้ในทุกเหตุการณ์จำลอง มีรูปแบบการได้มาซึ่งชุดข้อมูลเหมือนกัน ซึ่งเป็นไปตามตารางที่ 3.2 เป็นการแสดงค่าชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์

ตารางที่ 3.2 ค่าชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์

ลำดับเหตุการณ์ (n)	$(i_r)_n$	$(i_g)_n$	$(i_b)_n$	$(PPFD)_n$	กลุ่มเป้าหมาย
1	191.053	134.358	173.962	14	1
2	214.218	137.842	183.527	30	2
3	221.2525	189.828	196.7066	46	3
4	215.8218	181.9923	202.8351	61	4
5	215.7737	153.0713	183.3184	25	1
6	209.3265	220.9197	203.0721	40	2
7	213.2202	224.0652	202.646	55	3
8	218.5813	230.1739	195.0536	70	4
9	196.3115	200.6578	214.5001	36	1
10	199.7667	203.2983	218.231	51	2
11	205.4775	216.9534	205.9142	66	3
12	213.7209	231.2987	186.187	80	4
13	192.5031	206.6905	213.9847	46	1
14	200.2555	214.3223	210.2391	61	2
15	204.2663	221.0966	205.413	75	3
16	209.7288	232.5733	187.1574	90	4
17	187.6986	203.6975	212.7557	57	1
18	196.8685	206.3326	215.3126	71	2
19	202.2158	224.3067	192.2993	85	3
20	205.87	228.501	188.6157	98	4
21	150.0961	230.8574	228.4374	10	5
22	153.1303	233.098	237.7383	20	6
23	152.9655	232.9839	237.2672	32	7
24	152.0155	230.0284	240.2921	43	8
25	197.2911	148.8692	173.0541	25	5
26	180.77	177.9548	228.5946	36	6


ตารางที่ 3.2 ค่าชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ (ต่อ)

ลำดับเหตุการณ์ (n)	$(i_r)_n$	$(i_g)_n$	$(i_b)_n$	$(PPFD)_n$	กลุ่มเป้าหมาย
27	176.5032	181.3903	230.29	46	7
28	171.7206	180.6388	230.0184	57	8
29	203.4573	216.069	194.69	40	5
30	192.6177	185.771	224.2607	51	6
31	187.2797	191.983	222.6395	61	7
32	181.6453	181.2848	229.44	71	8
33	209.7848	227.3383	183.8871	55	5
34	198.2172	205.9159	204.8489	66	6
35	193.2207	204.229	212.2195	75	7
36	186.6953	202.6518	206.2697	85	8
37	213.7283	237.3698	169.5387	70	5
38	202.6628	225.8252	175.6086	80	6
39	196.4264	220.4754	188.0849	90	7
40	190.7075	210.1909	197.7091	98	8
ค่าเฉลี่ย (Average)	195.1217	204.6726	205.1655	56.7	
ส่วนเบี่ยงเบนมาตรฐาน ( $\sigma$ )	18.67553	27.02116	19.49005	23.02641	

จากตารางที่ 3.2 เป็นค่าชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ โดยที่ลำดับเหตุการณ์ที่ 1 จนถึง 20 เป็นการพิจารณาความแสงแอลอีดีสีแดงเป็นเป้าหมายหลัก ทำให้ทั้ง 20 เหตุการณ์จะประกอบไปด้วยกลุ่มเป้าหมายหรือชั้นข้อมูลเป้าหมาย (Target data class) ทั้งหมด 4 ชั้นข้อมูลเป้าหมายได้แก่ พิจารณาที่สีแดง 25% คือกลุ่มเป้าหมายที่ 1 พิจารณาที่สีแดง 50% คือกลุ่มเป้าหมายที่ 2 พิจารณาที่สีแดง 75% คือกลุ่มเป้าหมายที่ 3 และพิจารณาที่สีแดง 100% คือกลุ่มเป้าหมายที่ 4 ต่อมาลำดับเหตุการณ์ที่ 21 จนถึง 40 เป็นการพิจารณาความแสงแอลอีดีสีน้ำเงินเป็นเป้าหมายหลัก ทำให้ทั้ง 20 เหตุการณ์จะประกอบไปด้วยกลุ่มเป้าหมายหรือชั้นข้อมูลเป้าหมาย (Target data class) ทั้งหมด 4 ชั้นข้อมูล


เป้าหมายได้แก่ พิจารณาที่สีแดง 25% คือกลุ่มเป้าหมายที่ 5 พิจารณาที่สีแดง 50% คือกลุ่มเป้าหมายที่ 6 พิจารณาที่สีแดง 75% คือกลุ่มเป้าหมายที่ 7 และพิจารณาที่สีแดง 100% คือกลุ่มเป้าหมายที่ 8

ในท้ายที่สุด ค่าชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ จะนำมาหาสมการเพื่อทำการแปลงชุดข้อมูลและพล็อตเป็นกราฟเพื่อพิจารณาถึงความสัมพันธ์ของชุดข้อมูล ซึ่งเป็นไปตามรูปที่ 3.8 คือกราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดง และตามรูปที่ 3.9 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีน้ำเงิน



รูปที่ 3.8 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง

กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี RGB จากภาพ  
ย่อยแอลอีดีสีน้ำเงิน



รูปที่ 3.9 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่า  
คุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวง

## 2. ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะ เฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงิน

จากค่าเฉลี่ยตามสมการที่ 3.51, 3.52, 3.53, 3.54 และค่าส่วนเบี่ยงเบนมาตรฐานตามสมการที่ 3.55, 3.56, 3.57, 3.58 ผู้วิจัยนำค่าที่ได้เหล่านี้มาทำการปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ของชุดข้อมูลตามสมการที่ 3.59, 3.60, 3.61, และ 3.62 ตามลำดับ

$$STD(i_r)_n = \frac{(i_r)_n - Avg(i_r)}{\sigma(i_r)} \quad (3.59)$$

จากสมการที่ 3.59 เป็นค่าการกำหนดมาตรฐานเฉพาะค่าระดับสีแดงในปริภูมิย่อยสีแดงทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจากผลต่างระหว่างค่าสีแดงที่อยู่ในปริภูมิย่อยสีแดง

กับค่าเฉลี่ยเฉพาะค่าสีแดงในปริภูมิย่อยสีแดง และหารด้วยค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับในปริภูมิย่อยสีแดง ซึ่งค่าการกำหนดมาตรฐานเป็นไปตามตารางที่ 3.3

$$STD(i_g)_n = \frac{(i_g)_n - Avg(i_g)}{\sigma(i_g)} \quad (3.60)$$

จากสมการที่ 3.60 เป็นค่าการกำหนดมาตรฐานเฉพาะค่าระดับสีเขียวในปริภูมิย่อยสีเขียวทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจากผลต่างระหว่างค่าสีเขียวที่อยู่ในปริภูมิย่อยสีเขียว กับค่าเฉลี่ยเฉพาะค่าสีเขียวในปริภูมิย่อยสีเขียว และหารด้วยค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับในปริภูมิย่อยสีเขียว ซึ่งค่าการกำหนดมาตรฐานเป็นไปตามตารางที่ 3.3

$$STD(i_b)_n = \frac{(i_b)_n - Avg(i_b)}{\sigma(i_b)} \quad (3.61)$$

จากสมการที่ 3.61 เป็นค่าการกำหนดมาตรฐานเฉพาะค่าระดับสีน้ำเงินในปริภูมิย่อยสีน้ำเงินทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจากผลต่างระหว่างค่าสีน้ำเงินที่อยู่ในปริภูมิย่อยสีน้ำเงินกับค่าเฉลี่ยเฉพาะค่าสีน้ำเงินในปริภูมิย่อยสีน้ำเงิน และหารด้วยค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับในปริภูมิย่อยสีน้ำเงิน ซึ่งค่าการกำหนดมาตรฐานเป็นไปตามตารางที่ 3.3

$$STD(PPFD)_n = \frac{(PPFD)_n - Avg(PPFD)}{\sigma(PPFD)} \quad (3.62)$$

จากสมการที่ 3.62 เป็นค่าการกำหนดมาตรฐานค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจากผลต่างระหว่างค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) กับค่าเฉลี่ยระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) และหารด้วยค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะของค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ซึ่งค่าการกำหนดมาตรฐานเป็นไปตามตารางที่ 3.3



ตารางที่ 3.3 ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์


ลำดับ เหตุการณ์ (n)	$STD(i_r)_n$	$STD(i_g)_n$	$STD(i_b)_n$	$STD(PPFD)_n$	กลุ่มเป้าหมาย
1	-0.21784	-2.60221	-1.60101	-1.85439	1
2	1.022533	-2.47328	-1.11025	-1.15954	2
3	1.399204	-0.54937	-0.43401	-0.46468	3
4	1.108409	-0.83935	-0.11957	0.186742	4
5	1.105837	-1.90966	-1.12094	-1.37668	1
6	0.760614	0.601274	-0.10741	-0.72525	2
7	0.969106	0.717684	-0.12927	-0.07383	3
8	1.256171	0.943752	-0.51882	0.577598	4
9	0.063713	-0.14858	0.478945	-0.89897	1
10	0.248725	-0.05086	0.670368	-0.24754	2
11	0.554516	0.454488	0.038414	0.403884	3
12	0.995913	0.985381	-0.97375	1.011882	4
13	-0.14021	0.074679	0.452497	-0.46468	1
14	0.274899	0.074679	0.452497	0.186742	2
15	0.48966	0.602176	0.012698	0.79474	3
16	0.782151	1.032552	-0.92396	1.446166	4
17	-0.39747	-0.03608	0.389442	0.013029	1
18	0.093537	0.061435	0.520631	0.621026	2
19	0.379863	0.72662	-0.66014	1.229024	3
20	0.575531	0.881843	-0.84914	1.793593	4
21	-2.41094	0.969047	1.19404	-2.02811	5
22	-2.24847	1.051968	1.671256	-1.59382	6
23	-2.2573	1.047746	1.647083	-1.07268	7
24	-2.30816	0.938369	1.802286	-0.59497	8
25	0.116163	-2.06517	-1.64758	-1.37668	5

ตารางที่ 3.3 ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ (ต่อ)

ลำดับ เหตุการณ์ (n)	$STD(i_r)_n$	$STD(i_g)_n$	$STD(i_b)_n$	$STD(PPFD)_n$	กลุ่มเป้าหมาย
26	-0.76847	-0.98877	1.202105	-0.89897	6
27	-0.99694	-0.86163	1.289097	-0.46468	7
28	-1.25303	-0.88944	1.275161	0.013029	8
29	0.446339	0.42176	-0.53748	-0.72525	5
30	-0.13407	-0.69951	0.979744	-0.24754	6
31	-0.41991	-0.46962	0.896564	0.186742	7
32	-0.72161	-0.86553	1.245486	0.621026	8
33	0.785152	0.838813	-1.09176	-0.07383	5
34	0.165755	0.046011	-0.01624	0.403884	6
35	-0.10179	-0.01642	0.361931	0.79474	7
36	-0.4512	-0.07479	0.056654	1.229024	8
37	0.996312	1.210059	-1.82795	0.577598	5
38	0.4038	0.782817	-1.51651	1.011882	6
39	0.069866	0.58483	-0.87637	1.446166	7
40	-0.23636	0.20422	-0.38257	1.793593	8

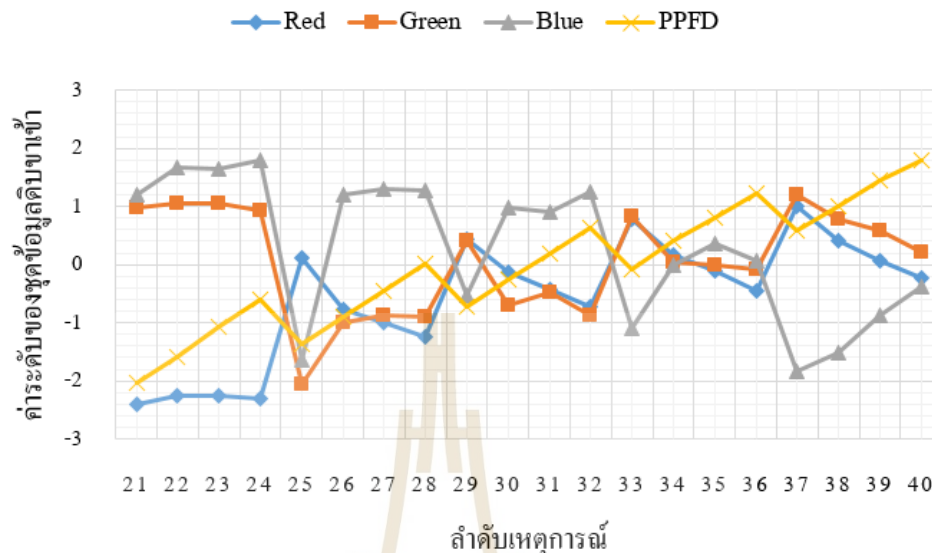
จากตารางที่ 3.3 เป็นค่าชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ โดยที่ค่าชุดข้อมูลเหล่านี้จะถูกปรับขนาดลงให้เหลืออยู่ในช่วง [-3,3] ซึ่งค่าสูงสุด (Max) ของชุดข้อมูลมีค่าเท่ากับ 1.80229 และค่าต่ำสุด (Min) ของชุดข้อมูลมีค่าเท่ากับ -2.60221

เมื่อชุดข้อมูลเหล่านี้ถูกปรับขนาดลง ทำให้สามารถพิจารณาถึงรายละเอียดของชุดข้อมูลได้ชัดเจนยิ่งขึ้น รวมถึงทำให้ช่วงข้อมูลลดความซับซ้อนของชุดข้อมูลในเรื่องของมิติหรือจำนวนค่าคุณลักษณะที่มีความสัมพันธ์กันมากยิ่งขึ้น ซึ่งเป็นไปตามรูปที่ 3.10 คือกราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายอัลตราสปีดทั้งสี่ดวง และตามรูปที่ 3.11 คือกราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายอัลตราสปีดทั้งสี่ดวง



รูปที่ 3.10 กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายอัลตราสปีดทั้งสี่ดวง

กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดในปริภูมิสี  
RGB จากภาพถ่ายแอตดีตีสีน้ำเงิน



รูปที่ 3.11 กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายแอตดีตีสีน้ำเงินทั้งสี่ดวง

### 3. ชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายแอตดีตีสีแดงและสีน้ำเงิน

ในส่วนนี้คือส่วนสุดท้ายก่อนนำชุดข้อมูลที่เกิดจากกระบวนการสกัดค่าคุณลักษณะเฉพาะในปริภูมิ RGB เข้าสู่โครงข่ายประสาทเทียม ส่วนนี้จะถูกเรียกว่าชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) โดยหลักการในการแปลงข้อมูลด้วยเทคนิคนี้ อันดับแรกจำเป็นต้องหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ตามสมการที่ 3.63 และ 3.64 อันดับที่สองจะหาค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ตามสมการที่ 3.65 และ 3.66 เพื่อหาค่าลักษณะเฉพาะ (Eigenvalues) และเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ที่ท้ายที่สุดทำการแปลงชุดข้อมูลใหม่ด้วยผลคูณเมทริกซ์ระหว่างเวกเตอร์ลักษณะเฉพาะกับชุดข้อมูลชุดที่จัดรูปแบบใหม่ในรูปแบบของเมทริกซ์ตามสมการที่ 3.71, 3.72, 3.73, 3.74 และ 3.75 ตามลำดับ

$$Cov(x, y) = \sum_{n=1}^N \frac{[(x)_n - Avg(x)][(y)_n - Avg(y)]}{(N - 1)} \quad (3.63)$$

จากสมการที่ 3.63 เป็นยกตัวอย่างการหาค่าความแปรปรวนร่วม (Covariance) ซึ่งเกิดจากผลรวมระหว่างตัวแปร  $x$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $x$  และคูณด้วยตัวแปร  $y$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $y$  และสุดท้ายหารด้วยจำนวนทั้งหมดลบด้วยหนึ่ง โดยผู้วิจัยจะนำค่าชุดข้อมูลทั้งหมด จำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยค่าระดับสีแดงในปริภูมิย่อยสีแดง ค่าระดับสีเขียวในปริภูมิย่อยสีเขียว ค่าระดับสีน้ำเงินในปริภูมิย่อยสีน้ำเงิน และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ ( $n$ ) ที่ได้มาแทนในตัวแปรแทนตัวแปร  $x$  และ  $y$  ในการหาค่าจริงตามสมการที่ 3.64

$$\text{Covariance matrix} = \begin{bmatrix} Cov(i_r, i_r) & Cov(i_r, i_g) & Cov(i_r, i_b) & Cov(i_r, \text{PPFD}) \\ Cov(i_g, i_r) & Cov(i_g, i_g) & Cov(i_g, i_b) & Cov(i_g, \text{PPFD}) \\ Cov(i_b, i_r) & Cov(i_b, i_g) & Cov(i_b, i_b) & Cov(i_b, \text{PPFD}) \\ Cov(\text{PPFD}, i_r) & Cov(\text{PPFD}, i_g) & Cov(\text{PPFD}, i_b) & Cov(\text{PPFD}, \text{PPFD}) \end{bmatrix} \quad (3.64)$$

จากสมการที่ 3.64 เป็นการหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ซึ่งหาได้จากสมการที่ 3.63 ที่ประยุกต์ใช้ร่วมกับชุดข้อมูลจำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยค่าระดับสีแดงในปริภูมิย่อยสีแดง ค่าระดับสีเขียวในปริภูมิย่อยสีเขียว ค่าระดับสีน้ำเงินในปริภูมิย่อยสีน้ำเงิน และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทำให้ได้เมทริกซ์ขนาด  $4 \times 4$  และสมการความแปรปรวนร่วม (Covariance) จำนวน 16 สมการ ในท้ายที่สุดผู้วิจัยสามารถหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ได้ตามตารางที่ 3.4 ดังนี้

ตารางที่ 3.4 ค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) สำหรับชุดข้อมูลในปริภูมิสี RGB

Covariance matrix				
	$i_r$	$i_g$	$i_b$	PPFD
$i_r$	348.7756	-47.1794	-274.534	155.6952
$i_g$	-47.1794	730.1429	62.66694	269.905
$i_b$	-274.534	62.66694	379.862	-110.898
PPFD	155.6952	269.905	-110.898	530.2154

จากตารางที่ 3.4 เป็นค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ซึ่งจะนำค่าที่ได้เหล่านี้ไปหาค่าสหสัมพันธ์ (Correlation) หรือ ค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ตามสมการที่ 3.65 และ 3.66 ตามลำดับ

$$\text{Corr}(x, y) = \frac{\text{Cov}(x, y)}{\sigma(x)\sigma(y)} \quad (3.65)$$

จากสมการที่ 3.65 เป็นยกตัวอย่างการหาค่าความสัมพันธ์ (Correlation) ซึ่งเกิดจากผลรวมระหว่างตัวแปร  $x$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $x$  และคูณด้วยตัวแปร  $y$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $y$  และสุดท้ายหารด้วยจำนวนทั้งหมดลบด้วยหนึ่ง โดยผู้วิจัยจะนำค่าชุดข้อมูลทั้งหมดจำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยระดับสีแดงในปฏิภูมีย่อยสีแดง ค่าระดับสีเขียวในปฏิภูมีย่อยสีเขียว ค่าระดับสีน้ำเงินในปฏิภูมีย่อยสีน้ำเงิน และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 4 ลำดับเหตุการณ์ ( $n$ ) ที่ได้มาแทนในตัวแปรแทนตัวแปร  $x$  และ  $y$  ในการหาค่าจริงตามสมการที่ 3.66

$$\text{Correlation matrix} = \begin{bmatrix} \frac{\text{Cov}(i_r, i_r)}{\sigma(i_r)\sigma(i_r)} & \frac{\text{Cov}(i_r, i_g)}{\sigma(i_r)\sigma(i_g)} & \frac{\text{Cov}(i_r, i_b)}{\sigma(i_r)\sigma(i_b)} & \frac{\text{Cov}(i_r, \text{PPFD})}{\sigma(i_r)\sigma(\text{PPFD})} \\ \frac{\text{Cov}(i_g, i_r)}{\sigma(i_g)\sigma(i_r)} & \frac{\text{Cov}(i_g, i_g)}{\sigma(i_g)\sigma(i_g)} & \frac{\text{Cov}(i_g, i_b)}{\sigma(i_g)\sigma(i_b)} & \frac{\text{Cov}(i_g, \text{PPFD})}{\sigma(i_g)\sigma(\text{PPFD})} \\ \frac{\text{Cov}(i_b, i_r)}{\sigma(i_b)\sigma(i_r)} & \frac{\text{Cov}(i_b, i_g)}{\sigma(i_b)\sigma(i_g)} & \frac{\text{Cov}(i_b, i_b)}{\sigma(i_b)\sigma(i_b)} & \frac{\text{Cov}(i_b, \text{PPFD})}{\sigma(i_b)\sigma(\text{PPFD})} \\ \frac{\text{Cov}(\text{PPFD}, i_r)}{\sigma(\text{PPFD})\sigma(i_r)} & \frac{\text{Cov}(\text{PPFD}, i_g)}{\sigma(\text{PPFD})\sigma(i_g)} & \frac{\text{Cov}(\text{PPFD}, i_b)}{\sigma(\text{PPFD})\sigma(i_b)} & \frac{\text{Cov}(\text{PPFD}, \text{PPFD})}{\sigma(\text{PPFD})\sigma(\text{PPFD})} \end{bmatrix} \quad (3.66)$$

จากสมการที่ 3.66 เป็นการหาค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ซึ่งหาได้จากสมการที่ 3.65 ที่ประยุกต์ใช้ร่วมกับชุดข้อมูลจำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยค่าระดับสีแดงในปฏิภูมีย่อยสีแดง ค่าระดับสีเขียวในปฏิภูมีย่อยสีเขียว ค่าระดับสีน้ำเงินในปฏิภูมีย่อยสีน้ำเงิน และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทำให้ได้เมทริกซ์ขนาด  $4 \times 4$  และสมการสหสัมพันธ์ (Correlation) จำนวน 16 สมการ ในท้ายที่สุดผู้วิจัยสามารถหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ได้ตามตารางที่ 3.5 ดังนี้

ตารางที่ 3.5 ค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) สำหรับชุดข้อมูลในปริภูมิสี RGB

Correlation matrix				
	$i_r$	$i_g$	$i_b$	PPFD
$i_r$	1	-0.09349	-0.75424	0.362056
$i_g$	-0.09349	1	0.118993	0.433791
$i_b$	-0.75424	0.118993	1	-0.24711
PPFD	0.362056	0.433791	-0.24711	1

จากตารางที่ 3.5 เป็นค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ซึ่งจะนำค่าที่ได้เหล่านี้ ไปหาค่าลักษณะเฉพาะ (Eigenvalues) และจากนั้นจึงหาค่าเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ซึ่งผู้วิจัยจะนำเสนอวิธีการหาค่าลักษณะเฉพาะ (Eigenvalues) และค่าเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ดังต่อไปนี้

Sol<sup>n</sup>

$$\begin{aligned}
 \det(A - \lambda I) &= \begin{vmatrix} 1 & -0.09349 & -0.75424 & 0.362056 \\ -0.09349 & 1 & 0.118993 & 0.433791 \\ -0.75424 & 0.118993 & 1 & -0.24711 \\ 0.362056 & 0.433791 & -0.24711 & 1 \end{vmatrix} - \lambda \begin{vmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{vmatrix} \\
 &= \begin{vmatrix} 1 - \lambda & -0.09349 & -0.75424 & 0.362056 \\ -0.09349 & 1 - \lambda & 0.118993 & 0.433791 \\ -0.75424 & 0.118993 & 1 - \lambda & -0.24711 \\ 0.362056 & 0.433791 & -0.24711 & 1 - \lambda \end{vmatrix} \\
 &= (\lambda^4 - 4\lambda^3 - 5.0279\lambda^2 - 2.15266\lambda + 0.275521) \\
 &= (\lambda - 1.95272)(\lambda - 1.37094)(\lambda - 0.44512)(\lambda - 0.231216)
 \end{aligned}$$

Ans  $\lambda_1 = 1.952723$ ,  $\lambda_2 = 1.37094$ ,  $\lambda_3 = 0.44512$ ,  $\lambda_4 = 0.231216$

วิธีการข้างต้นเป็นวิธีการหาค่าลักษณะเฉพาะ (Eigenvalues) จากวิธีการตัวกำหนดหรือเรียกว่าดีเทอร์มิแนนต์ (Determinant) โดยกำหนดให้ A แทนเป็นเมทริกซ์สหสัมพันธ์ (Correlation matrix) และลบด้วยค่าลักษณะเฉพาะ (Eigenvalues) ที่ผู้วิจัยต้องการหาค่า

แทนด้วย  $\lambda$  และคูณด้วยเอกลักษณ์เมทริกซ์ที่แทนด้วย I จากนั้นสามารถหาค่าลักษณะเฉพาะ (Eigenvalues) โดยมีทั้งหมดจำนวน 4 ค่า ได้แก่  $\lambda_1 = 1.952723$ ,  $\lambda_2 = 1.37094$ ,  $\lambda_3 = 0.44512$  และ  $\lambda_4 = 0.231216$  ตามลำดับ ในท้ายที่สุดนำค่าลักษณะเฉพาะ (Eigenvalues) เหล่านี้ไปหาค่าเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) โดยสามารถได้ตามวิธีการที่นำเสนอ ดังต่อไปนี้

Sol<sup>n</sup>

$$(A - \lambda I)\bar{X} = \bar{0}$$

$$\left( \begin{bmatrix} 1 & -0.09349 & -0.75424 & 0.362056 \\ -0.09349 & 1 & 0.118993 & 0.433791 \\ -0.75424 & 0.118993 & 1 & -0.24711 \\ 0.362056 & 0.433791 & -0.24711 & 1 \end{bmatrix} - \lambda I \right) \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

↓

$$(1-\lambda)X_1 - 0.09349X_2 - 0.75424X_3 + 0.362056X_4 = 0 \rightarrow (1)$$

$$-0.09349X_1 + (1-\lambda)X_2 + 0.118993X_3 + 0.433791X_4 = 0 \rightarrow (2)$$

$$-0.75424X_1 + 0.118993X_2 + (1-\lambda)X_3 - 0.24711X_4 = 0 \rightarrow (3)$$

$$0.362056X_1 + 0.433791X_2 - 0.24711X_3 + (1-\lambda)X_4 = 0 \rightarrow (4)$$

$$\text{แทน } \lambda_1 = 1.952723 \text{ ลงในสมการ (1)-(4); } \bar{X}_1 = \begin{bmatrix} -0.65071 \\ -0.05616 \\ 0.620655 \\ -0.43383 \end{bmatrix}$$

$$\text{แทน } \lambda_2 = 1.370943 \text{ ลงในสมการ (1)-(4); } \bar{X}_2 = \begin{bmatrix} -0.18563 \\ 0.772367 \\ 0.259254 \\ 0.549343 \end{bmatrix}$$



$$\text{แทน } \lambda_3 = 0.445121 \text{ ลงในสมการ (1)-(4); } \bar{X}_3 = \begin{bmatrix} -0.05244 \\ -0.6246 \\ 0.368421 \\ 0.686582 \end{bmatrix}$$

$$\text{แทน } \lambda_4 = 0.231213 \text{ ลงในสมการ (1)-(4); } \bar{X}_4 = \begin{bmatrix} -0.73442 \\ -0.10086 \\ -0.64175 \\ 0.19651 \end{bmatrix}$$

วิธีการข้างต้นเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) โดยกำหนดให้ A แทนเป็นเมทริกซ์สหสัมพันธ์ (Correlation matrix) และลบด้วยค่าลักษณะเฉพาะ (Eigenvalues) ด้วย  $\lambda$  และคูณด้วยเอกลักษณ์เมทริกซ์ที่แทนด้วย I เหมือนเดิม แต่ที่เพิ่มจากเดิมคือเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ที่แทนด้วย  $\bar{X}$  จากนั้นแทนค่าลักษณะเฉพาะ (Eigenvalues) โดยมีทั้งหมดจำนวน 4 ค่า ได้แก่  $\lambda_1 = 1.952723$ ,  $\lambda_2 = 1.37094$ ,  $\lambda_3 = 0.44512$  และ  $\lambda_4 = 0.231216$  ลงในสมการ (1), (2), (3) และ (4) ในท้ายที่สุดจะได้เวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ตามวิธีการข้างต้น และทำการเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ซึ่งเป็นไปตามสมการที่ 3.67, 3.68, 3.69 และ 3.70 ตามลำดับ

$$(\bar{X}_1)^T = [-0.65071 \quad -0.05616 \quad 0.620655 \quad -0.43383] \quad (3.67)$$

$$(\bar{X}_2)^T = [-0.18563 \quad 0.772367 \quad 0.259254 \quad 0.549343] \quad (3.68)$$

$$(\bar{X}_3)^T = [-0.05244 \quad -0.6246 \quad 0.368421 \quad 0.686582] \quad (3.69)$$

$$(\bar{X}_4)^T = [-0.73442 \quad -0.10086 \quad -0.64175 \quad 0.19651] \quad (3.70)$$

$$X_n = \begin{bmatrix} STD(i_r)_n \\ STD(i_g)_n \\ STD(i_b)_n \\ STD(PPFD)_n \end{bmatrix} \quad (3.71)$$

จากสมการที่ 3.71 เป็นการจัดรูปแบบของชุดข้อมูลใหม่ให้อยู่ในรูปแบบของเมทริกซ์ขนาด  $4 \times 1$  ซึ่งประกอบไปด้วย ค่าการกำหนดมาตรฐานเฉพาะค่าระดับสีแดงในปริภูมิย่อยสีแดงทั้ง 40 ลำดับเหตุการณ์ (n) ค่าการกำหนดมาตรฐานเฉพาะค่าระดับสีเขียวในปริภูมิย่อยสีเขียวทั้ง 40 ลำดับเหตุการณ์ (n) ค่าการกำหนดมาตรฐานเฉพาะค่าระดับสีน้ำเงินในปริภูมิย่อยสีน้ำเงินทั้ง 40 ลำดับเหตุการณ์ (n) และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) ในท้ายที่สุดแล้วผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) จะเป็นไปตามสมการที่ 3.72, 3.73, 3.74 และ 3.75 ตามลำดับ

$$Y(i_r)_n = (\bar{X}_1)^T \times (X_n) \quad (3.72)$$

จากสมการที่ 3.72 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของค่าระดับสีแดงในปริภูมิย่อยสีแดงทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_1$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.6

$$Y(i_g)_n = (\bar{X}_2)^T \times (X_n) \quad (3.73)$$

จากสมการที่ 3.73 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของค่าระดับสีเขียวในปริภูมิย่อยสีเขียวทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_2$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.6

$$Y(i_b)_n = (\bar{X}_3)^T \times (X_n) \quad (3.74)$$

จากสมการที่ 3.74 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของ ค่าการกำหนดมาตรฐานเฉพาะค่าระดับสี

น้ำเงินในปริภูมิย่อยสีน้ำเงินทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_3$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.6

$$Y(\text{PPFD})_n = (\bar{X}_4)^T \times (X_n) \quad (3.75)$$

จากสมการที่ 3.75 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_4$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.6


ตารางที่ 3.6 ชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์

ลำดับเหตุการณ์ (n)	$Y(i_r)_n$	$Y(i_g)_n$	$Y(i_b)_n$	$Y(\text{PPFD})_n$	กลุ่มเป้าหมาย
1	0.098703	-3.40319	-0.22628	1.085491	1
2	-0.71252	-3.02491	0.286023	-0.01686	2
3	-0.9474	-1.05184	-0.20918	-0.78498	3
4	-0.82934	-0.78245	0.550296	-0.61595	4
5	-0.7108	-2.72711	-0.2234	-0.1707	1
6	-0.28073	-0.10305	-0.95296	-0.69285	2
7	-0.71911	0.300352	-0.5974	-0.71567	3
8	-1.44299	0.678536	-0.44991	-0.57129	4
9	0.654146	-0.49626	-0.3513	-0.51582	1
10	0.364468	-0.04764	0.095744	-0.65639	2
11	-0.53773	0.479928	-0.0215	-0.39837	3
12	-1.74674	0.879629	-0.3317	-0.00706	4
13	0.569484	-0.05425	-0.19163	-0.28626	1

ตารางที่ 3.6 ชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก ในปริภูมิสี RGB (Principal Component Analysis) จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ (ต่อ)

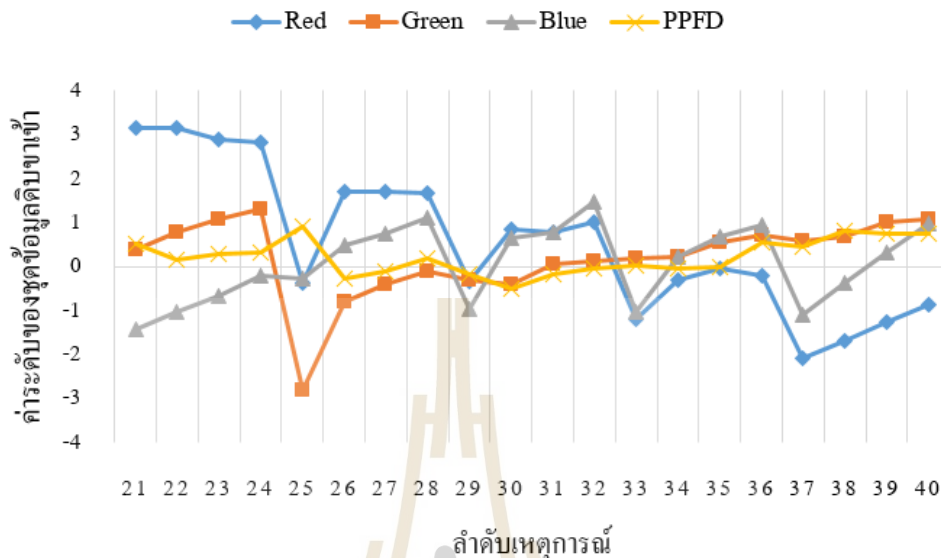
ลำดับเหตุการณ์ (n)	$Y(i_r)_n$	$Y(i_g)_n$	$Y(i_b)_n$	$Y(PPFD)_n$	กลุ่มเป้าหมาย
14	0.016757	0.226548	0.233863	-0.46312	2
15	-0.68935	0.814084	0.148537	-0.27233	3
16	-1.76779	1.207221	-0.03344	0.198562	4
17	0.496724	0.154033	0.195806	0.048189	1
18	-0.0106	0.506219	0.574919	-0.28697	2
19	-1.23089	0.994717	0.126853	0.31289	3
20	-1.72917	1.339429	0.337631	0.385765	4
21	3.135345	0.39143	-1.43139	0.508076	5
22	3.132751	0.787609	-1.01771	0.159483	6
23	2.89764	1.066004	-0.66571	0.284312	7
24	2.825962	1.293632	-0.20956	0.326977	8
25	-0.38494	-2.80005	-0.2684	0.909788	5
26	1.691674	-0.80324	0.483548	-0.28399	6
27	1.698787	-0.4015	0.746338	-0.09951	7
28	1.651093	-0.11663	1.099994	0.194192	8
29	-0.33307	-0.29486	-0.9828	-0.16793	5
30	0.842002	-0.39737	0.634943	-0.50837	6
31	0.775052	0.050253	0.773868	-0.18292	7
32	1.021758	0.129493	1.4637	-0.05999	8
33	-1.20359	0.178527	-1.01801	0.024888	5
34	-0.29574	0.222429	0.233886	-0.03658	6
35	-0.05299	0.536632	0.694589	0.000318	7
36	-0.20023	0.715837	0.93507	0.544068	8
37	-2.10137	0.593063	-1.08493	0.432825	5
38	-1.68693	0.692375	-0.37409	0.796546	6
39	-1.24962	1.005973	0.301091	0.736298	7
40	-0.87323	1.087722	0.97534	0.750964	8

จากตารางที่ 3.6 เป็นค่าชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ โดยที่ค่าชุดข้อมูลใหม่เหล่านี้จะถูกแปลงข้อมูลอยู่ในช่วง  $[-3.5, 3.2]$  ซึ่งค่าสูงสุด (Max) ของชุดข้อมูลมีค่าเท่ากับ 3.1353 และค่าต่ำสุด (Min) ของชุดข้อมูลมีค่าเท่ากับ -3.4031 เมื่อชุดข้อมูลเหล่านี้ถูกแปลงขนาดให้เป็นข้อมูลใหม่ ทำให้สามารถพิจารณาถึงรายละเอียดของชุดข้อมูลได้ชัดเจนยิ่งขึ้น รวมถึงทำให้ช่วงข้อมูลลดความซับซ้อนของชุดข้อมูลในเรื่องของมิติหรือจำนวนค่าคุณลักษณะที่ความสัมพันธ์กันมากยิ่งขึ้น และส่งผลต่อประสิทธิภาพในการฝึกฝนและทดสอบของโครงข่ายประสิทธิภาพ ซึ่งเป็นไปตามรูปที่ 3.12 คือกราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง และตามรูปที่ 3.13 คือกราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวง



รูปที่ 3.12 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง

กราฟความสัมพันธ์ของชุดข้อมูลใหม่ในปริภูมิสี RGB จากภาพ  
ย่อยแอลอีดีสีน้ำเงิน



รูปที่ 3.13 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะ เฉพาะจากภาพย่อยแอลอีดีสีน้ำเงินทั้งสิ้น

### 3.3.4 กระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV

ในส่วนของหัวข้อย่อยนี้ ผู้วิจัยจะนำเสนอถึงการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV เพื่อนำชุดข้อมูลที่ได้เหล่านี้ เตรียมพร้อมสำหรับชั้นข้อมูลขาเข้า (Input data class) และชั้นข้อมูลเป้าหมาย (Target data class) ซึ่งกระบวนการแปลงข้อมูลด้วยเทคนิคการวิเคราะห์องค์ประกอบหลักในปริภูมิสี HSV ผู้วิจัยนำเสนอถึงชุดข้อมูล 3 ส่วนหลัก ๆ ได้แก่ 1) นำเสนอชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงิน 2) นำเสนอชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงิน 3) นำเสนอชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงิน

### 1. ชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงิน

การสกัดค่าคุณลักษณะเฉพาะทั้งหมด 40 เหตุการณ์จะมีชุดข้อมูลทั้งหมด 160 ชุดข้อมูล จากเดิมในหนึ่งเหตุการณ์จำลองจะประกอบไปด้วยสี่ชุดข้อมูล ผู้วิจัยจะทำการเฉลี่ยทั้งสี่ชุดข้อมูลให้เหลือหนึ่งชุดข้อมูล จากสมการ 3.33, 3.34, 3.35 และ 3.36 ที่เป็นสมการชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีแดงจะถูกเฉลี่ยซึ่งเป็นไปตามสมการที่ 3.76 และจากสมการ 3.45, 3.46, 3.47 และ 3.48 ที่เป็นชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี HSV จากภาพย่อยแสงแอลอีดีสีน้ำเงินจะถูกเฉลี่ยซึ่งเป็นไปตามสมการที่ 3.77

$$I_{avg(R)} = \frac{I_{R1} + I_{R2} + I_{R3} + I_{R4}}{4} \quad (3.76)$$

จากสมการที่ 3.76 เป็นสมการที่เกิดจากเฉลี่ยทั้ง 4 ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 4 ในปริภูมิสี HSV ให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งเหตุการณ์ เช่นเดียวกัน

$$I_{avg(B)} = \frac{I_{B1} + I_{B2} + I_{B3} + I_{B4}}{4} \quad (3.77)$$

จากสมการที่ 3.77 เป็นสมการที่เกิดจากเฉลี่ยทั้ง 4 ชุดข้อมูลดิบของกลุ่มเป้าหมายที่ 8 ในปริภูมิสี HSV ให้เหลือเพียงหนึ่งชุดข้อมูลต่อหนึ่งเหตุการณ์

ค่าชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ ผู้วิจัยจะทำการเตรียมชุดข้อมูลด้วยเทคนิคการเฉลี่ยชุดข้อมูล (Average) ทั้งปริภูมิย่อย Hue ปริภูมิย่อย Saturation ปริภูมิย่อย Value และค่าระดับความเข้มแสง โดยความหนาแน่นของฟोटอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ตามสมการที่ 3.78, 3.79, 3.80 และ 3.81 ตามลำดับ และผู้วิจัยทำการคำนวณเพื่อหาค่าส่วนเบี่ยงเบนมาตรฐาน (Standard deviation) ตามสมการที่ 3.82, 3.83, 3.84 และ 3.85 ตามลำดับ

$$Avg(i_h) = \sum_{n=1}^{40} \frac{(i_h)_n}{N} \quad (3.78)$$

จากสมการที่ 3.78 เป็นการเฉลี่ยเฉพาะค่าเฉลี่ยในปริภูมิย่อย Hue ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 123.74 ตามตารางที่ 3.7

$$Avg(i_s) = \sum_{n=1}^{40} \frac{(i_s)_n}{N} \quad (3.79)$$

จากสมการที่ 3.79 เป็นการเฉลี่ยเฉพาะค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 158.8938 ตามตารางที่ 3.7

$$Avg(i_v) = \sum_{n=1}^{40} \frac{(i_v)_n}{N} \quad (3.80)$$

จากสมการที่ 3.80 เป็นการเฉลี่ยเฉพาะค่าความสว่างของสีในปริภูมิย่อย Value ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 236.6409 ตามตารางที่ 3.7

$$Avg(PPFD) = \sum_{n=1}^{40} \frac{(PPFD)_n}{N} \quad (3.81)$$

จากสมการที่ 3.81 เป็นการเฉลี่ยเฉพาะค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าเฉลี่ยที่ได้มีค่าเท่ากับ 56.7 ตามตารางที่ 3.7

$$\sigma(i_h) = \sqrt{\sum_{n=1}^{40} \frac{[(i_h)_n - Avg(i_h)]^2}{(N - 1)}} \quad (3.82)$$

จากสมการที่ 3.82 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าเฉดสีในปริภูมิย่อย Hue ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 29.4996 ตามตารางที่ 3.7

$$\sigma(i_s) = \sqrt{\sum_{n=1}^{40} \frac{[(i_s)_n - Avg(i_s)]^2}{(N - 1)}} \quad (3.83)$$



จากสมการที่ 3.83 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าความบริสุทธิ์ของสีในปริภูมีย่อย Saturation ที่ 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 18.4492 ตามตารางที่ 3.7

$$\sigma(i_v) = \sqrt{\sum_{n=1}^{40} \frac{[(i_v)_n - Avg(i_v)]^2}{(N - 1)}} \quad (3.84)$$

จากสมการที่ 3.84 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าความสว่างของสีในปริภูมีย่อย Value ที่ 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 16.0937 ตามตารางที่ 3.7

$$\sigma(PPFD) = \sqrt{\sum_{n=1}^{40} \frac{[(PPFD)_n - Avg(PPFD)]^2}{(N - 1)}} \quad (3.85)$$

จากสมการที่ 3.85 เป็นค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าระดับความเข้มแสงโดยความหนาแน่นของฟोटอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ที่ 40 ลำดับเหตุการณ์ (n) โดยที่ N = 40 คือลำดับเหตุการณ์ทั้งหมด ซึ่งค่าส่วนเบี่ยงเบนมาตรฐานที่ได้มีค่าเท่ากับ 23.02641 ตามตารางที่ 3.7

โดยสรุปแล้วจากสมการที่ 3.1 จนถึงสมการที่ 3.50 เป็นการยกยกตัวอย่างเหตุการณ์จำลองเพียงหนึ่งเหตุการณ์ คือเหตุการณ์จำลองในการควบคุมระดับความเข้มแสงแอลอีดีสีแดงที่ 100% และแสงแอลอีดีสีน้ำเงินที่ 100% โดยวัตถุประสงค์ที่ผู้วิจัยยกตัวอย่างมาเพียงตัวอย่างเดียว เป็นเพราะถ้าหากจะต้องยกตัวอย่างเหตุการณ์จำลองทั้งหมด 40 เหตุการณ์จะมีเนื้อหาที่มากเกินไป ดังนั้นจากสมการทั้งหมดนี้ในทุกเหตุการณ์จำลอง มีรูปแบบการได้มาซึ่งชุดข้อมูลเหมือนกัน ซึ่งเป็นไปตามตารางที่ 3.7 เป็นการแสดงค่าชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์

ตารางที่ 3.7 ค่าชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์


ลำดับเหตุการณ์ (n)	$(i_h)_n$	$(i_s)_n$	$(i_v)_n$	$(PPFD)_n$	กลุ่มเป้าหมาย
1	48.06608	174.3486	236.077	14	1
2	58.64653	152.5324	244.029	30	2
3	57.96418	135.144	248.2893	46	3
4	57.9433	109.0196	252.3608	61	4
5	153.283	166.5231	215.464	25	1
6	151.0677	146.8609	240.028	40	2
7	151.4859	149.4042	242.281	55	3
8	144.7085	155.8016	244.761	70	4
9	150.0372	170.1538	211.077	36	1
10	153.7716	153.3373	229.938	51	2
11	153.211	149.6926	237.365	66	3
12	148.7467	141.8364	243.755	80	4
13	146.0254	170.4213	205.005	46	1
14	151.6733	153.2622	223.831	61	2
15	153.065	144.8262	234.626	75	3
16	153.5694	142.9502	238.761	90	4
17	142.5744	169.8206	206.12	57	1
18	150.0305	153.9965	223.11	71	2
19	152.3877	146.6418	229.286	85	3
20	153.7989	145.7713	233.465	98	4
21	101.9598	217.4928	254.406	10	5
22	98.76084	191.3989	254.973	20	6
23	99.03312	190.0642	254.959	32	7
24	96.60589	168.079	254.987	43	8
25	120.3254	163.4895	234.785	25	5
26	113.4677	145.7175	250.332	36	6

ตารางที่ 3.7 ค่าชุดข้อมูลดิบในปริภูมิ HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ (ต่อ)

ลำดับเหตุการณ์ (n)	$(i_h)_n$	$(i_s)_n$	$(i_v)_n$	$(PPFD)_n$	กลุ่มเป้าหมาย
27	110.1666	146.8626	252.383	46	7
28	106.487	176.2654	253.609	57	8
29	128.0336	173.1189	217.926	40	5
30	119.5721	154.5831	244.33	51	6
31	115.4753	152.367	249.052	61	7
32	112.0714	153.3617	251.658	71	8
33	132.7504	183.0839	202.096	55	5
34	123.2143	159.4341	240.524	66	6
35	119.9274	149.6223	244.839	75	7
36	116.2715	149.6028	248.639	85	8
37	135.7944	183.9279	196.132	70	5
38	125.6879	162.9234	234.475	80	6
39	122.6527	154.0552	239.816	90	7
40	119.2887	147.9597	246.085	98	8
ค่าเฉลี่ย (Average)	123.74	158.8938	236.6409	56.7	
ส่วนเบี่ยงเบนมาตรฐาน ( $\sigma$ )	29.4996	18.4492	16.0937	23.0264	


จากตารางที่ 3.7 เป็นค่าชุดข้อมูลดิบในปริภูมิ HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ โดยที่ลำดับเหตุการณ์ที่ 1 จนถึง 20 เป็นการพิจารณาความแสงแอลอีดีสีแดงเป็นเป้าหมายหลัก ทำให้ทั้ง 20 เหตุการณ์จะประกอบไปด้วยกลุ่มเป้าหมายหรือชั้นข้อมูลเป้าหมาย (Target data class) ทั้งหมด 4 ชั้นข้อมูลเป้าหมายได้แก่ พิจารณาที่สีแดง 25% คือกลุ่มเป้าหมายที่ 1 พิจารณาที่สีแดง 50% คือกลุ่มเป้าหมายที่ 2 พิจารณาที่สีแดง 75% คือกลุ่มเป้าหมายที่ 3 และพิจารณาที่สีแดง 100% คือกลุ่มเป้าหมายที่ 4 ต่อมาลำดับเหตุการณ์ที่ 21 จนถึง 40 เป็นการพิจารณาความแสงแอลอีดีสีน้ำเงินเป็นเป้าหมายหลัก ทำให้ทั้ง 20 เหตุการณ์จะประกอบไปด้วยกลุ่มเป้าหมายหรือชั้นข้อมูลเป้าหมาย (Target data class) ทั้งหมด 4 ชั้นข้อมูลเป้าหมายได้แก่ พิจารณาที่สีแดง 25% คือกลุ่มเป้าหมายที่ 5 พิจารณาที่สีแดง 50% คือกลุ่มเป้าหมายที่ 6 พิจารณาที่สีแดง 75% คือกลุ่มเป้าหมายที่ 7 และพิจารณาที่สีแดง 100% คือกลุ่มเป้าหมายที่ 8

ในท้ายที่สุด ค่าชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ จะนำมาหาสมการเพื่อทำการแปลงชุดข้อมูลและพล็อตเป็นกราฟเพื่อพิจารณาถึงความสัมพันธ์ของชุดข้อมูล ซึ่งเป็นไปตามรูปที่ 3.14 คือกราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดง และตามรูปที่ 3.15 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีน้ำเงิน



รูปที่ 3.14 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง

กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี HSV จาก  
ภาพถ่ายแอลอีดีสีน้ำเงิน



รูปที่ 3.15 กราฟความสัมพันธ์ของชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่า  
คุณลักษณะเฉพาะจากภาพถ่ายแอลอีดีสีน้ำเงินทั้งสี่ดวง

## 2. ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะ จากภาพถ่ายแอลอีดีสีแดงและสีน้ำเงิน

จากค่าเฉลี่ยตามสมการที่ 3.78, 3.79, 3.80, 3.81 และค่าส่วนเบี่ยงเบนมาตรฐาน  
ตามสมการที่ 3.82, 3.83, 3.84, 3.85 ผู้วิจัยนำค่าที่ได้เหล่านี้มาทำการปรับขนาดด้วยเทคนิคการ  
กำหนดมาตรฐาน (Standardization) ของชุดข้อมูลตามสมการที่ 3.86, 3.87, 3.88, และ 3.89  
ตามลำดับ

$$STD(i_h)_n = \frac{(i_h)_n - Avg(i_h)}{\sigma(i_h)} \quad (3.86)$$

จากสมการที่ 3.86 เป็นค่าการกำหนดมาตรฐานเฉพาะค่าเฉลี่ยในปริภูมิย่อย  
Hue ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจากผลต่างระหว่างค่าเฉลี่ยที่อยู่ในปริภูมิย่อย Hue กับ  
ค่าเฉลี่ยเฉพาะค่าเฉลี่ยในปริภูมิย่อย Hue และหารด้วยค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าเฉลี่ยใน  
ปริภูมิย่อย Hue ซึ่งค่าการกำหนดมาตรฐานเป็นไปตามตารางที่ 3.8

$$STD(i_s)_n = \frac{(i_s)_n - Avg(i_s)}{\sigma(i_s)} \quad (3.87)$$

จากสมการที่ 3.87 เป็นค่าการกำหนดมาตรฐานเฉพาะค่าความบริสุทธิ์ของสีใน ปริภูมิย่อย Saturation ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจากผลต่างระหว่างค่าความบริสุทธิ์ของสี ที่อยู่ในปริภูมิย่อย Saturation กับค่าเฉลี่ยเฉพาะค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation และหารด้วยค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะค่าความบริสุทธิ์ในปริภูมิย่อย Saturation ซึ่งค่าการกำหนด มาตรฐานเป็นไปตามตารางที่ 3.8

$$STD(i_v)_n = \frac{(i_v)_n - Avg(i_v)}{\sigma(i_v)} \quad (3.88)$$

จากสมการที่ 3.88 เป็นค่าการกำหนดมาตรฐานเฉพาะค่าความสว่างของสีในปริภูมิ ย่อย Value ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจากผลต่างระหว่างค่าความสว่างของสีที่อยู่ใน ปริภูมิย่อย Value กับค่าเฉลี่ยเฉพาะค่าความสว่างของสีในปริภูมิย่อย Value และหารด้วยค่าส่วน เบี่ยงเบนมาตรฐานเฉพาะค่าความสว่างของสีในปริภูมิย่อย Value ซึ่งค่าการกำหนดมาตรฐาน เป็นไปตามตารางที่ 3.8

$$STD(PPFD)_n = \frac{(PPFD)_n - Avg(PPFD)}{\sigma(PPFD)} \quad (3.89)$$

จากสมการที่ 3.89 เป็นค่าการกำหนดมาตรฐานค่าระดับความเข้มแสงโดยความ หนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) โดยที่เกิดจาก ผลต่างระหว่างค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) กับค่าเฉลี่ยระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) และหารด้วยค่าส่วนเบี่ยงเบนมาตรฐานเฉพาะของค่าระดับความเข้มแสง โดยความ หนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ซึ่งค่าการกำหนดมาตรฐานเป็นไปตาม ตารางที่ 3.8

ตารางที่ 3.8 ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ใน  
 ปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์

ลำดับ เหตุการณ์ (n)	$STD(i_h)_n$	$STD(i_s)_n$	$STD(i_v)_n$	$STD(PPFD)_n$	กลุ่มเป้าหมาย
1	-2.56525	0.837693	-0.03503	-1.85439	1
2	-2.20659	-0.34481	0.459057	-1.15954	2
3	-2.22972	-1.28731	0.723787	-0.46468	3
4	-2.23043	-2.70333	0.976773	0.186742	4
5	1.00147	0.413529	-1.31587	-1.37668	1
6	0.926372	-0.65222	0.210446	-0.72525	2
7	0.940549	-0.51437	0.350475	-0.07383	3
8	0.710805	-0.16761	0.504575	0.577598	4
9	0.891441	0.610322	-1.58847	-0.89897	1
10	1.018032	-0.30118	-0.41648	-0.24754	2
11	0.999029	-0.49874	0.044984	0.403884	3
12	0.847692	-0.92456	0.442046	1.011882	4
13	0.755446	0.624821	-1.96574	-0.46468	1
14	0.946901	-0.30525	-0.79598	0.186742	2
15	0.99408	-0.76251	-0.1252	0.79474	3
16	1.011178	-0.86419	0.131736	1.446166	4
17	0.63846	0.592262	-1.89645	0.013029	1
18	0.891215	-0.26545	-0.84078	0.621026	2
19	0.97112	-0.6641	-0.45703	1.229024	3
20	1.018956	-0.71128	-0.19734	1.793593	4
21	-0.73832	3.176239	1.103884	-2.02811	5
22	-0.84676	1.761869	1.139112	-1.59382	6
23	-0.83753	1.689523	1.138209	-1.07268	7
24	-0.91981	0.497861	1.139965	-0.59497	8
25	-0.11575	0.249097	-0.11531	-1.37668	5

ตารางที่ 3.8 ชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ (ต่อ)


ลำดับเหตุการณ์ (n)	$STD(i_h)_n$	$STD(i_s)_n$	$STD(i_v)_n$	$STD(PPFD)_n$	กลุ่มเป้าหมาย
26	-0.34822	-0.7142	0.850733	-0.89897	6
27	-0.46012	-0.65213	0.978173	-0.46468	7
28	-0.58486	0.94159	1.054319	0.013029	8
29	0.145546	0.771037	-1.16285	-0.72525	5
30	-0.14129	-0.23366	0.477764	-0.24754	6
31	-0.28017	-0.35378	0.771205	0.186742	7
32	-0.39555	-0.29986	0.933095	0.621026	8
33	0.305441	1.311174	-2.14652	-0.07383	5
34	-0.01782	0.029281	0.24129	0.403884	6
35	-0.12924	-0.50254	0.509411	0.79474	7
36	-0.25317	-0.5036	0.745531	1.229024	8
37	0.408628	1.356918	-2.51708	0.577598	5
38	0.066028	0.218415	-0.1346	1.011882	6
39	-0.03686	-0.26227	0.197304	1.446166	7
40	-0.1509	-0.59267	0.586849	1.793593	8

จากตารางที่ 3.8 เป็นค่าชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ โดยที่ค่าชุดข้อมูลเหล่านี้จะถูกปรับขนาดลงให้เหลืออยู่ในช่วง  $[-3.5, 3]$  ซึ่งค่าสูงสุด (Max) ของชุดข้อมูลมีค่าเท่ากับ 3.1762 และค่าต่ำสุด (Min) ของชุดข้อมูลมีค่าเท่ากับ -2.7033 เมื่อชุดข้อมูลเหล่านี้ถูกปรับขนาดลง ทำให้สามารถพิจารณาถึงรายละเอียดของชุดข้อมูลได้ชัดเจนยิ่งขึ้น รวมถึงทำให้ช่วงข้อมูลลดความซับซ้อนของชุดข้อมูลในเรื่องของมิติหรือจำนวนค่าคุณลักษณะที่มีความสัมพันธ์กันมากยิ่งขึ้น ซึ่งเป็นไปตามรูปที่ 3.16 คือกราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง และตามรูปที่ 3.17 คือกราฟ




ความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายอัลตราอัลตราสโตนิกเงินทั้งสี่ดวง

กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดใน  
ปริภูมิสี HSV จากภาพถ่ายอัลตราอัลตราสโตนิกเงินทั้งสี่ดวง



รูปที่ 3.16 กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายอัลตราอัลตราสโตนิกเงินทั้งสี่ดวง

กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดใน  
ปริภูมิสี HSV จากภาพถ่ายแอตลีตีสีน้ำเงิน



รูปที่ 3.17 กราฟความสัมพันธ์ของชุดข้อมูลดิบที่ถูกปรับขนาดด้วยเทคนิคการกำหนดมาตรฐาน (Standardization) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายแอตลีตีสีน้ำเงินทั้งสี่ดวง

3. ชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพถ่ายแอตลีตีสีแดงและสีน้ำเงิน

ในส่วนนี้คือส่วนสุดท้ายก่อนนำชุดข้อมูลที่เกิดจากกระบวนการสกัดค่าคุณลักษณะเฉพาะในปริภูมิสี HSV เข้าสู่โครงข่ายประสาทเทียม ส่วนนี้จะถูกเรียกว่าชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) โดยหลักการในการแปลงข้อมูลด้วยเทคนิคนี้ อันดับแรกจำเป็นต้องหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ตามสมการที่ 3.90 และ 3.91 อันดับที่สองจะหาค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ตามสมการที่ 3.92 และ 3.93 เพื่อหาค่าลักษณะเฉพาะ (Eigenvalues) และเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ที่ท้ายที่สุดทำการแปลงชุดข้อมูลใหม่ด้วยผลคูณเมทริกซ์ระหว่างเวกเตอร์ลักษณะเฉพาะกับชุดข้อมูลเดิมที่จัดรูปแบบใหม่ในรูปแบบของเมทริกซ์ตามสมการที่ 3.98, 3.99, 3.100, 3.101 และ 3.102 ตามลำดับ

$$Cov(x,y) = \sum_{n=1}^N \frac{[(x)_n - Avg(x)][(y)_n - Avg(y)]}{(N - 1)} \quad (3.90)$$

จากสมการที่ 3.90 เป็นนัยคือตัวอย่างการหาค่าความแปรปรวนร่วม (Covariance) ซึ่งเกิดจากผลรวมระหว่างตัวแปร  $x$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $x$  และคูณด้วยตัวแปร  $y$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $y$  และสุดท้ายหารด้วยจำนวนทั้งหมดลบด้วยหนึ่ง โดยผู้วิจัยจะนำค่าชุดข้อมูลทั้งหมด จำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยค่าเฉลี่ยสีในปริภูมิย่อย Hue ค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation ค่าความสว่างของสีในปริภูมิย่อย Value และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ ( $n$ ) ที่ได้มาแทนในตัวแปรแทนตัวแปร  $x$  และ  $y$  ในการหาค่าจริงตามสมการที่ 3.91

$$\text{Covariance matrix} = \begin{bmatrix} Cov(i_r, i_r) & Cov(i_r, i_g) & Cov(i_r, i_b) & Cov(i_r, PPFD) \\ Cov(i_g, i_r) & Cov(i_g, i_g) & Cov(i_g, i_b) & Cov(i_g, PPFD) \\ Cov(i_b, i_r) & Cov(i_b, i_g) & Cov(i_b, i_b) & Cov(i_b, PPFD) \\ Cov(PPFD, i_r) & Cov(PPFD, i_g) & Cov(PPFD, i_b) & Cov(PPFD, PPFD) \end{bmatrix} \quad (3.91)$$

จากสมการที่ 3.91 เป็นการหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ซึ่งหาได้จากสมการที่ 3.90 ที่ประยุกต์ใช้ร่วมกับชุดข้อมูลจำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยค่าเฉลี่ยสีในปริภูมิย่อย Hue ค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation ค่าความสว่างของสีในปริภูมิย่อย Value และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทำให้ได้เมทริกซ์ขนาด  $4 \times 4$  และสมการความแปรปรวนร่วม (Covariance) จำนวน 16 สมการ ในท้ายที่สุดผู้วิจัยสามารถหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ได้ตามตารางที่ 3.9 ดังนี้

ตารางที่ 3.8 ค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) สำหรับชุดข้อมูลในปริภูมิสี HSV

Covariance matrix				
	$i_h$	$i_s$	$i_v$	PPFD
$i_h$	870.2271	-15.6294	-236.237	282.7271
$i_s$	-15.6294	340.3721	-65.1918	-221.309
$i_v$	-236.237	-65.1918	259.006	-14.5741
PPFD	282.7271	-221.309	-14.5741	530.2154

จากตารางที่ 3.9 เป็นค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ซึ่งจะนำค่าที่ได้เหล่านี้ ไปหาค่าสหสัมพันธ์ (Correlation) หรือ ค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ตามสมการที่ 3.92 และ 3.93 ตามลำดับ

$$\text{Corr}(x, y) = \frac{\text{Cov}(x, y)}{\sigma(x)\sigma(y)} \quad (3.92)$$

จากสมการที่ 3.92 เป็นยกตัวอย่างการหาค่าความสัมพันธ์ (Correlation) ซึ่งเกิดจากผลรวมระหว่างตัวแปร  $x$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $x$  และคูณด้วยตัวแปร  $y$  จำนวนที่  $n$  ลบด้วยค่าเฉลี่ย  $y$  และสุดท้ายหารด้วยจำนวนทั้งหมดลบด้วยหนึ่ง โดยผู้วิจัยจะนำค่าชุดข้อมูลทั้งหมดจำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยค่าเฉลี่ยสีในปริภูมิย่อย Hue ค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation ค่าความสว่างของสีในปริภูมิย่อย Value และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ ( $n$ ) ที่ได้มาแทนในตัวแปรแทนตัวแปร  $x$  และ  $y$  ในการหาค่าจริงตามสมการที่ 3.93

$$\text{Correlation matrix} = \begin{bmatrix} \frac{\text{Cov}(i_r, i_r)}{\sigma(i_r)\sigma(i_r)} & \frac{\text{Cov}(i_r, i_g)}{\sigma(i_r)\sigma(i_g)} & \frac{\text{Cov}(i_r, i_b)}{\sigma(i_r)\sigma(i_b)} & \frac{\text{Cov}(i_r, \text{PPFD})}{\sigma(i_r)\sigma(\text{PPFD})} \\ \frac{\text{Cov}(i_g, i_r)}{\sigma(i_g)\sigma(i_r)} & \frac{\text{Cov}(i_g, i_g)}{\sigma(i_g)\sigma(i_g)} & \frac{\text{Cov}(i_g, i_b)}{\sigma(i_g)\sigma(i_b)} & \frac{\text{Cov}(i_g, \text{PPFD})}{\sigma(i_g)\sigma(\text{PPFD})} \\ \frac{\text{Cov}(i_b, i_r)}{\sigma(i_b)\sigma(i_r)} & \frac{\text{Cov}(i_b, i_g)}{\sigma(i_b)\sigma(i_g)} & \frac{\text{Cov}(i_b, i_b)}{\sigma(i_b)\sigma(i_b)} & \frac{\text{Cov}(i_b, \text{PPFD})}{\sigma(i_b)\sigma(\text{PPFD})} \\ \frac{\text{Cov}(\text{PPFD}, i_r)}{\sigma(\text{PPFD})\sigma(i_r)} & \frac{\text{Cov}(\text{PPFD}, i_g)}{\sigma(\text{PPFD})\sigma(i_g)} & \frac{\text{Cov}(\text{PPFD}, i_b)}{\sigma(\text{PPFD})\sigma(i_b)} & \frac{\text{Cov}(\text{PPFD}, \text{PPFD})}{\sigma(\text{PPFD})\sigma(\text{PPFD})} \end{bmatrix} \quad (3.93)$$

จากสมการที่ 3.93 เป็นการหาค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ซึ่งหาได้จากสมการที่ 3.92 ที่ประยุกต์ใช้ร่วมกับชุดข้อมูลจำนวน 4 ตัวแปร ซึ่งประกอบไปด้วยค่าเฉลี่ยสีในปริภูมิย่อย Hue ค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation ค่าความสว่างของสีในปริภูมิ

ข้อ Value และค่าระดับความเข้มแสงโดยความหนาแน่นของ โฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทำให้ได้เมทริกซ์ขนาด  $4 \times 4$  และสมการสหสัมพันธ์ (Correlation) จำนวน 16 สมการ ในท้ายที่สุดผู้วิจัยสามารถหาค่าเมทริกซ์ความแปรปรวนร่วม (Covariance matrix) ได้ตามตารางที่ 3.10 ดังนี้

ตารางที่ 3.9 ค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) สำหรับชุดข้อมูลในปริภูมิสี HSV

Correlation matrix				
	$i_h$	$i_s$	$i_v$	PPFD
$i_h$	1	-0.02872	-0.49759	0.416222
$i_s$	-0.02872	1	-0.21956	-0.52095
$i_v$	-0.49759	-0.21956	1	-0.03933
PPFD	0.416222	-0.52095	-0.03933	1

จากตารางที่ 3.10 เป็นค่าเมทริกซ์สหสัมพันธ์ (Correlation matrix) ซึ่งจะนำค่าที่ได้เหล่านี้ ไปหาค่าลักษณะเฉพาะ (Eigenvalues) และจากนั้นจึงหาค่าเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ซึ่งผู้วิจัยจะนำเสนอวิธีการหาค่าลักษณะเฉพาะ (Eigenvalues) และค่าเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ดังต่อไปนี้

Sol<sup>n</sup>

$$\det(A - \lambda I) = \begin{vmatrix} 1 & -0.02872 & -0.49759 & 0.416222 \\ -0.02872 & 1 & -0.21956 & -0.52095 \\ -0.49759 & -0.21956 & 1 & -0.03933 \\ 0.416222 & -0.52095 & -0.03933 & 1 \end{vmatrix} - \lambda \begin{vmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{vmatrix}$$

$$= \begin{vmatrix} 1 - \lambda & -0.02872 & -0.49759 & 0.416222 \\ -0.02872 & 1 - \lambda & -0.21956 & -0.52095 \\ -0.49759 & -0.21956 & 1 - \lambda & -0.03933 \\ 0.416222 & -0.52095 & -0.03933 & 1 - \lambda \end{vmatrix}$$

$$\begin{aligned}
&= (\lambda^4 - 4\lambda^3 - 5.2572\lambda^2 - 2.52787\lambda + 0.393217) \\
&= (\lambda - 1.72812)(\lambda - 1.47315)(\lambda - 0.470345)(\lambda - 0.328396)
\end{aligned}$$

Ans  $\lambda_1 = 1.72812, \lambda_2 = 1.47315, \lambda_3 = 0.470345, \lambda_4 = 0.328396$

วิธีการข้างต้นเป็นวิธีการหาค่าลักษณะเฉพาะ (Eigenvalues) จากวิธีการตัวกำหนด หรือเรียกว่าดีเทอร์มิแนนต์ (Determinant) โดยกำหนดให้ A แทนเป็นเมทริกซ์สหสัมพันธ์ (Correlation matrix) และลบด้วยค่าลักษณะเฉพาะ (Eigenvalues) ที่ผู้วิจัยต้องการหาค่าแทนด้วย  $\lambda$  และคูณด้วยเอกลักษณ์เมทริกซ์ที่แทนด้วย I จากนั้นสามารถหาค่าลักษณะเฉพาะ (Eigenvalues) โดยมีทั้งหมดจำนวน 4 ค่า ได้แก่  $\lambda_1 = 1.72812, \lambda_2 = 1.47315, \lambda_3 = 0.470345$  และ  $\lambda_4 = 0.328396$  ตามลำดับ ในท้ายที่สุดนำค่าลักษณะเฉพาะ (Eigenvalues) เหล่านี้ไปหาค่าเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) โดยสามารถได้ตามวิธีการที่นำเสนอ ดังต่อไปนี้

Sol''

จาก  $(A - \lambda I)\vec{X} = \vec{0}$

จะได้

$$\left( \begin{bmatrix} 1 & -0.02872 & -0.49759 & 0.416222 \\ -0.02872 & 1 & -0.21956 & -0.52095 \\ -0.49759 & -0.21956 & 1 & -0.03933 \\ 0.416222 & -0.52095 & -0.03933 & 1 \end{bmatrix} - \lambda I \right) \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$



$$(1-\lambda)X_1 - 0.02872X_2 - 0.49759X_3 + 0.416222X_4 = 0 \rightarrow (1)$$

$$-0.02872X_1 + (1-\lambda)X_2 - 0.21956X_3 - 0.52095X_4 = 0 \rightarrow (2)$$

$$-0.49759X_1 - 0.21956X_2 + (1-\lambda)X_3 - 0.03933X_4 = 0 \rightarrow (3)$$

$$0.416222X_1 - 0.52095X_2 - 0.03933X_3 + (1-\lambda)X_4 = 0 \rightarrow (4)$$

$$\text{แทน } \lambda_1 = 1.72812 \text{ ลงในสมการ (1)-(4) จะได้ } \vec{X}_1 = \begin{bmatrix} -0.59923 \\ 0.372176 \\ 0.331131 \\ -0.62671 \end{bmatrix}$$

$$\text{แทน } \lambda_2 = 1.47315 \text{ ลงในสมการ (1)-(4) จะได้ } \vec{X}_2 = \begin{bmatrix} -0.35568 \\ -0.61365 \\ 0.633042 \\ 0.310139 \end{bmatrix}$$

$$\text{แทน } \lambda_3 = 0.470345 \text{ ลงในสมการ (1)-(4) จะได้ } \vec{X}_3 = \begin{bmatrix} -0.41276 \\ -0.57328 \\ -0.64677 \\ -0.28751 \end{bmatrix}$$

$$\text{แทน } \lambda_4 = 0.328396 \text{ ลงในสมการ (1)-(4) จะได้ } \vec{X}_4 = \begin{bmatrix} -0.58655 \\ 0.395314 \\ -0.26701 \\ 0.654511 \end{bmatrix}$$

วิธีการข้างต้นเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) โดยกำหนดให้ A แทนเป็นเมทริกซ์สหสัมพันธ์ (Correlation matrix) และลบด้วยค่าลักษณะเฉพาะ (Eigenvalues) ด้วย  $\lambda$  และคูณด้วยเอกลักษณะเมทริกซ์ที่แทนด้วย I เหมือนเดิม แต่ที่เพิ่มจากเดิมคือเวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ที่แทนด้วย  $\vec{X}$  จากนั้นแทนค่าลักษณะเฉพาะ (Eigenvalues) โดยมีทั้งหมดจำนวน 4 ค่า ได้แก่  $\lambda_1 = 1.952723$ ,  $\lambda_2 = 1.37094$ ,  $\lambda_3 = 0.44512$  และ  $\lambda_4 = 0.231216$  ลงในสมการ (1), (2), (3) และ (4) ในท้ายที่สุดจะได้เวกเตอร์ลักษณะเฉพาะ (Eigenvectors) ตามวิธีการข้างต้น และทำการเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ซึ่งเป็นไปตามสมการที่ 3.94, 3.95, 3.96 และ 3.97 ตามลำดับ

$$(\bar{X}_1)^T = \begin{bmatrix} -0.59923 & 0.372176 & 0.331131 & -0.62671 \end{bmatrix} \quad (3.94)$$

$$(\bar{X}_2)^T = \begin{bmatrix} -0.35568 & -0.61365 & 0.633042 & 0.310139 \end{bmatrix} \quad (3.95)$$

$$(\bar{X}_3)^T = \begin{bmatrix} -0.41276 & -0.57328 & -0.64677 & -0.28751 \end{bmatrix} \quad (3.96)$$

$$(\bar{X}_4)^T = \begin{bmatrix} -0.58655 & 0.395314 & -0.26701 & 0.654511 \end{bmatrix} \quad (3.97)$$

$$X_n = \begin{bmatrix} STD(i_h)_n \\ STD(i_s)_n \\ STD(i_v)_n \\ STD(PPFD)_n \end{bmatrix} \quad (3.98)$$

จากสมการที่ 3.98 เป็นการจัดรูปแบบของชุดข้อมูลใหม่ให้อยู่ในรูปแบบของเมทริกซ์ขนาด  $4 \times 1$  ซึ่งประกอบไปด้วย ค่าการกำหนดมาตรฐานเฉพาะค่าเฉดสีในปริภูมิย่อย Hue ทั้ง 40 ลำดับเหตุการณ์ (n) ค่าการกำหนดมาตรฐานเฉพาะค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation ทั้ง 40 ลำดับเหตุการณ์ (n) ค่าการกำหนดมาตรฐานเฉพาะค่าความสว่างของสีในปริภูมิย่อย Value ทั้ง 40 ลำดับเหตุการณ์ (n) และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) ในท้ายที่สุดแล้วผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) จะเป็นไปตามสมการที่ 3.99, 3.100, 3.101 และ 3.102 ตามลำดับ

$$Y(i_h)_n = (\bar{X}_1)^T \times (X_n) \quad (3.99)$$

จากสมการที่ 3.99 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของค่าเฉดสีในปริภูมิย่อย Hue ทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_1$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.11

$$Y(i_s)_n = (\bar{X}_2)^T \times (X_n) \quad (3.100)$$



จากสมการที่ 3.100 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation ทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_2$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.11

$$Y(i_v)_n = (\bar{X}_3)^T \times (X_n) \quad (3.101)$$

จากสมการที่ 3.101 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของค่าการกำหนดมาตรฐานเฉพาะค่าความสว่างของสีในปริภูมิย่อย Value ทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_3$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.11

$$Y(\text{PPFD})_n = (\bar{X}_4)^T \times (X_n) \quad (3.102)$$

จากสมการที่ 3.102 เป็นผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ของค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ทั้ง 40 ลำดับเหตุการณ์ (n) โดยเกิดจากผลคูณเมทริกซ์ระหว่างเมทริกซ์สลับเปลี่ยน (Transpose of a matrix) ของเวกเตอร์ลักษณะเฉพาะ  $\bar{X}_4$  กับชุดข้อมูลใหม่ในรูปแบบของเมทริกซ์ ซึ่งค่าผลลัพธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) เป็นไปตามตารางที่ 3.11

ตารางที่ 3.10 ชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะ ทั้ง 40 เหตุการณ์


ลำดับเหตุการณ์ (n)	$Y(i_h)_n$	$Y(i_s)_n$	$Y(i_v)_n$	$Y(PPFD)_n$	กลุ่มเป้าหมาย
1	2.999503	-0.19893	1.134433	0.631445	1
2	2.072617	0.927417	1.144953	0.27647	2
3	1.38789	1.897094	1.323815	0.301556	3
4	0.536822	3.128465	1.784961	0.101014	4
5	-0.01915	-1.86993	0.596445	-0.97364	1
6	-0.27364	-0.02097	0.063941	-1.33208	2
7	-0.59272	0.180075	-0.2988	-0.89692	3
8	-0.68322	0.348588	-0.68972	-0.23987	4
9	-0.26963	-1.97596	0.568004	-0.44585	1
10	-0.7049	-0.5177	0.092995	-0.767	2
11	-1.02248	0.104452	-0.27166	-0.53081	3
12	-1.33984	0.859507	-0.3967	-0.31846	4
13	-0.57983	-2.04063	0.734968	0.02463	1
14	-1.06162	-0.59545	0.245278	-0.34132	2
15	-1.41899	0.281559	-0.12071	-0.33092	3
16	-1.79026	0.702562	-0.42295	-0.02338	4
17	-0.79829	-1.78702	0.61976	0.374546	1
18	-1.30045	-0.49374	0.149555	0.003286	2
19	-1.75066	0.153966	-0.0779	0.0943	3
20	-2.06471	0.505395	-0.40088	0.347765	4
21	3.261107	-1.61668	-1.64697	0.066508	5
22	2.539189	-0.55319	-0.93903	-0.15417	6
23	2.179829	-0.35102	-1.05061	0.153152	7
24	1.48682	0.55877	-0.47198	0.042532	8
25	0.986665	-0.61165	0.375372	-0.7039	5

ตารางที่ 3.11 ชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ (ต่อ)

ลำดับเหตุการณ์ (n)	$Y(i_h)_n$	$Y(i_s)_n$	$Y(i_v)_n$	$Y(PPFD)_n$	กลุ่มเป้าหมาย
26	0.787951	0.821867	0.261404	-0.89363	6
27	0.648136	1.038943	0.064723	-0.55324	7
28	1.041851	0.301686	-0.98404	0.442283	8
29	0.269215	-1.48598	0.458523	0.055243	5
30	0.311042	0.419308	-0.04556	-0.29908	6
31	0.174552	0.862864	-0.23403	-0.05922	7
32	0.0452	1.10799	-0.44688	0.270795	8
33	-0.35955	-2.29497	0.531793	0.863999	5
34	-0.15164	0.266377	-0.28161	0.221947	6
35	-0.43898	0.923314	-0.21653	0.261291	7
36	-0.55909	1.252205	-0.44234	0.554761	8
37	-0.93532	-2.39229	0.515349	1.346867	5
38	-0.637	0.071105	-0.35634	0.74584	6
39	-0.91652	0.747468	-0.37783	0.811789	7
40	-0.1509	-0.59267	0.586849	1.793593	8


จากตารางที่ 3.11 เป็นค่าชุดข้อมูลใหม่ที่ถูกแปลงด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิ HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะทั้ง 40 เหตุการณ์ โดยที่ค่าชุดข้อมูลใหม่เหล่านี้จะถูกแปลงข้อมูลอยู่ในช่วง  $[-2.4, 3.3]$  ซึ่งค่าสูงสุด (Max) ของชุดข้อมูลมีค่าเท่ากับ 3.2611 และค่าต่ำสุด (Min) ของชุดข้อมูลมีค่าเท่ากับ -2.3923 เมื่อชุดข้อมูลเหล่านี้ถูกแปลงขนาดให้เป็นข้อมูลใหม่ ทำให้สามารถพิจารณาถึงรายละเอียดของชุดข้อมูลได้ชัดเจนยิ่งขึ้น รวมถึงทำให้ช่วงข้อมูลลดความซับซ้อนของชุดข้อมูลในเรื่องของมิติหรือจำนวนค่าคุณลักษณะที่ความสัมพันธ์กันมากยิ่งขึ้น และส่งผลต่อประสิทธิภาพในการฝึกฝนและทดสอบของโครงข่ายประสาทเทียม ซึ่งเป็นไปตามรูปที่ 3.18 คือกราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component

Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง และตามรูปที่ 3.19 คือกราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีน้ำเงินทั้งสี่ดวง



รูปที่ 3.18 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงทั้งสี่ดวง

กราฟของชุดข้อมูลใหม่ในปริภูมิสี HSV จากภาพถ่าย  
แอลอีดีสีน้ำเงิน



รูปที่ 3.19 กราฟความสัมพันธ์ของชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะ เฉพาะจากภาพถ่ายแอลอีดีสีน้ำเงินทั้งสี่ดวง

### 3.4 การทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมในการทำนาย ความเข้มแสงแอลอีดี

ในหัวข้อนี้เป็นการนำผลการทดสอบการทำงานของโครงข่ายประสาทเทียมที่ทำการพัฒนา โดยทำการทดสอบแบ่งออกเป็นสี่ส่วน 3.4.1 การทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียม โดยใช้ชุดข้อมูลแบบไบนารีอย่างง่าย 3.4.2 การเปรียบเทียบทดสอบโครงข่ายประสาทเทียม โดยอินพุตชุดข้อมูลดิบและชุดข้อมูลใหม่ทั้งในปริภูมิสี RGB และ HSV เพื่อยืนยันความสามารถในการเรียนรู้และทดสอบโครงข่ายประสาทเทียมวิเคราะห์ความสามารถในการทำงานของอัลกอริทึม โดยการทดสอบดำเนินการ โปรแกรม Visual Studio Code 2019 3.4.3 นำเสนอผลการทดสอบการการทำนายด้วยเมทริกซ์คอนฟิวชัน (Confusion Matrix) และ 3.4.4 นำเสนอผลการทดสอบการเลือกสกัดลักษณะเฉพาะที่สำคัญสำหรับระบบตรวจจับความเข้มแสงแอลอีดีเพื่อนำไปใช้งานจริงได้อย่างมีประสิทธิภาพ

### 3.4.1 การทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมโดยใช้ชุดข้อมูลแบบไบนารีอย่างง่าย

การกำหนดชุดข้อมูลขาเข้าที่ใช้ทดสอบเป็นชุดข้อมูลแบบไบนารี (Binary) โดยมีค่าสองค่าได้แก่ 0 และ 1 ซึ่งใช้จำนวน 4 บิต เป็นชุดข้อมูลทั้งหมด 16 ชุดข้อมูล และกำหนดกลุ่มเป้าหมาย 4 กลุ่ม โดยจะแบ่งเป็นอัตราส่วนสำหรับชุดข้อมูลในการฝึกฝนต่อการทดสอบเป็น 70 : 30 และแต่ละโครงข่ายประสาทเทียมจะมีค่าพารามิเตอร์ที่แตกต่างกัน จึงได้ทำการปรับเปลี่ยนค่าพารามิเตอร์ในแต่ละโครงข่ายประสาทเทียม เพื่อดูการตอบสนองในการทำงานแล้วทำการวิเคราะห์ประสิทธิภาพในการทำงาน ซึ่งการกำหนดชุดข้อมูลขาเข้าสำหรับการฝึกฝนเป็นไปตามตารางที่ 3.12

ตารางที่ 3.12 ชุดข้อมูลสำหรับการฝึกฝนให้กับโครงข่ายประสาทเทียมอย่างง่าย

ลำดับที่	ชุดข้อมูลขาเข้า				กลุ่มเป้าหมาย
1	0	0	0	0	1
2	0	0	0	1	1
3	0	0	1	0	1
4	0	0	1	1	1
5	0	1	0	0	2
6	0	1	0	1	2
7	0	1	1	0	2
8	0	1	1	1	2
9	1	0	0	0	3
10	1	0	0	1	3
11	1	0	1	0	3
12	1	0	1	1	3
13	1	1	0	0	4
14	1	1	0	1	4
15	1	1	1	0	4
16	1	1	1	1	4

โครงข่ายประสาทเทียมที่เตรียมไว้ ได้แก่ 1. Perceptron Learning Model 2. Logistic Regression Model 3. Support Vector Machine with Linear Kernel Model 4. Support Vector Machine with Radial Basis Function Kernel Model 5. Decision Tree Model 6. Random Forest Model และ 7. K-Nearest Neighbors Model ซึ่งโครงข่ายประสาทเทียมเหล่านี้จะมีการกำหนดพารามิเตอร์ เพื่อการตอบสนองของโครงข่ายประสาทเทียมและพิจารณาจากค่าความถูกต้อง (Accuracy) ในแต่ละพารามิเตอร์ที่กำหนด จากนั้นเลือกค่าพารามิเตอร์ในแต่ละโครงข่ายประสาทเทียมที่ดีที่สุดเพื่อนำมาใช้กับชุดข้อมูลที่ถูกแยกแบบออกแบบไว้ ซึ่งการกำหนดพารามิเตอร์ในแต่ละโครงข่ายประสาทเทียม จะมีการกำหนดดังนี้

1. Perceptron Learning Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่  $\eta_0$  และ Random\_state
2. Logistic Regression Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่ C และ Random\_state
3. Support Vector Machine with Linear Kernel Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่ C และ Random\_state
4. Support Vector Machine with Radial Basis Function Kernel Model Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 3 พารามิเตอร์ ได้แก่ Gamma, C และ Random\_state
5. Decision Tree Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่ Max\_depth และ Random\_state
6. Random Forest Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 3 พารามิเตอร์ ได้แก่ N\_estimators, Max\_depth และ Random\_state
7. K-Nearest Neighbors Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่ N\_neighbors และ P

ตารางที่ 3.13 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Perceptron Learning

พารามิเตอร์		ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)
eta0	Random_state		
0.1	1	100	100
1	1	90.90	80
10	1	90.90	80
0.1	5	100	80
1	5	100	80
10	5	100	60
0.1	10	90.90	60
1	10	90.90	60
10	10	90.90	60

ตารางที่ 3.14 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Logistic Regression

พารามิเตอร์		ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)
C	Random_state		
0.1	1	100	60
1	1	100	80
10	1	100	100
0.1	5	80.82	80
1	5	100	80
10	5	100	80
0.1	10	100	60
1	10	80.82	60
10	10	90.90	80



ตารางที่ 3.15 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Support Vector Machine with Linear Kernel

พารามิเตอร์		ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)
C	Random_state		
0.1	1	100	80
1	1	100	100
10	1	100	80
0.1	5	100	80
1	5	80.82	80
10	5	90.90	80
0.1	10	100	80
1	10	100	80
10	10	90.90	80

ตารางที่ 3.16 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Support Vector Machine with Radial Basis Function Kernel

พารามิเตอร์			ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)
Gamma	C	Random_state		
0.1	0.1	1	100	80
0.1	1	1	100	100
0.1	10	1	100	80
10	0.1	5	100	80
10	1	5	100	80
10	10	5	100	80
100	0.1	10	100	80
100	1	10	100	60
100	10	10	100	60

ตารางที่ 3.17 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Decision Tree

พารามิเตอร์		ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)
Max_depth	Random_state		
1	1	81.82	80
10	1	100	100
20	1	100	80
1	5	90.90	80
10	5	100	80
20	5	100	80
1	10	100	80
10	10	90.90	80
20	10	90.90	80

ตารางที่ 3.18 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม Random Forest

พารามิเตอร์			ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)
N_estimators	Max_depth	Random_state		
10	1	1	90.90	80
10	10	1	90.90	80
10	20	1	90.90	80
20	1	5	90.90	80
20	10	5	100	80
20	20	5	100	80
100	1	10	100	80
100	10	10	100	100
100	20	10	90.90	100

ตารางที่ 3.19 ผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ของโครงข่ายประสาทเทียม K-Nearest Neighbors Model

พารามิเตอร์		ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)
N_neighbors	P		
1	1	81.82	80
3	1	90.90	100
9	1	100	80
1	2	90.90	80
3	2	100	100
9	2	100	80
1	3	100	80
3	3	90.90	80
9	3	90.90	80

จากผลการทดสอบกับชุดข้อมูลขาเข้าสำหรับการฝึกฝนและการทดสอบ จากการปรับพารามิเตอร์ตามตารางที่ 3.12 จนถึง 3.19 แสดงให้เห็นว่าการปรับพารามิเตอร์มีผลตอบสนองต่อค่าความถูกต้องของโครงข่ายประสาทเทียม ซึ่งหลักเกณฑ์การพิจารณา ซึ่งพิจารณาจากค่าความถูกต้องของกลุ่มที่เคยฝึกฝนและของกลุ่มใหม่สูงสุด ซึ่งสามารถพิจารณาในแต่ละโครงข่ายประสาทเทียมได้ดังนี้

1. Perceptron Learning Model มีค่าความถูกต้องของกลุ่มที่เคยฝึกฝนและของกลุ่มใหม่ที่ 100% จากการกำหนดค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่  $\eta_0 = 0.1$  และ  $\text{Random\_state} = 1$

2. Logistic Regression Model มีค่าความถูกต้องของกลุ่มที่เคยฝึกฝนและของกลุ่มใหม่ที่ 100% จากการกำหนดค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่  $C = 10$  และ  $\text{Random\_state} = 1$

3. Support Vector Machine with Linear Kernel Model มีค่าความถูกต้องของกลุ่มที่เคยฝึกฝนและของกลุ่มใหม่ที่ 100% จากการกำหนดค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่  $C = 1$  และ  $\text{Random\_state} = 1$

4. Support Vector Machine with Radial Basis Function Kernel Model Model มีค่าความถูกต้องของกลุ่มที่เคยฝึกฝนและของกลุ่มใหม่ที่ 100% จากการกำหนดค่าพารามิเตอร์ที่เกี่ยวข้อง 3 พารามิเตอร์ ได้แก่  $\text{Gamma} = 0.1$ ,  $C = 1$  และ  $\text{Random\_state} = 1$

5. Decision Tree Model มีค่าความถูกต้องของกลุ่มที่เคยฝึกฝนและของกลุ่มใหม่ที่ 100% จากการกำหนดค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่  $\text{Max\_depth} = 10$  และ  $\text{Random\_state} = 1$

6. Random Forest Model มีค่าความถูกต้องของกลุ่มที่เคยฝึกฝนและของกลุ่มใหม่ที่ 100% จากการกำหนดค่าพารามิเตอร์ที่เกี่ยวข้อง 3 พารามิเตอร์ ได้แก่  $N\_estimators = 100$ ,  $\text{Max\_depth} = 10$  และ  $\text{Random\_state} = 10$

7. K-Nearest Neighbors Model มีค่าพารามิเตอร์ที่เกี่ยวข้อง 2 พารามิเตอร์ ได้แก่  $N\_neighbors = 3$  และ  $P = 2$

ในท้ายที่สุด จะนำโครงข่ายประสาทเทียมที่ได้จากการพิจารณาการกำหนดพารามิเตอร์เหล่านี้ไปทดสอบกับชุดข้อมูลที่ถูกออกแบบจากผู้วิจัย ซึ่งจะถูกนำเสนอในหัวข้อย่อยถัดไป

### 3.4.2 การเปรียบเทียบทดสอบโครงข่ายประสาทเทียมโดยอินพุตชุดข้อมูลดิบและชุดข้อมูลใหม่ทั้งในปริภูมิสี RGB และ HSV

ผู้วิจัยจะนำเสนอการกำหนดอินพุตเข้าทั้งหมด 4 ชุด ได้แก่ 1. ชุดข้อมูลดิบในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงินตามหัวข้อที่ 3.3.3 ตอนที่ 1 2. ชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงินตามหัวข้อที่ 3.3.3 ตอนที่ 3 3. ชุดข้อมูลดิบในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงินตามหัวข้อที่ 3.3.4 ตอนที่ 1 และ 4. ชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV จากกระบวนการสกัดค่าคุณลักษณะเฉพาะจากภาพย่อยแอลอีดีสีแดงและสีน้ำเงินตามหัวข้อที่ 3.3.4 ตอนที่ 3 ซึ่งนำชุดข้อมูลเหล่านี้มาเปรียบเทียบกัน เพื่อสังเกตประสิทธิภาพของชุดข้อมูลมีผลต่อการเรียนรู้และความถูกต้องในการทำนายของโครงข่ายประสาทเทียม รวมถึงนำเสนอการคัดเลือกโครงข่ายประสาทเทียมเหล่านี้ เพื่อให้เหมาะสมต่อชุดข้อมูลที่ผู้วิจัยสกัดค่าคุณลักษณะเฉพาะ

การเปรียบเทียบค่าความถูกต้อง (Accuracy) ในแต่ละตาราง จะเลือกใช้ชุดข้อมูลจำนวน 160 ชุดข้อมูล ซึ่งเดิมที่ที่ผู้วิจัยนำเสนอการนำมาซึ่งชุดข้อมูลต่าง ๆ มีจำนวน 40 ชุดข้อมูล

ผู้วิจัยจะทำการเพิ่มชุดข้อมูลอีกจำนวน 120 ชุดข้อมูล เป็นจำนวนทั้งหมด 160 ชุดข้อมูล ซึ่งชุดข้อมูลที่นำมาเพิ่มจำนวน 120 ชุดข้อมูล เป็นชุดข้อมูลคนละชุดกับ 40 ชุดข้อมูลที่นำเสนอในตอนแรก โดยเหตุผลที่ผู้วิจัยนำชุดข้อมูลมาเพิ่มเป็นชุดข้อมูลขาเข้าสำหรับโครงข่ายประสาทเทียมเพิ่มเพิ่มประสิทธิภาพแต่โครงข่ายประสาทเทียมในเรื่องของความถูกต้องของการฝึกฝนและตรวจจับความเข้มแสงแอลอีดี รวมถึงเป็นชุดข้อมูลที่เพียงพอต่อการตรวจสอบความถูกต้อง (Validation) หรือการทดสอบ (Testing)

โดยสรุปแล้วผู้วิจัยกำหนดชุดข้อมูลขาเข้าทั้งหมด 160 ชุดข้อมูล โดยแบ่งชุดข้อมูลออกเป็น 2 ส่วน ส่วนแรกคือชุดข้อมูลสำหรับการฝึกฝน (Training) จะแบ่งในส่วนนี้เป็นจำนวน 112 ชุดข้อมูล คิดเป็น 70% จากชุดข้อมูลทั้งหมด และส่วนที่สองคือชุดข้อมูลสำหรับการทดสอบ (Testing) จะแบ่งในส่วนนี้เป็นจำนวน 48 ชุดข้อมูล คิดเป็น 30% จากชุดข้อมูลทั้งหมด จากนั้นผู้วิจัยใช้เลือกใช้โครงข่ายประสาทเทียมทั้ง 7 ในการทดสอบและเปรียบเทียบกันเพื่อหาโครงข่ายประสาทเทียมที่เหมาะสมกับชุดข้อมูลที่ถูกรวบรวม ซึ่งโครงข่ายประสาทเทียมที่เลือก ได้แก่ 1. Perceptron Learning Model 2. Logistic Regression Model 3. Support Vector Machine with Linear Kernel Model 4. Support Vector Machine with Radial Basis Function Kernel Model 5. Decision Tree Model 6. Random Forest Model และ 7. K-Nearest Neighbors Model

จากนั้นจะดูนำเสนอตามตารางที่ 3.20 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลดิบในปริภูมิสี RGB ตารางที่ 3.21 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB ตารางที่ 3.22 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลดิบในปริภูมิสี HSV และตารางที่ 3.23 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียมจากชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV ดังนี้

ตารางที่ 3.20 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียม จากชุดข้อมูลดิบในปริภูมิสี RGB

ลำดับ ที่	โครงข่าย ประสาท เทียม	จำนวนชุด ข้อมูลที่ ทดสอบ ผิดพลาด	ความถูกต้อง ของกลุ่มที่เคย ฝึกฝน (%)	ความ ถูกต้องของ กลุ่มใหม่ (%)	ค่าเฉลี่ยความถูก ต้องระหว่างกลุ่มที่ ฝึกฝนและกลุ่มใหม่ (%)
1	Perceptron learning	37	24.11	22.92	<b>23.51</b>
2	Logistic regression	19	58.93	60.42	<b>59.67</b>
3	SVM with Linear kernel	11	77.68	77.08	<b>77.38</b>
4	SVM with RBF kernel	42	100	12.50	<b>56.25</b>
5	Decision Tree	27	100	43.75	<b>71.87</b>
6	Random Forest	21	100	56.25	<b>78.12</b>
7	K-Nearest Neighbors	19	79.46	60.42	<b>69.94</b>

ตารางที่ 3.21 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียม จากชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี RGB

ลำดับที่	โครงข่ายประสาทเทียม	จำนวนชุดข้อมูลที่ทดสอบผิดพลาด	ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)	ค่าเฉลี่ยความถูกต้องระหว่างกลุ่มที่เคยฝึกฝนและกลุ่มใหม่ (%)
1	Perceptron learning	29	45.53	39.58	<b>42.55</b>
2	Logistic regression	21	55.36	56.25	<b>55.80</b>
3	SVM with Linear kernel	18	70.53	62.50	<b>66.51</b>
4	SVM with RBF kernel	31	100	35.42	<b>67.71</b>
5	Decision Tree	23	100	52.08	<b>76.04</b>
6	Random Forest	25	99.11	47.92	<b>73.51</b>
7	K-Nearest Neighbors	20	75.89	58.33	<b>67.11</b>

ตารางที่ 3.22 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียม จากชุดข้อมูลดิบในปริภูมิสี HSV

ลำดับ ที่	โครงข่าย ประสาท เทียม	จำนวนชุด ข้อมูลที่ ทดสอบ ผิดพลาด	ความถูกต้อง ของกลุ่มที่เคย ฝึกฝน (%)	ความ ถูกต้องของ กลุ่มใหม่ (%)	ค่าเฉลี่ยความถูก ต้องระหว่างกลุ่มที่ ฝึกฝนและกลุ่มใหม่ (%)
1	Perceptron learning	39	22.32	18.75	<b>20.53</b>
2	Logistic regression	30	56.25	37.50	<b>46.87</b>
3	SVM with Linear kernel	20	75.89	58.33	<b>67.11</b>
4	SVM with RBF kernel	33	100	31.25	<b>65.62</b>
5	Decision Tree	17	100	64.58	<b>82.29</b>
6	Random Forest	13	100	72.92	<b>86.46</b>
7	K-Nearest Neighbors	26	82.14	45.83	<b>63.98</b>

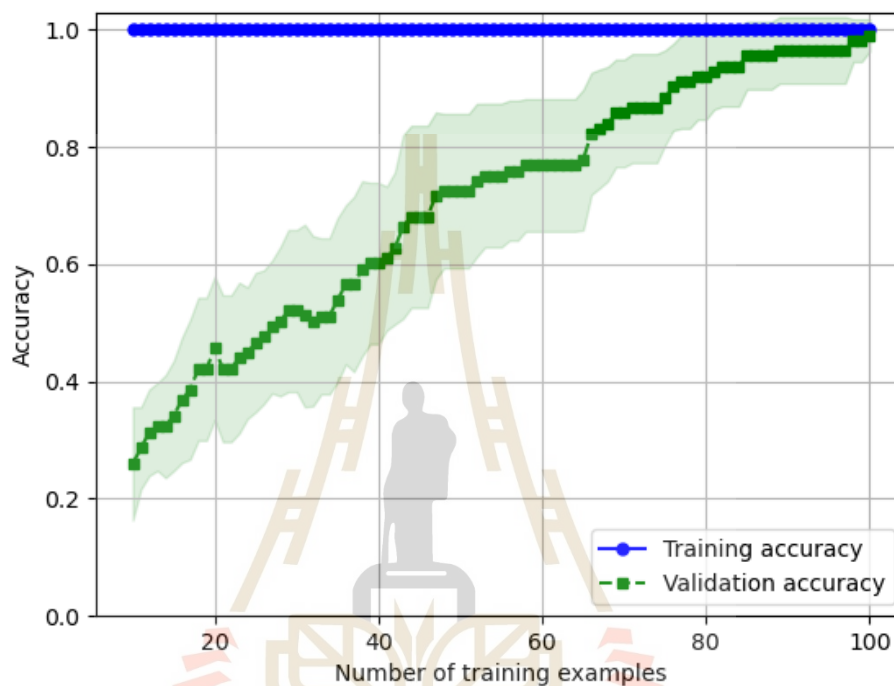


ตารางที่ 3.23 การเปรียบเทียบค่าความถูกต้อง (Accuracy) ของกลุ่มที่เคยฝึกฝน (Training) กลุ่มใหม่ (Testing) และจำนวนชุดข้อมูลที่ทดสอบผิดพลาดของแต่ละโครงข่ายประสาทเทียม จากชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์ห้อยค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV

ลำดับที่	โครงข่ายประสาทเทียม	จำนวนชุดข้อมูลที่ทดสอบผิดพลาด	ความถูกต้องของกลุ่มที่เคยฝึกฝน (%)	ความถูกต้องของกลุ่มใหม่ (%)	ค่าเฉลี่ยความถูกต้องระหว่างกลุ่มที่เคยฝึกฝนและกลุ่มใหม่ (%)
1	Perceptron learning	19	59.82	60.42	<b>60.12</b>
2	Logistic regression	12	82.14	75.00	<b>78.57</b>
3	SVM with Linear kernel	4	96.43	91.67	<b>94.05</b>
4	SVM with RBF kernel	6	100	87.50	<b>93.75</b>
5	Decision Tree	10	100	79.17	<b>89.585</b>
6	Random Forest	2	100	95.83	<b>97.91</b>
7	K-Nearest Neighbors	5	99.5	89.58	<b>94.54</b>

จากผลการทดสอบตามตารางที่ 3.20 3.21 3.22 และ 3.23 เมื่อเปรียบเทียบกันเห็นได้ชัดว่าชุดข้อมูลที่อยู่ในปริภูมิสี HSV ตามตารางที่ 3.22 และ 3.23 มีค่าความถูกต้อง (Accuracy) จากการทำนายด้วยโครงข่ายประสาทเทียมทั้ง 7 สูงกว่าชุดข้อมูลที่อยู่ในปริภูมิสี RGB ตามตารางที่ 3.20 และ 3.21 ดังนั้นการคัดเลือกจากค่าความถูกต้องจะเลือกเพียงชุดข้อมูลในปริภูมิสี HSV โดยจะแบ่งจากชุดข้อมูลดิบตามตารางที่ 3.22 และชุดข้อมูลใหม่ตามตารางที่ 3.23 จากนั้นทำการพิจารณาอีกครั้งจากผลตามตาราง พบว่าค่าความถูกต้อง (Accuracy) แสดงให้เห็นว่าโครงข่ายประสาทเทียม แรนด้อมฟอว์เรสต์ (Random Forest : RF) ตามตารางที่ 3.23 ลำดับที่ 6 สามารถทำนายข้อมูลใน

ระดับดีเยี่ยม มีความแม่นยำสูงสุด โดยการทดสอบกับชุดข้อมูลของกลุ่มที่เคยฝึกฝนมีความถูกต้อง 100% กลุ่มใหม่มีความถูกต้อง 95.83% โดยรวมโครงข่ายประสาทเทียมนี้มีความถูกต้อง 97.91 และ ยังมีความผิดพลาดน้อยมากที่สุด 2 จำนวน เห็นได้ชัดว่าชุดข้อมูลที่เตรียมไว้มีความเหมาะสมกับระบบ โครงข่ายประสาทเทียมเร็นด้อมฟอร์เรสต์ (Random Forest : RF) มากที่สุด



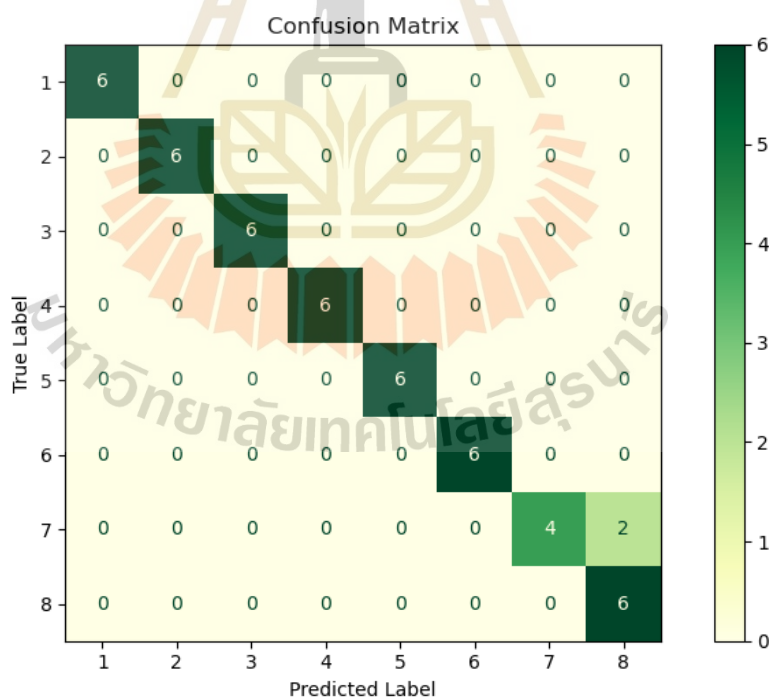
รูปที่ 3.20 กราฟแสดงประสิทธิภาพความถูกต้อง (Accuracy) ในส่วนของการฝึกฝน (Training) และการตรวจสอบความถูกต้อง (Validation) ของโครงข่ายประสาทเทียมเร็นด้อมฟอร์เรสต์ (Random Forest : RF) สำหรับชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV

ในการทดสอบ อย่างที่กล่าวไปก่อนหน้านี้ผู้วิจัยแบ่งชุดข้อมูลออกเป็นสองส่วน ได้แก่ ส่วนการฝึกฝน (Training) ใช้ชุดข้อมูลจำนวน 112 ชุดข้อมูลคิดเป็น 70% ส่วนการทดสอบ (Testing) ใช้ชุดข้อมูลจำนวน 48 ชุดข้อมูลคิดเป็น 30% เป้าหมายคือการทำนายหรือตรวจจับเปอร์เซ็นต์ของความเข้มแสงแอลอีดีสีแดงและสีน้ำเงิน

จากรูปที่ 3.20 จะเห็นว่าชัดเจนว่าโครงข่ายประสาทเทียมเร็นด้อมฟอร์เรสต์ (Random Forest : RF) กับชุดข้อมูลใหม่ในปริภูมิสี HSV ของผู้วิจัย มีค่าความถูกต้องในส่วนของการฝึกฝน (Training Accuracy) ที่เสถียรมาก ซึ่งมีค่าเท่ากับ 1.00 ตลอดจากชุดข้อมูลตัวอย่างในการ

ฝึกฝน (Number of Training Examples) ที่นำมาเปรียบเทียบ อย่างไรก็ตาม ดูเหมือนว่าค่าความถูกต้องในส่วนของการตรวจสอบความถูกต้อง (Validation Accuracy) จะมีค่าสูงสุดที่ค่าประมาณ 0.98 – 0.99 ซึ่งค่าจะไม่ยอมเพิ่มไปมากกว่านี้ โดยที่จากการประเมินค่าประสิทธิภาพความถูกต้องในส่วนของการฝึกฝนและการตรวจสอบความถูกต้อง สามารถวิเคราะห์ได้ว่าโครงข่ายประสาทเทียมมีปัญหาเรื่องค่าของชุดข้อมูลแต่ละค่าลักษณะเฉพาะ (Feature) มีความแปรปรวน (Variance) ซึ่งหมายถึงการที่โครงข่ายประสาทเทียมยังไม่สามารถทำนายหรือตรวจจับความเข้มแสงแอลอีดีได้ดีเยี่ยมถึงขั้นไม่สามารถผิดพลาดหรือหาที่ติได้เลย โดยผู้วิจัยสามารถวิเคราะห์ทางเลือกสำหรับการเพิ่มประสิทธิภาพสำหรับโครงข่ายประสาทเทียมเพื่อลดปัญหาความแปรปรวน (Variance) เช่น การเพิ่มชุดข้อมูลในส่วนของการฝึกฝน (Training) และในส่วนของการตรวจสอบความถูกต้อง (Validation) หรือการจัดชุดข้อมูลเข้าให้เป็นระเบียบเพิ่มขึ้น แต่ในที่สุดแล้วโครงข่ายประสาทเทียมเร็นด้อมฟอร์เรสต์ (Random Forest : RF) ที่ได้คัดเลือกมาจากการเปรียบเทียบแล้วพบว่าดีที่สุดแล้ว นั้นยังคงมีประสิทธิภาพและเหมาะสมที่สุดกับชุดข้อมูลที่ผู้วิจัยออกแบบ

### 3.4.3 ผลการทดสอบการการทำนายด้วยเมทริกซ์คอนฟิวชัน (Confusion Matrix)



รูปที่ 3.21 เมทริกซ์คอนฟิวชัน (Confusion Matrix) ของโครงข่ายประสาทเทียมเร็นด้อมฟอร์เรสต์ (Random Forest : RF) สำหรับชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV

จากรูปที่ 3.21 เป็นการแสดงผลค่าความถูกต้อง (Accuracy) ผ่านรูปแบบของเมทริกซ์คอนฟิวชันขนาด  $8 \times 8$  ซึ่งประกอบด้วยชุดข้อมูลในส่วนที่เรียกว่าการทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีทั้งหมด 48 ชุดข้อมูล ซึ่งแต่ละคลาสของเป้าหมายถูกแบ่งชุดข้อมูลออกเป็น 6 ชุดข้อมูล โดยลาเบลค่าจริง (True Label) และลาเบลที่ถูกทำนาย (Predicted Label) ประกอบไปด้วยเป้าหมายที่ตั้งค่าว่าเป็นจำนวนแปดคลาส ได้แก่คลาสเป้าหมายที่ 1 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีแดง 25% คลาสเป้าหมายที่ 2 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีแดง 50% คลาสเป้าหมายที่ 3 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีแดง 75% คลาสเป้าหมายที่ 4 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีแดง 100% คลาสเป้าหมายที่ 5 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีน้ำเงิน 25% คลาสเป้าหมายที่ 6 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีน้ำเงิน 50% คลาสเป้าหมายที่ 7 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีน้ำเงิน 75% และคลาเป้าหมายที่ 8 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีน้ำเงิน 100% โดยสรุปแล้วประสิทธิภาพโดยรวมของโครงข่ายประสาทเทียมแรนด้อมฟอรัลเรสต์ (Random Forest : RF) มีค่าความถูกต้อง (Accuracy) ที่ 95.83% และผิดพลาดไปเพียง 4.17% สิ่งที่น่าสนใจอยู่ที่ความผิดพลาดซึ่งเกิดจากการทำนายหรือการตรวจจับความเข้มแสงแอลอีดีที่ผิดพลาดของโครงข่ายประสาทเทียม ซึ่งคลาเป้าหมายที่ 7 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีน้ำเงิน 75% โครงข่ายประสาทเทียมทำนายได้เพียง 4 ชุดข้อมูล ซึ่งอีก 2 ชุดข้อมูล ทำนายพลาดไปเป็นคลาเป้าหมายที่ 8 คือทำนายหรือตรวจจับความเข้มแสงแอลอีดีสีน้ำเงิน 100% โดยที่ทำให้คลาเป้าหมายที่ 8 จะมีการทำนายเป็นจำนวนทั้งหมด 8 ชุดข้อมูล ซึ่งมีการทำนายเกินจำนวน 2 ชุดข้อมูล ซึ่งทำให้ทราบได้ว่าคลาเป้าหมายที่ 7 และคลาเป้าหมายที่ 8 มีค่าลักษณะเฉพาะที่มีความสัมพันธ์ใกล้เคียงกัน ซึ่งยากต่อการที่จะทำให้โครงข่ายประสาทเทียมทำการทำนาย โดยท้ายที่สุดแล้วการวิเคราะห์ถึงชุดข้อมูลที่โครงข่ายข่ายประสาทเทียมทำนายผิดพลาดจากผลการทดสอบด้วยเมทริกซ์คอนฟิวชัน (Confusion Matrix) เป็นเพียงการพิจารณาและประเมินประสิทธิภาพขั้นต้นเท่านั้น แต่เท่านี้ก็เพียงพอต่อการประเมินความสามารถของโครงข่ายประสาทเทียมที่นำมาใช้ร่วมกับชุดข้อมูลของผู้วิจัย ดังนั้นเพื่อการวิเคราะห์และประเมินประสิทธิภาพเพิ่มสูงขึ้นอีก ผู้วิจัยจำเป็นต้องพิจารณาเพิ่มเติมจากเดิมคือค่าความถูกต้อง (Accuracy) โดยที่เพิ่มเติมคือค่ารู้จำ (Recall) และ ค่าความแม่นยำ (Precision) เป็นต้น

ตารางที่ 3.24 การประเมินประสิทธิภาพของโครงข่ายประสาทเทียมแรนด้อมฟอเรสต์  
(Random Forest : RF) สำหรับชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบ  
หลัก (Principal Component Analysis) ในปริภูมิสี HSV ด้วยค่าความแม่นยำ  
(Precision) และ ค่ารู้จำ (Recall)

ลำดับเป้าหมายที่	ค่าความแม่นยำ (Precision)	ค่ารู้จำ (Recall)	จำนวนชุดข้อมูลที่ทำนายได้
1	100%	100%	6
2	100%	100%	6
3	100%	100%	6
4	100%	100%	6
5	100%	100%	6
6	100%	100%	6
7	100%	66.67%	4
8	75%	100%	8

จากตารางที่ 3.24 สามารถประเมินประสิทธิภาพของโครงข่ายประสาทเทียม  
แรนด้อมฟอเรสต์ (Random Forest : RF) สำหรับชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์  
องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV ได้ด้วยค่าความแม่นยำ  
(Precision) และ ค่ารู้จำ (Recall) โดยจะสามารถประเมินได้ดังนี้

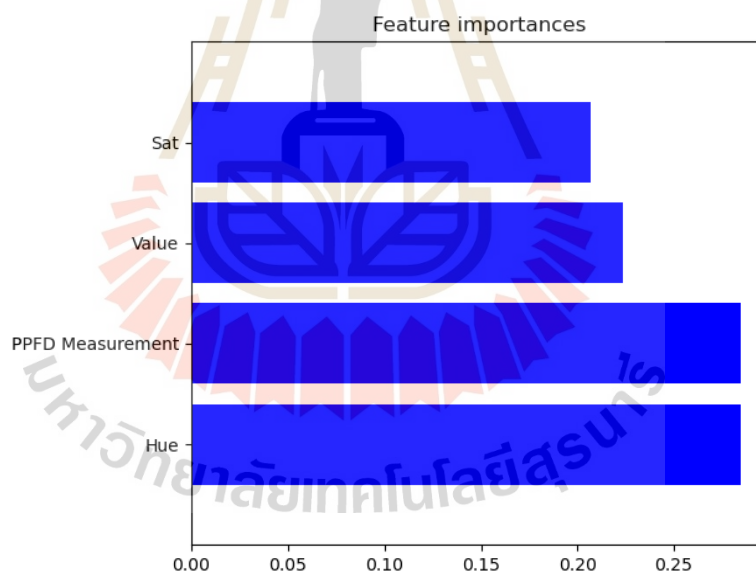
- ค่ารู้จำ (Recall) จะทำการแยกตามคลาสเป้าหมาย หรือคำตอบที่มีในชุดข้อมูล  
ในที่นี้มี 8 คลาสเป้าหมาย แต่จะพิจารณาเพียง 2 คลาสเป้าหมายที่มีปัญหาได้ คือ คลาสเป้าหมายที่ 7  
ทำนายหรือตรวจจับความเข้มแอลกอฮอล์สีน้ำเงิน 75% และ คลาสเป้าหมายที่ 8 ทำนายหรือตรวจจับ  
ความเข้มแอลกอฮอล์สีน้ำเงิน 100% โดยคลาสเป้าหมายที่ 7 และคลาสเป้าหมายที่ 8 มีค่ารู้จำ (Recall)  
เท่ากับ 66.67% และ 100% ตามลำดับ ในที่นี้เปอร์เซ็นต์ค่ารู้จำ (Recall) ของคลาสเป้าหมายที่ 8  
มากกว่าคลาสเป้าหมายที่ 7 ซึ่งแสดงให้เห็นว่าโครงข่ายประสาทเทียมนี้มีการทำนายหรือตรวจจับ  
คลาสเป้าหมายที่ 8 ได้ดีกว่าคลาสเป้าหมายที่ 7 หรือโครงข่ายประสาทเทียมนี้มีการฝึกฝนชุดข้อมูล  
ของคลาสเป้าหมายที่ 8 ได้ดีมากกว่าคลาสเป้าหมายที่ 7 ดังนั้นโครงข่ายประสาทเทียมนี้อาจจะมี  
โอกาสในการทำนายหรือตรวจจับชุดข้อมูลที่เหมาะสมกับคลาสเป้าหมายที่ 8 มากกว่า

- ค่าความแม่นยำ (Precision) โดยจะพิจารณาเพียง 2 คลาสเป้าหมายที่มีปัญหา  
ได้ คือ คลาสเป้าหมายที่ 7 ทำนายหรือตรวจจับความเข้มแอลกอฮอล์สีน้ำเงิน 75% และ คลาสเป้าหมายที่

8 ทำนายหรือตรวจจับความเข้มแอลกอฮอล์สีน้ำเงิน 100% โดยคลาสเป้าหมายที่ 7 และคลาสเป้าหมายที่ 8 มีค่าความแม่นยำ (Precision) เท่ากับ 100% และ 75% ตามลำดับ ในที่นี้เปอร์เซ็นต์ค่าความแม่นยำ (Precision) ของคลาสเป้าหมายที่ 7 มากกว่าคลาสเป้าหมายที่ 8 ซึ่งแสดงให้เห็นว่าโครงข่ายประสาทเทียมนี้มีการค้นหาชุดข้อมูลเพื่อทำนายตามคลาสเป้าหมายของคลาสเป้าหมายที่ 7 ได้ดีกว่าคลาสเป้าหมายที่ 8 ดังนั้นชุดข้อมูลตามคลาสเป้าหมายที่ 7 มีความเหมาะสมและมีซับซ้อนน้อยกว่าคลาสเป้าหมายที่ 8 จึงทำให้ค่าความแม่นยำสูงมากกว่า

#### 3.4.4 ผลการทดสอบการเลือกสกัดลักษณะเฉพาะที่สำคัญสำหรับระบบตรวจจับความเข้มแสงแอลกอฮอล์เพื่อนำไปใช้งานจริงได้อย่างมีประสิทธิภาพ

ในการทดสอบ ผู้วิจัยใช้อัลกอริทึมการเลือกย้อนหลังแบบตามลำดับ (Sequential Backward Selection) เพื่อใช้ในการเลือกคุณสมบัติที่สำคัญโดยใช้งานร่วมกับโครงข่ายประสาทเทียมแบบต้นไม้สุ่ม (Random Forest : RF) ซึ่งเป็นไปตามรูปที่ 3.22 เป็นกราฟแสดงค่าคุณลักษณะเฉพาะที่สำคัญของชุดข้อมูลในระบบควบคุมความเข้มแสงแอลกอฮอล์



รูปที่ 3.22 กราฟแสดงค่าคุณลักษณะเฉพาะที่สำคัญสำหรับชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) ในปริภูมิสี HSV ของระบบตรวจจับความเข้มแสงแอลกอฮอล์

จากรูปที่ 3.22 ผลการทดสอบ ผู้วิจัยสามารถสรุปได้จากการประเมินความสำคัญของค่าคุณลักษณะเฉพาะที่สำคัญด้วยโครงข่ายประสาทเทียม โดยค่าเฉลี่ยในปริภูมีย่อย Hue และ

ค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) เป็นค่าคุณลักษณะเฉพาะที่สำคัญของชุดข้อมูลในระบบควบคุมความเข้มแสงแอลอีดี ค่าความสำคัญของค่าลักษณะเฉพาะของค่าเฉลี่ยในปริภูมิย่อย Hue และค่าระดับความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) คือ 0.284543 และ 0.284505 ตามลำดับ เป็นค่าคุณลักษณะเฉพาะที่มีความสำคัญมากที่สุด โดยทั้งสองค่าคุณลักษณะนี้คิดเป็นสัดส่วนเปอร์เซ็นต์ที่สำคัญจากทั้งหมดคิดเป็น 0.569048 หรือ 56.91% ซึ่งเป็นสัดส่วนเกินครึ่งจากจำนวนทั้งหมดและด้วยค่าคุณลักษณะเฉพาะทั้งสองค่านี้มีส่วนสำคัญที่ทำให้โครงข่ายประสาทเทียมทำนายหรือตรวจจับความเข้มแสงแอลอีดีได้อย่างมีประสิทธิภาพ ในขณะที่ค่าความบริสุทธิ์ของสีในปริภูมิย่อย Saturation และค่าความสว่างของสีในปริภูมิย่อย Value ที่มีสัดส่วนเปอร์เซ็นต์ที่น้อยกว่าเมื่อรวมกันคิดเป็นสัดส่วน 43.09% ซึ่งแสดงให้เห็นถึงความสำคัญน้อยกว่าเมื่อเปรียบเทียบกับกัน รวมถึงอาจจะเป็นค่าที่ทำให้ชุดข้อมูลมีความแปรปรวน (Varaince) ทำให้ลดทอนประสิทธิภาพของโครงข่ายประสาทเทียมได้

### 3.5 สรุป

ในบทที่ 3 นี้ได้นำเสนอการดำเนินงานวิจัยและผลการดำเนินงานวิจัยของส่วนที่ 1 ซึ่งเป็นการจำลองเหตุการณ์สำหรับการตรวจจับระดับความเข้มแสงแอลอีดี โดยในงานวิจัยนี้ได้นำเสนอการเตรียมข้อมูลในการฝึกฝนและทดสอบกับโครงข่ายประสาทเทียมด้วยกระบวนการเก็บข้อมูลด้วยวิธีการที่ถูกออกแบบทั้งในปริภูมิสี RGB และ HSV การทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมในการทำนายความเข้มแสงแอลอีดีโดยอันดับแรกทดสอบประสิทธิภาพของโครงข่ายประสาทเทียมโดยใช้ชุดข้อมูลอย่างง่ายแบบไบนารี (Binary) โดยทำการปรับเปลี่ยนพารามิเตอร์ในแต่ละโครงข่ายประสาทเทียม เพื่อดูผลตอบสนองค่าความถูกต้องทั้งด้านการฝึกฝนและทดสอบ ซึ่งเป็นการพิจารณาเพื่อวิเคราะห์ประสิทธิภาพของโครงข่ายประสาทเทียมและเลือกใช้พารามิเตอร์ที่เหมาะสมสำหรับชุดข้อมูลที่ถูกออกแบบโดยผู้วิจัย ถัดมาจะทำการเปรียบเทียบการทดสอบโครงข่ายประสาทเทียมเพื่อหาชุดข้อมูลที่เหมาะสม ซึ่งในที่สุดก็คือโครงข่ายประสาทเทียมประสาทเทียมแรนด้อมฟอรัเรสต์ (Random Forest : RF) ที่เหมาะสมกับชุดข้อมูลที่ถูกแปลงเป็นชุดข้อมูลใหม่ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) จากนั้นทำการทดสอบหรือการประเมินค่าประสิทธิภาพของโครงข่ายประสาทเทียมด้วยเทคนิคเมทริกซ์คอนฟิวชัน (Confusion Matrix) ซึ่งสามารถประเมินประสิทธิภาพทั้งในด้านค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) และค่ารู้จำ (Recall) ซึ่งผลลัพธ์ที่ได้จากค่าเหล่านี้อยู่ในระดับดีมาก รวมถึงการผลการทดสอบการเลือกค่าคุณลักษณะเฉพาะที่สำคัญ โดยที่ค่าเฉลี่ยในปริภูมิย่อย Hue

และค่าระดับความเข้มแสง โดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) เป็น  
ชุดข้อมูลที่สำคัญที่สุด ทำให้สามารถประเมินและวิเคราะห์ได้ว่าชุดข้อมูลเหล่านี้มีผลอย่างไรในการ  
เพิ่มพูนประสิทธิภาพของโรงข่ายประสาทเทียม และในท้ายที่สุดผู้วิจัยสามารถพิจารณาได้ว่า  
โรงข่ายประสาทเทียมนี้พร้อมกับชุดข้อมูลที่ผ่านการคัดเลือกพร้อมสำหรับการนำไปใช้งานจริง





## บทที่ 4

### วิธีการดำเนินงานวิจัยส่วนที่ 2

#### การสร้างระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคนิค

#### ปัญญาประดิษฐ์

##### 4.1 บทนำ

ในการดำเนินงานวิจัยในส่วนที่ 2 จะนำโครงข่ายประสาทเทียมแรนด้อมฟอเรสต์ (Random Forest) ที่ได้จากการทดสอบในส่วนของจำลองเหตุการณ์ (Simulation) ด้วยกระบวนการเตรียมข้อมูลที่ผู้วิจัยออกแบบไว้ ไปทำการใช้งานจริง (Implementation) ในการตรวจจับระดับความแสงแอลอีดีให้เหมาะสมตามช่วงการเจริญเติบโตของพืชผลในระบบฮาร์ดแวร์ของการควบคุมแสงแอลอีดีอัจฉริยะ

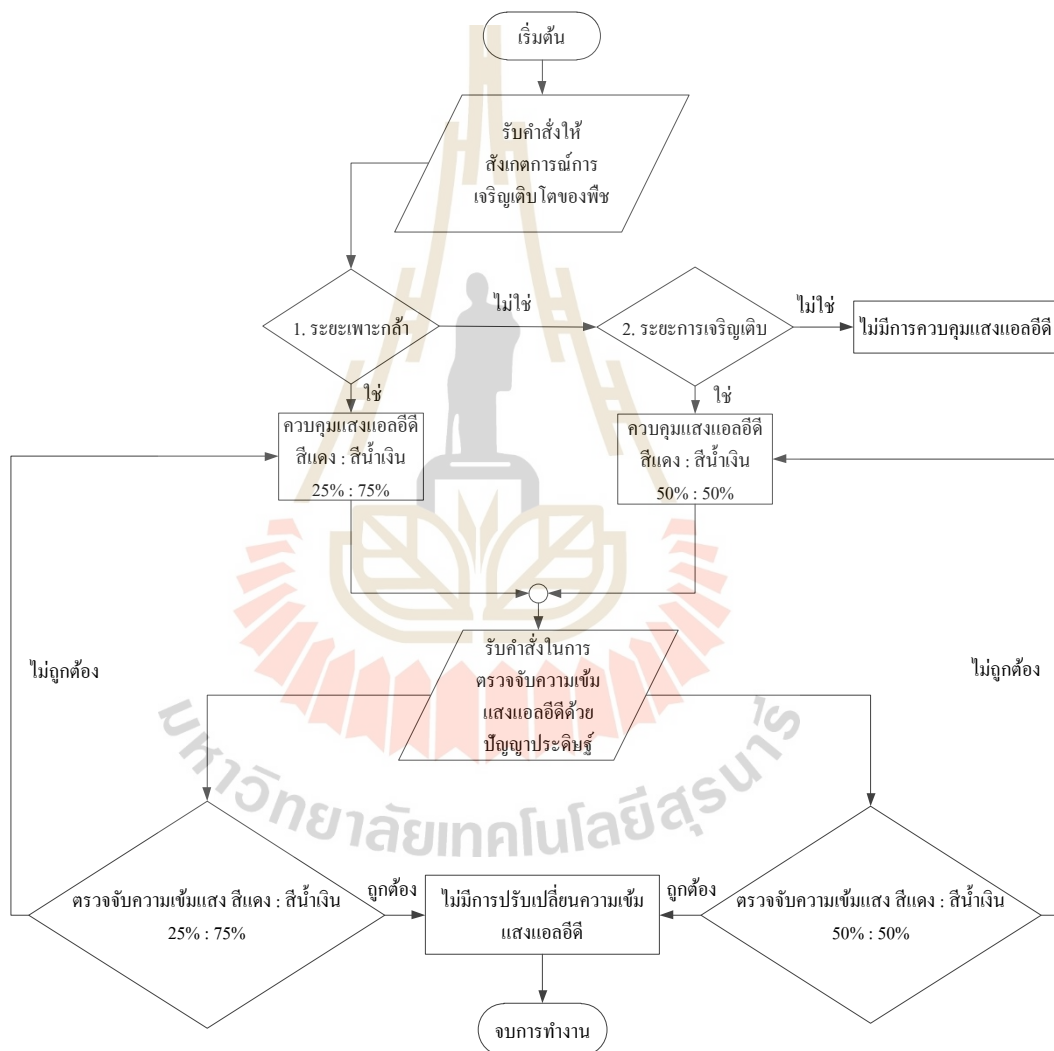
ดังนั้นผู้วิจัยจะนำเสนอโดยแบ่งออกเป็น 5 ส่วนหลัก ๆ โดยอันดับแรกนำเสนอการออกแบบระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ทั้งหมด จากนั้นอันดับที่สองนำเสนอการออกแบบการสร้างระบบควบคุมแสงแอลอีดีอัจฉริยะโดยใช้ Nvidia Jetson Nano Developer Kit ในการประมวลผลภาพและควบคุมแสงแอลอีดี ถัดมาอันดับสามนำเสนอการออกแบบโปรแกรมในการควบคุมและตรวจจับความระดับความเข้มแสงแอลอีดีเพื่อใช้ในการทดสอบการทำงาน จากนั้นอันดับสี่นำเสนอการทดลองการควบคุมความสว่างของระบบควบคุมแสงแอลอีดีโดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิทัล (Digital Multimeter Instrument) และส่วนสุดท้ายนำเสนอการควบคุมและตรวจจับความระดับความเข้มแสงแอลอีดีนำไปใช้งานจริงกับพืชผล

##### 4.2 การออกแบบระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยี

##### ปัญญาประดิษฐ์

ในหัวข้อนี้จะนำเสนอการออกแบบระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ โดยงานวิจัยนี้ ผู้วิจัยจะออกแบบระบบสองส่วน ได้แก่ ในส่วนแรกจะทำการสังเกตการณ์เจริญเติบโตของพืชเพื่อควบคุมระดับความเข้มแสงแอลอีดีให้เหมาะสมตามช่วงการเจริญเติบโตของพืช โดยทำการออกแบบอัตราส่วนระดับความเข้มแสงแอลอีดีและปลูกผักกาดหอมกรีนโอ๊ค (Green Oak Lattuce) [Kua – Hung Lin, 2556] และ [นภัทร วัจนเทพินทร์,

2560] และในส่วนที่สองจะทำการตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ซึ่งในส่วนนี้เป็นส่วนที่เกิดจากการจำลองเหตุการณ์ (Simulation) ที่ถูกนำเสนอในบทที่ 3 โดยต่อเนื่องมาในบทนี้จะถูกนำเสนอเพิ่มเติมในส่วนของการนำไปใช้งานจริง (Implementation) โดยทั้งสองส่วนนี้ผู้วิจัยจะทำการออกแบบโปรแกรมเพื่อใช้งานและทดสอบจริง และท้ายที่สุด ผู้วิจัยนำเสนอแผนผังการทำงานของระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ตามรูปที่ 4.1



รูปที่ 4.1 แผนผังการทำงานของระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียนโดยใช้เทคโนโลยีปัญญาประดิษฐ์


จากรูปที่ 4.1 เป็นการแสดงแผนผังระบบทั้งหมด ซึ่งเป็นการทำงานของระบบควบคุมแสง แอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ โดยระบบการทำงานหลัก ๆ จะถูกนำเสนอแบ่งออกเป็นสองส่วนได้แก่

ส่วนที่หนึ่ง ส่วนการสังเกตการณ์การเจริญเติบโตของพืช โดยส่วนนี้ระบบจะเริ่มดำเนินการทำงานจากรับหน้าที่ทำการสังเกตการณ์และเฝ้าดูการเจริญเติบโตของผักกาดหอมกรีน โอ๊ค ซึ่งตามบทความ [Kua – Hung Lin, 2556] และ [นภัทร วจนเทพินทร์, 2560] ได้ระบุไว้ว่าช่วงการเจริญเติบโตของผักกาดหอมกรีนโอ๊คทั้งหมดสองช่วงเวลาคือ ระยะการเติบโตช่วงที่หนึ่งเป็นช่วงระยะเพาะกล้า (Seeding) เป็นช่วงเริ่มต้นปลูกจากการเพาะเมล็ดจนถึงต้นกล้า จะใช้ระยะเวลาในช่วงนี้ประมาณ 15 – 20 วัน และระยะการเติบโตช่วงที่สองเป็นช่วงระยะการเจริญเติบโต (Vegatative Growth) เป็นช่วงที่พืชมีใบและลำต้นสมบูรณ์ควรเร่งการสังเคราะห์ด้วยแสง จะใช้ระยะเวลาในช่วงนี้ประมาณ 20 – 25 วัน รวมมีอายุก่อนที่จะเก็บเกี่ยวประมาณ 40 – 45 วัน และได้ระบุถึงพืชผลมีความต้องการแสงที่มีความยาวคลื่นและสัดส่วนของแสงที่มีความแตกต่างกันสองช่วงเวลาคือช่วงระยะเพาะกล้า (Seeding) ต้องการแสงสีแดงมีความยาวคลื่น 660 นาโนเมตร และแสงสีน้ำเงินที่มีความยาวคลื่น 450 นาโนเมตร ในสัดส่วนแสงสีแดงแต่สีน้ำเงินประมาณ 25% : 75% และระยะการเจริญเติบโต (Vegative Growth) ต้องการแสงสีแดงมีความยาวคลื่น 660 นาโนเมตร และแสงสีน้ำเงินที่มีความยาวคลื่น 450 นาโนเมตร ในสัดส่วนแสงสีแดงแต่สีน้ำเงินประมาณ 50% : 50% ถึงแม้ว่าจะมีบทความที่ระบุถึงช่วงเวลาการปลูกและสัดส่วนของแสงในการเร่งการเจริญเติบโตก็ตาม แต่ความเป็นจริงแล้วขึ้นอยู่กับปัจจัยต่าง ๆ อีก อาทิ เช่น สภาพของดินมีความร่วนซึ่งสามารถระบายน้ำและอากาศได้ดี มีความชื้นในดินที่เพียงพอ สถานที่ปลูกควรที่จะสามารถให้พืชรับแสงได้เต็มที่ตลอดวัน อุณหภูมิอยู่ระหว่าง 21 – 26 องศาเซลเซียส ซึ่งโดยผลของสภาพแวดล้อมเหล่านี้จะทำให้พืชผลเจริญเติบโตได้ดีสามารถคาดการณ์ถึงช่วงอายุของพืชผลได้อย่างแม่นยำ แต่ถ้าหากสภาพแวดล้อมไม่เป็นไปตามอย่างที่กล่าวจะทำให้พืชผลมีผลผลิตไม่เป็นไปตามต้องการ และที่สำคัญคืออาจจะไม่สามารถเจริญเติบโตได้ดีเท่าที่ควร ดังนั้นเมื่อทราบถึงช่วงระยะการเจริญเติบโตและสัดส่วนความเข้มแสงแอลอีดีเรียบร้อยแล้ว ทำให้สามารถทำการตั้งค่าระดับความเข้มแสงแอลอีดีให้ตรงตามช่วงอายุของพืชให้กับระบบได้ โดยเริ่มต้นจากระยะเพาะกล้า (Seeding) เมื่อทำการสังเกตการณ์และเฝ้าดูว่าช่วงระยะนี้ จะทำการปรับระดับความเข้มแสงแอลอีดีในสัดส่วนของสีแดงและสีน้ำเงินที่ 25% : 75% จากนั้นเมื่อพืชเจริญเติบโตไปเป็นช่วงระยะที่สองคือระยะการเจริญเติบโต (Vegative Growth) จะทำการปรับระดับความเข้มแสงแอลอีดีในสัดส่วนของสีแดงและสีน้ำเงินที่ 100% : 100% และสุดท้ายเมื่อพืชเจริญเติบโตจนครบทั้งสองระยะแล้ว จะไม่ทำการควบคุมระดับความเข้มแสงแอลอีดี ซึ่งหมายถึงการปิดระบบหรือสิ้นสุดการทำงาน


ส่วนที่สอง ส่วนการตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ โดยระบบจะทำหน้าที่ในการตรวจจับความเข้มแสงแอลอีดีจากการควบคุมความเข้มแสงแอลอีดีตามช่วงการเจริญเติบโตของพืชต่อเนื่องจากหน้าที่ในส่วนที่หนึ่ง ดังนั้น ถ้าระบบเริ่มต้นจากการสังเกตการณ์และพบว่าอยู่ในช่วงระยะเพาะกล้า (Seeding) จากนั้นระบบจะทำการปรับระดับความเข้มแสงแอลอีดีตามสัดส่วนที่เหมาะสมตามช่วงระยะเพาะกล้า และจากนั้นระบบจะทำหน้าที่ตรวจจับความเข้มแสงแอลอีดีว่าเป็นไปตามช่วงระยะของพืชที่ต้องการหรือไม่ ถ้าในกรณีที่ระบบตรวจจับพบว่าไม่ถูกต้อง ระบบจะทำการควบคุมระดับความเข้มแสงแอลอีดีอัตโนมัติตามช่วงอายุของพืช และถ้าในกรณีที่ระบบตรวจจับพบว่าถูกต้อง ระบบจะไม่ทำการควบคุมระดับความเข้มแสงแอลอีดี ซึ่งหมายถึงการปิดระบบหรือสิ้นสุดการทำงาน ในท้ายที่สุดแล้วในหัวข้อนี้ผู้วิจัยได้นำเสนอแผนผังการทำงานของระบบทั้งหมดเพียงภาพรวมเท่านั้น ซึ่งรายละเอียดทั้งหมดจะถูกนำเสนอเพิ่มเติมในหัวข้อถัดไป

#### **4.3 การออกแบบการสร้างระบบควบคุมแสงแอลอีดีอัจฉริยะโดยใช้ Nvidia Jetson Nano Developer Kit ในการประมวลผลภาพและควบคุมความเข้มแสงแอลอีดี**


ในหัวข้อนี้ผู้วิจัยจะกล่าวถึงการออกแบบอุปกรณ์ การติดตั้งและการทดสอบอุปกรณ์และตามด้วยออกแบบวิธีการของระบบควบคุมแสงแอลอีดีอัจฉริยะ โดยใช้ Nvidia Jetson Nano Developer Kit ในการประมวลผลภาพและควบคุมความเข้มแสง โดยรูปที่ 4.2 จะเป็นแผนภาพการทำงานโดยรวมทั้งหมดของระบบ รูปที่ 4.3 ภาพอุปกรณ์ฝั่งควบคุมระบบแสงแอลอีดีทั้งหมด และรูปที่ 4.4 ภาพอุปกรณ์ แผงไฟแอลอีดี LED Driver และหม้อแปลงขนาด 24 Vdc 20 A



รูปที่ 4.2 แผนภาพรวมการออกแบบอุปกรณ์ของระบบควบคุมแสงแอลอีดีอัจฉริยะ



รูปที่ 4.3 ภาพอุปกรณ์ฝั่งควบคุมระบบแสงแอลอีดีทั้งหมด



รูปที่ 4.4 ภาพอุปกรณ์ แสงไฟแอลอีดี LED Driver และหม้อแปลงขนาด 24Vdc 20A

แผนภาพและภาพอุปกรณ์ของระบบควบคุมแสงแอลอีดีอัจฉริยะ โดยใช้ Nvidia Jetson Nano Developer Kit ในการประมวลผลภาพและควบคุมความเข้มแสงแอลอีดี เป็นไปตามรูปที่ 4.2 4.3 และ 4.4 ตามลำดับ โดยวงจรในระบบทั้งหมดประกอบไปด้วย อันดับแรกคือหม้อแปลงขนาด 24Vdc 20A ทำหน้าที่แปลงแรงดันไฟฟ้า 220 Vac ให้ลดลงเป็น 24 Vdc และสามารถจ่ายกระแสไฟฟ้าสูงสุด 20 A ซึ่ง Regulator LED Driver ต้องการกระแสไฟฟ้าเพียง 1.5 A จำนวน 5 อัน คิดเป็นจำนวนทั้งหมดที่ต้องการกระแสไฟฟ้าคือ 7.5 A ต่อมา ไฟ LED แบ่งเป็นสีแดงจำนวน 16 ดวงและสีน้ำเงินทั้งหมด 18 ดวง รวมเป็นทั้งหมด 34 ดวง ซึ่งทำหน้าที่ในการให้แสงสว่างแก่พืชผล และให้แสงสว่างแก่ Logitech C310 Webcam ซึ่งทำหน้าที่ในการประมวลผลภาพและนำผลที่ได้ไปโอนข้อมูลให้แก่ Nvidia Jetson Nano จากนั้น Nvidia Jetson Nano ที่เชื่อมต่อเข้ากับ PCA9685 เพื่อให้สามารถควบคุมความเข้มแสงได้ ด้วยการสื่อสารแบบ I2C โดยจับความเข้มแสงผ่าน PWM ทั้ง 16 Channels โดย PWM Channel 8 ทำการควบคุมระดับความเข้มแสงสีน้ำเงินและ PWM Channel 11 ทำการควบคุมระดับความเข้มแสงสีแดง ท้ายที่สุดคือหน้าจอแสดงผลที่เชื่อมต่อจาก Nvidia Jetson Nano เพื่อที่จะแสดงผลเพื่อควบคุมการทำงานทั้งหมด

ก่อนที่จะนำอุปกรณ์ไปใช้งานจริงสำหรับระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรียน โดยใช้เทคโนโลยีปัญญาประดิษฐ์ จำเป็นอย่างยิ่งต้องมีการทดสอบอุปกรณ์ โดยบนระบบฮาร์ดแวร์ นั้นได้เลือกใช้บอร์ดไมโครคอนโทรลเลอร์ Nvidia Jetson Nano Developer Kit ซึ่งมีคุณลักษณะ ดังนี้

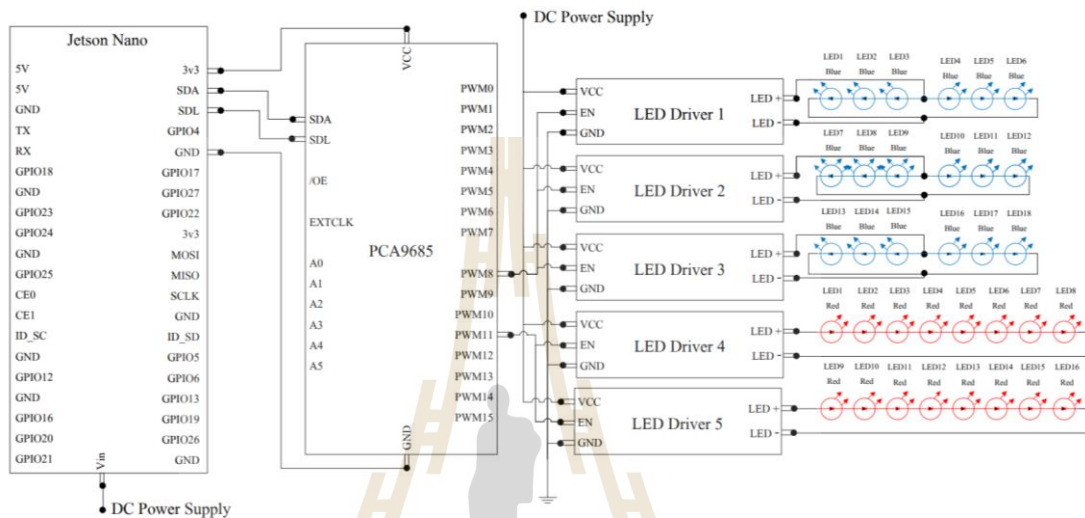
SoC :	Tegra X1
CPU :	Quad core ARM A57
GPU :	128 core Maxwell™ GPU
RAM :	4 GB 64 bit LPDDR4 (1.6 GHz)
Storage :	microSD (การทดสอบใช้ขนาด 64 GB)
GPIO :	J41 pin header
Ports :	HDMI Type A, 4 x USB 3.0 Type A, Micro B USB, Ethernet, Camera Serial Interface (CSI)

สำหรับกล้องที่ใช้ในการประมวลผลภาพดิจิทัลคือกล้องเว็บแคม Logitech C310 HD ซึ่งมีคุณสมบัติดังนี้

Max Resolution :	HD 720p/30fps
Photo Quality :	5 Megapixels
Focus type :	Fixed focus
Lens technology :	Standard
Built-in mic :	mono
FoV :	60°

การทดสอบประสิทธิภาพการควบคุมระดับความเข้มแสงแอลอีดี จะนำ Nvidia Jetson Nano Developer Kit เชื่อมต่อกับบอร์ด PCA9685 โดยสื่อสารกันผ่านพอร์ต SDA (Serial Data) และ SCL (Serial Clock) หรือเรียกว่าการสื่อสารแบบ I2C (Inter Integrate Circuit Bus) ซึ่งบอร์ดนี้เป็นอุปกรณ์ควบคุมแบบ Pulse Width Modulation (PWM) ที่สามารถควบคุมจำนวนระดับ (Level) ในระดับ 16 บิต หรือความเป็นไปได้จำนวน  $2^{16} = 65536$  จำนวน จากนั้นทำการเชื่อมต่อบอร์ด PCA9685 เข้ากับ LED Driver ที่เป็นตัวแปลงกระแสสำหรับแสงแอลอีดีสีแดงและสีน้ำเงิน โดยใช้พอร์ต Pulse Width Modulation (PWM) โดยให้ PWM Channel 8 เชื่อมต่อกับ LED Driver สีน้ำเงิน และ PWM Channel 11 เชื่อมต่อกับ LED Driver สีแดง ถัดมาให้ LED Driver 1-3 เชื่อมต่อกับ แอลอีดีสีน้ำเงิน โดยวงจรแอลอีดีสีน้ำเงินต่อวงจรแบบขนาน และ LED Driver 4-5 เชื่อมต่อกับ แอลอีดีสีแดง โดยวงจรแอลอีดีสีแดงต่อวงจรแบบอนุกรม ท้ายที่สุดภาษาที่ใช้พัฒนาการทำงานของระบบทั้งหมด ได้พัฒนาโดยใช้ภาษาไพทอน เวอร์ชัน 3.7 (Python 3.7) ซึ่งใช้ภาษาไพทอนในการ

พัฒนาระบบประมวลผลภาพดิจิทัล อัลกอริทึมสำหรับการตรวจจับความเข้มแสงแอลอีดี ควบคุมระดับความเข้มแสงแอลอีดี โดยทั้งหมดนี้จะถูกควบคุมการทำงานผ่าน โปรแกรมซึ่งจะถูกนำเสนออย่างละเอียดในหัวข้อถัดไป โดยรูปที่ 4.5 เป็นรายละเอียดของการเชื่อมต่อวงจรเพื่อทดสอบประสิทธิภาพการควบคุมระดับความเข้มแสงแอลอีดี



รูปที่ 4.5 การเชื่อมต่อวงจรเพื่อทดสอบประสิทธิภาพการควบคุมระดับความเข้มแสงแอลอีดี

การตั้งค่าการควบคุมความเข้มแสงแอลอีดีจะใช้คำสั่งภาษาไพทอนเวอร์ชัน 3.7 ในการควบคุมการทำงานผ่านบอร์ดไมโครคอนโทรลเลอร์ Nvidia Jetson Nano โดยใช้โปรแกรม Visual Studio Code 2019 บนระบบปฏิบัติการ Ubuntu 18.04 LTS 64-bit จากนั้นใช้บอร์ด PCA9685 เป็นตัวกลางในการควบคุมระดับความเข้มแสงแอลอีดีให้กับ LED Driver ซึ่งการตั้งค่าการทำงานจะใช้ไลบรารี adafruit\_pca9685 จากนั้นการกำหนดระดับความเข้มแสงแอลอีดีด้วยบอร์ดมีขนาดต่ำสุดและสูงสุดที่ 0 และ 65535 ตามลำดับ ดังนั้นแสดงว่า ถ้าหากป้อนค่า 0 ให้กับอุปกรณ์ LED Driver อุปกรณ์ชิ้นนี้จะทำหน้าที่ขับกระแสให้แสงแอลอีดีมีความสว่างต่ำสุด และป้อนค่า 65535 ให้กับอุปกรณ์ LED Driver อุปกรณ์ชิ้นนี้จะทำหน้าที่ขับกระแสให้แสงแอลอีดีมีความสว่างสูงสุด และสุดท้ายผู้วิจัยทำการตั้งค่าให้การปรับความเข้มแสงแอลอีดีอยู่ในหน่วยของเปอร์เซ็นต์เพื่อให้ง่ายต่อการปรับค่า โดยสามารถอธิบายในรูปของสมการได้ดังนี้


$$Red = \frac{65535 \times R}{100} \quad (4.1)$$



$$Blue = \frac{65535 \times B}{100} \quad (4.2)$$

โดย	<i>Red</i>	คือค่าควบคุมความเข้มของแสงแอลอีดีสีแดง
	<i>Blue</i>	คือค่าควบคุมความเข้มของแสงแอลอีดีสีน้ำเงิน
	<i>R</i>	คือค่าความเข้มแสงแอลอีดีสีแดงในหน่วยเปอร์เซ็นต์ที่อยู่ในช่วง [0,100]
	<i>B</i>	คือค่าความเข้มแสงแอลอีดีสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่อยู่ในช่วง [0,100]





โดยรูปที่ 4.6 เป็นภาพตัวอย่างการเปิด – ปิดแสงแอลอีดีจากการป้อนค่า 0 หรือ 0% เป็นการกำหนดความสว่างแสงแอลอีดีทั้งสีแดงและสีน้ำเงินต่ำสุดหรือมืดสนิท (รูปย่อยที่ 4.6 ก) และการป้อนค่า 65535 หรือ 100% เป็นการกำหนดความสว่างแสงแอลอีดีทั้งสีแดงและสีน้ำเงินสูงสุดหรือสว่างที่สุด (รูปย่อยที่ 4.6 ข)







รูปที่ 4.6 ภาพตัวอย่างการเปิด – ปิดระบบควบคุมแสงแอลอีดี


ต่อมาผู้วิจัยได้ทำการตั้งค่าการควบคุมความเข้มแสงแอลอีดีเพื่อทดสอบการทำงานโดยทดลองป้อนค่า 25%, 50%, 75% และ 100% ให้แก่แอลอีดีสีแดงและสีน้ำเงิน พร้อมบันทึกภาพจากกล้องเว็บแคม Logitech C310 HD และบันทึกค่าความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ด้วยเครื่องมือวัดเซนเซอร์ควันตัม เอ็มคิว – 200 (MQ – 200 Quantum Sensor) เพื่อหาความสัมพันธ์กันระหว่างข้อมูลที่ป้อนในหน่วยเปอร์เซ็นต์และค่าความเข้มแสง PPFD ตามตารางที่ 4.1

ตารางที่ 4.1 ความสัมพันธ์กันระหว่างข้อมูลที่ป้อนในหน่วยเปอร์เซ็นต์และค่าความเข้มแสง PPFD

ตัวอย่างภาพ	ชนิดของตัวอย่างภาพ	ค่าความเข้มแสงแอลอีดีในหน่วยเปอร์เซ็นต์	ค่าระดับความสว่างของแสงแอลอีดี	ค่าความเข้มแสง PPFD
	แสงแอลอีดีสีแดง	25%	16383.75	14
	แสงแอลอีดีสีแดง	50%	32767.5	30
	แสงแอลอีดีสีแดง	75%	49151.25	46
	แสงแอลอีดีสีแดง	100%	65535	61

ตารางที่ 4.1 ความสัมพันธ์กันระหว่างข้อมูลที่ป้อนในหน่วยเปอร์เซ็นต์และค่าความแสง PPFD (ต่อ)

ตัวอย่างภาพ	ชนิดของ ตัวอย่างภาพ	ค่าความเข้มแสง แอลอีดีในหน่วย เปอร์เซ็นต์	ค่าระดับความ สว่างของแสง แอลอีดี	ค่าความเข้ม แสง PPFD
	แสงแอลอีดี สีน้ำเงิน	25%	16383.75	10
	แสงแอลอีดี สีน้ำเงิน	50%	32767.5	20
	แสงแอลอีดี สีน้ำเงิน	75%	49151.25	32
	แสงแอลอีดี สีน้ำเงิน	100%	65535	43



รูปที่ 4.7 ความสัมพันธ์กันระหว่างข้อมูลที่ป้อนในหน่วยเปอร์เซ็นต์และค่าความแสง PPFD ของแสงแอลอีดีสีแดงและสีน้ำเงิน

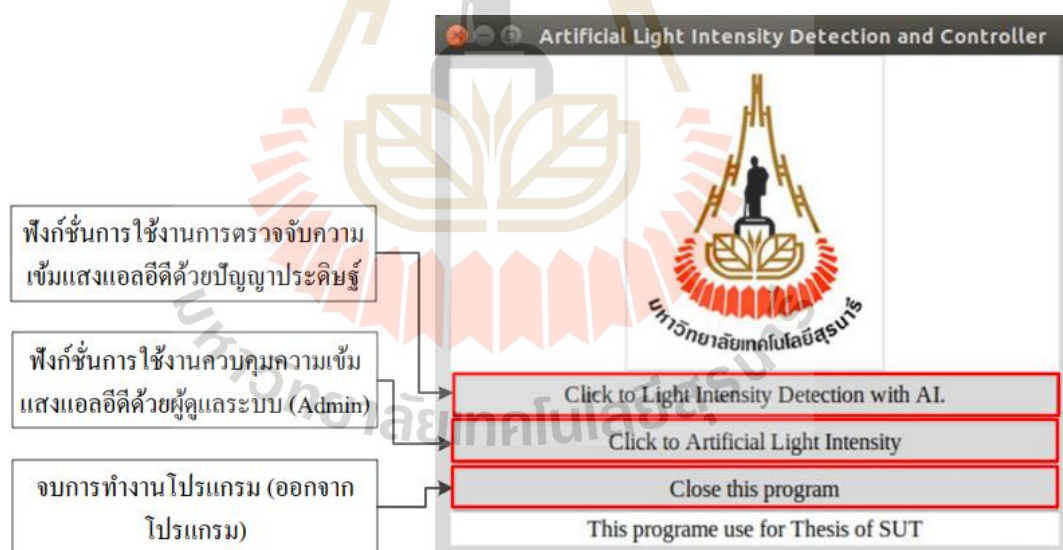
จากรูปที่ 4.7 เป็นกราฟความสัมพันธ์กันระหว่างข้อมูลที่ป้อนในหน่วยเปอร์เซ็นต์และค่าความแสง PPFD ของแสงแอลอีดีสีแดงและสีน้ำเงิน ซึ่งพบว่าเมื่อทำการปรับค่าเข้มแสงแอลอีดีในหน่วยเปอร์เซ็นต์ให้มีค่าเพิ่มขึ้น ค่าความเข้มแสง PPFD ที่บันทึกค่าได้ก็มีแนวโน้มที่เพิ่มขึ้นเช่นเดียวกัน

โดยสรุปแล้วผลการทดสอบประสิทธิภาพการควบคุมระดับความเข้มแสงแอลอีดีสามารถใช้งานได้จริง โดยเมื่อทำการป้อนค่าที่ต่ำที่สุดคือ 0 หรือ 0% ความสว่างของแสงแอลอีดีทั้งสองสีต่ำที่สุดหรือมืดสนิท และทำการป้อนค่าที่สูงที่สุดคือ 65535 หรือ 100% ความสว่างของแสงแอลอีดีทั้งสองสีสูงที่สุดหรือสว่างที่สุด โดยค่าที่ได้มีความสัมพันธ์กับค่าค่าความเข้มแสงโดยความหนาแน่นของโฟตอนฟลักซ์สังเคราะห์ด้วยแสง (PPFD) ซึ่งทั้งสองค่ามีความสัมพันธ์ไปในแนวโน้มเดียวกัน แต่อย่างไรก็ตามการทดสอบครั้งนี้เป็นเพียงทดสอบเพื่อทดลองการทำงานในการควบคุมระดับ

ความเข้มแสงแอลอีดีเท่านั้น ดังนั้นการทดลองการควบคุมความสว่างจำเป็นต้องมีการเทียบวัดกับเครื่องมือวัดทางไฟฟ้าเพื่อให้การควบคุมระดับแสงแอลอีดีมีมาตรฐานและน่าเชื่อถือ ซึ่งผู้วิจัยจะนำเสนอในหัวข้อที่ 4.5

#### 4.4 การออกแบบโปรแกรมในการควบคุมและตรวจจับความระดับความเข้มแสงแอลอีดีเพื่อใช้ในการทดสอบการทำงาน

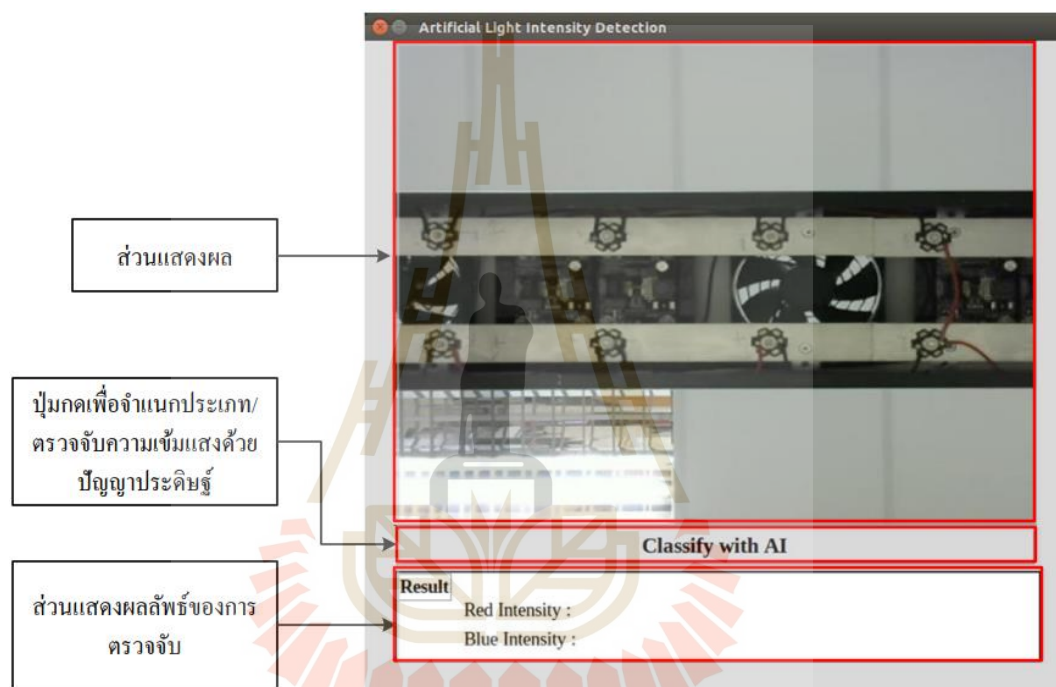
ในหัวข้อนี้ผู้วิจัยนำเสนอการทำงานของระบบระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ โดยนำเสนอการเลือกรูปแบบโปรแกรม GUI (Graphical User Interface) ที่พัฒนาขึ้นเพื่อสะดวกต่อการดำเนินงาน การทดสอบ และนำเสนอในรูปแบบการควบคุมและตรวจจับตามเวลาจริงที่สามารถทำงานได้อย่างต่อเนื่อง โดยการทดสอบดำเนินการบนโปรแกรม Visual Studio Code 2019 บนระบบปฏิบัติการ Ubuntu 18.04 LTS 64-bit ในบอร์ดไมโครคอนโทรลเลอร์ Nvidia Jetson Nano Developer Kit โดยรูปที่ 4.8 จนถึง 4.15 จะเป็นการนำเสนอการใช้งานโปรแกรมโดยรวมที่ผู้วิจัยออกแบบเบื้องต้น



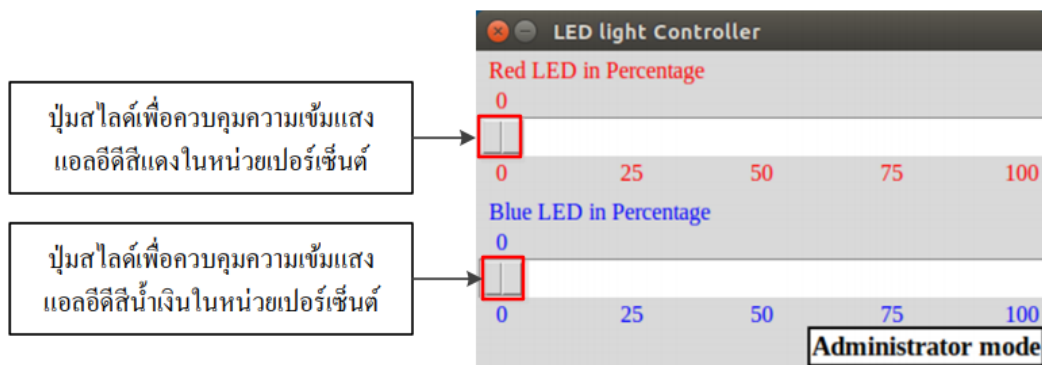
รูปที่ 4.8 ตัวอย่างหน้าต่างแรกของโปรแกรมที่ใช้ในการทดสอบ

จากรูปที่ 4.8 จะเป็นหน้าต่างแรกของโปรแกรมเพื่อเข้าใช้งานฟังก์ชันต่าง ๆ โดยที่การทำงานของโปรแกรมจะประกอบไปด้วยสองฟังก์ชันได้แก่ ฟังก์ชันแรก คือฟังก์ชันการใช้งานการตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ เป็นฟังก์ชันการทำงานสำหรับการมอนิเตอร์ใน


การประมวลผลภาพดิจิทัลแล้วจากนั้นทำการตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ ซึ่งผลลัพธ์ที่ได้จากการตรวจจับ คือค่าความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินในหน่วยเปอร์เซ็นต์ จากนั้นฟังก์ชันที่สอง คือฟังก์ชันการใช้งานควบคุมความเข้มแสงแอลอีดีด้วยผู้ดูแลระบบ (Administrator) เป็นฟังก์ชันการทำงานสำหรับควบคุมความเข้มแสงแอลอีดีในหน่วยเปอร์เซ็นต์ ซึ่งจะมีลาเบล (Label) ระบุไว้ว่าเป็นการทำงานของผู้ดูแลระบบ โดยการทำงานทั้งสองฟังก์ชันจะถูกนำเสนอตัวอย่างการทำงานเบื้องต้นตามรูปภาพที่ 4.9 และ 4.10



รูปที่ 4.9 ตัวอย่างฟังก์ชันการใช้งานการตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ของโปรแกรมที่ใช้ในการทดสอบ




รูปที่ 4.10 ตัวอย่างฟังก์ชันการใช้งานควบคุมความเข้มแสงแอลอีดีด้วยผู้ดูแลระบบของโปรแกรมที่ใช้ในการทดสอบ




รูปที่ 4.11 ตัวอย่างการใช้งานการจำแนกประเภท/ตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์

จากรูปภาพที่ 4.11 เป็นตัวอย่างการใช้งานการจำแนกประเภท/ตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ โดยกดปุ่มสีเขียวตามภาพชื่อ "Classify with AI" จากนั้นเมื่อกดปุ่มนี้จะ

มีหน้าต่างขึ้นมาตามรูปภาพที่ 4.12 โดยจะเป็นการป้อนข้อมูลที่สำคัญอีกชุดข้อมูลซึ่งเป็นค่าลักษณะเฉพาะที่เป็นค่าความเข้มแสง PPFd ที่วัดได้จากเครื่องมือวัดเซนเซอร์ควอนตัม เอ็มคิว – 200 ซึ่งถ้าหากป้อนข้อมูลที่ไม่ถูกต้องตามฐานข้อมูลของชุดข้อมูลความเข้มแสง PPFd ก็จะเป็นไปตามรูปที่ 4.13 และถ้าหากถูกต้องก็จะเป็นไปตามรูปที่ 4.14

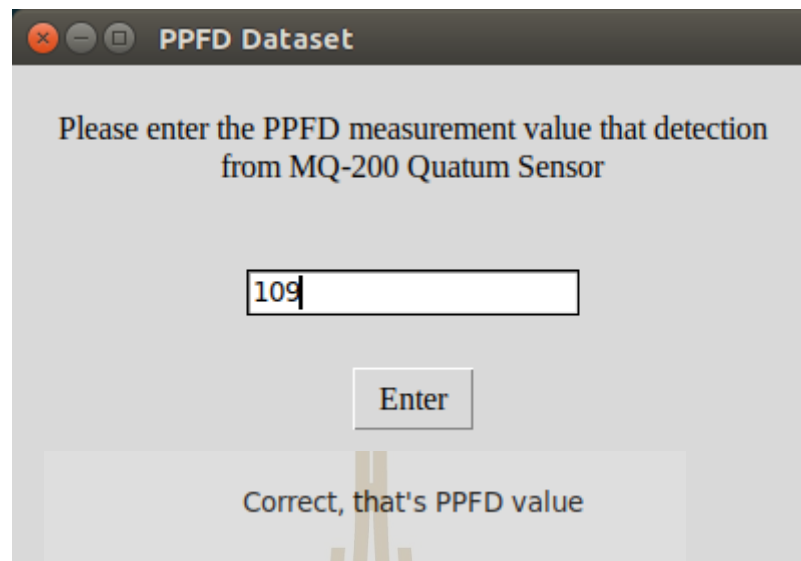


รูปที่ 4.12 ตัวอย่างหน้าต่างในการป้อนชุดข้อมูลค่าความเข้มแสง PPFd



รูปที่ 4.13 ตัวอย่างหน้าต่างในการป้อนชุดข้อมูลค่าความเข้มแสง PPFd ที่ไม่ถูกต้อง






รูปที่ 4.14 ตัวอย่างหน้าต่างในการป้อนชุดข้อมูลค่าความเข้มแสง PPFD ที่ถูกต้อง



รูปที่ 4.15 ตัวอย่างหน้าต่างโปรแกรม โดยรวมทั้งหมด

จากรูปที่ 4.15 เป็นตัวอย่างหน้าต่างโปรแกรมโดยรวมทั้งหมดของระบบ ซึ่งการทำงานของโปรแกรมหลัก ๆ จะมีทั้งหมด 3 หน้าต่าง ตามที่อธิบายไปข้างต้น โดยที่ท้ายที่สุดผู้วิจัยจะนำเสนอการใช้งานของโปรแกรมที่เพิ่มรายละเอียดมากยิ่งขึ้น การใช้งานโปรแกรมที่ผู้วิจัยออกแบบ ผู้วิจัย

ได้ออกแบบผลลัพธ์ที่จากการจำแนกประเภท/ตรวจจับ ที่แตกต่างกันออกไปทั้งหมด 3 รูปแบบ โดยสามารถอธิบายเป็นแผนภาพการทำงานของรูปแบบที่หนึ่งได้ดังนี้




รูปที่ 4.16 แผนภาพแสดงกระบวนการทำงานของโปรแกรมทั้งสามรูปแบบ

จากรูปที่ 4.16 เป็นแผนภาพแสดงกระบวนการทำงานของโปรแกรมทั้งสามรูปแบบ โดยเริ่มต้นจาก ผู้วิจัยจะทำการควบคุมระดับความเข้มแสงแอลอีดีตามสัดส่วนช่วงอายุของพืชจากการสังเกตการณ์และพิจารณาของผู้วิจัย จากนั้นทำการถ่ายภาพด้วย ทำให้ได้ภาพแสงแอลอีดีหนึ่งภาพซึ่งนำภาพเหล่านี้ไปประมวลผลภาพดิจิทัล แล้วทำการป้อนข้อมูลอีกชุดคือค่าความเข้มแสง PPFD และทำการกำหนดเป็นชุดข้อมูลขาเข้าสำหรับโครงข่ายประสาทเทียมแรนด้อมฟอเรสต์ (Random Forest) ต่อมาโครงข่ายประสาทเทียมจะจำแนกประเภทภาพออกเป็นคลาสเป้าหมาย ซึ่งคลาสแต่ละเป้าหมาย ผู้วิจัยจะทำการกำหนดให้ว่าคลาสเป้าหมายที่ได้มามีสัดส่วนเหมาะสมตาม

ช่วงอายุของพืชหรือไม่ ถ้าหากถูกต้องสัดส่วนที่ได้ในแต่ละคลาสเป้าหมายจะถูกระบุว่ามีความเข้มแสงแอลอีดีในหน่วยเปอร์เซ็นต์และระบุว่าเหมาะสมกับพืชช่วงอายุใด แต่ถ้าไม่ถูกต้องจะบุเหมือนกัน แต่เพิ่มเติมคือจะฟังก์ชันที่สามารถปรับเปลี่ยนระดับความเข้มแสงแอลอีดีให้เหมาะสมตามช่วงอายุของพืชตามการแนะนำของโปรแกรมที่ผู้วิจัยออกแบบและทำการตรวจจับอีกครั้งจนกว่าจะถูกต้อง และในท้ายที่สุดผู้วิจัยจะนำเสนอตัวอย่างหน้าต่างการทำงานของโปรแกรมแต่ประกอบไปด้วยผลลัพธ์ทั้งสามรูปแบบตามหัวข้อย่อต่อไปนี้

#### 4.4.1 การออกแบบโปรแกรมการตรวจจับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินในเงื่อนไขสำหรับการตรวจจับที่ถูกต้อง

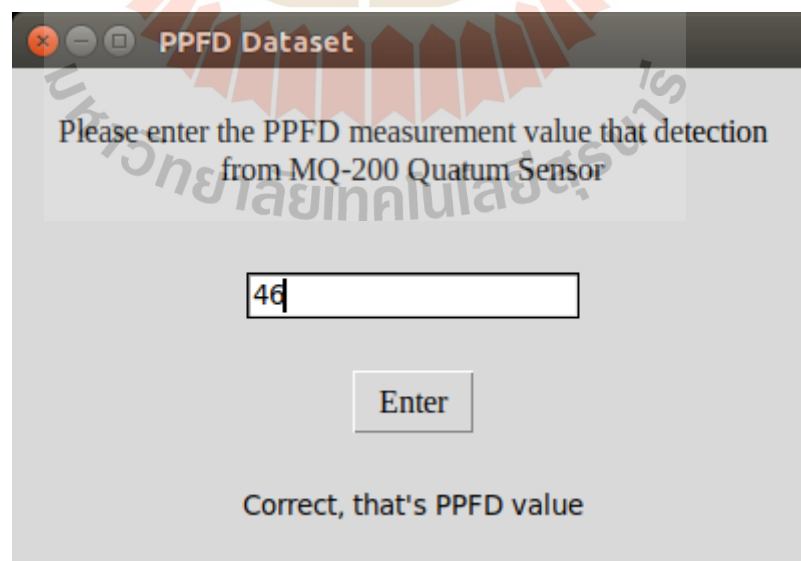
รูปแบบที่หนึ่ง คือ โครงข่ายประสาทเทียมสามารถตรวจจับความเข้มแสงแอลอีดีได้ว่าระดับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินมีสัดส่วนตามที่ระยะการเจริญเติบโตของพืชซึ่งสัดส่วนหรืออัตราส่วนความเข้มแสงแอลอีดีสีแดงและสีน้ำเงิน 25% : 75% สำหรับระยะเพาะกล้า (Seeding) และสัดส่วนหรืออัตราส่วนความเข้มแสงแอลอีดีสีแดงและสีน้ำเงิน 50% : 50% สำหรับระยะการเจริญเติบโต (Vegative Growth) โดยในรูปแบบที่หนึ่งจะเป็นผลลัพธ์ที่โครงข่ายประสาทเทียมตรวจจับแล้วพบว่าถูกต้องตามช่วงอายุของพืชตามเวลาจริง ถ้าเช่นนั้นจะไม่ถูกปรับความเข้มแสงแอลอีดีและสิ้นสุดการทำงานของโปรแกรม ตามรูปภาพที่ 4.17 จนถึง 4.20 เป็นการยกตัวอย่างการทำงานตามเหตุการณ์ที่พืชอยู่ในช่วงอายุการเพาะกล้า โดยที่ได้ต้องปรับความเข้มแสงแอลอีดีให้มีอัตราส่วนสีแดงต่อสีน้ำเงินคือ 25% : 75%



รูปที่ 4.17 ตัวอย่างหน้าต่างโปรแกรมควบคุมความเข้มแสงแอลอีดีตามอัตราส่วน 25% : 75%



รูปที่ 4.18 ตัวอย่างหน้าต่าง โปรแกรมเพื่อตรวจจับความเข้มแสงแอลอีดีตามอัตราส่วน 25% : 75%




รูปที่ 4.19 ตัวอย่างหน้าต่าง โปรแกรมในการป้อนค่าความเข้มแสง PPFD เพื่อตรวจจับ



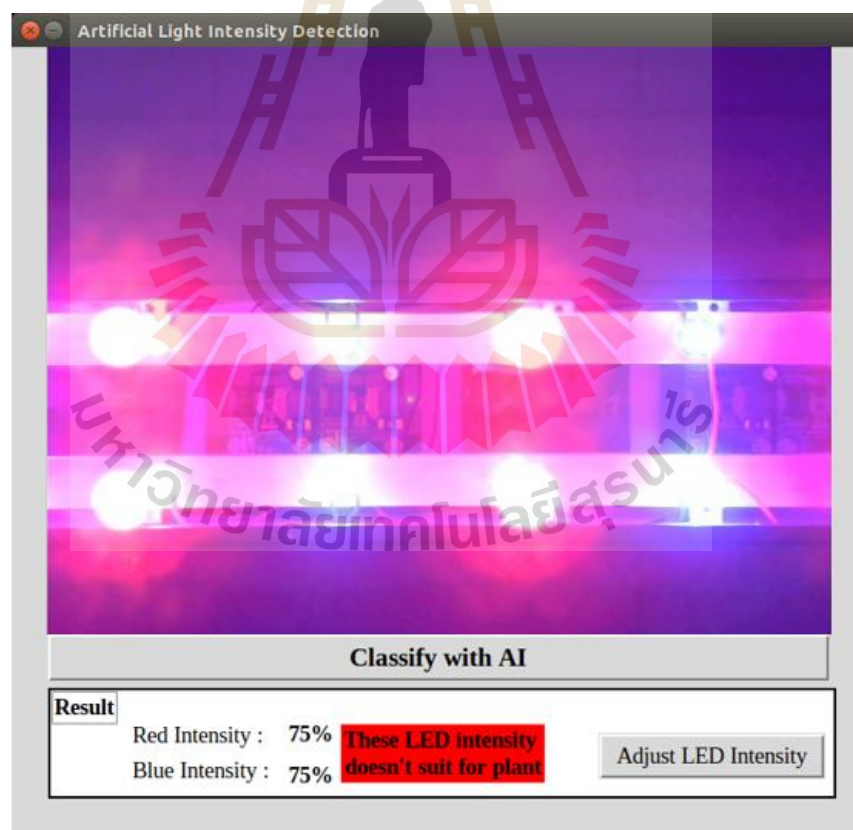
รูปที่ 4.20 ตัวอย่างหน้าต่าง โปรแกรมแสดงผลพัทธ์ของการตรวจจับความเข้มแสงแอลอีดี

#### 4.4.2 การออกแบบโปรแกรมการตรวจจับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินในเงื่อนไขสำหรับการตรวจจับที่ไม่ถูกต้อง

รูปแบบที่สอง คือ โครงข่ายประสาทเทียมสามารถตรวจจับความเข้มแสงแอลอีดีได้ว่าระดับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินมีส่วนไม่เป็นไปตามที่ระยะการเจริญเติบโตของพืช ซึ่งสัดส่วนหรืออัตราส่วนความเข้มแสงแอลอีดีสีแดงและสีน้ำเงิน 75% : 75% โดยในรูปแบบที่สองจะเป็นผลลัพธ์ที่โครงข่ายประสาทเทียมตรวจจับแล้วพบว่าไม่ถูกต้องตามช่วงอายุของพืชตามเวลาจริง ถ้าเช่นนั้นจะถูกปรับเปลี่ยนระดับความเข้มแสงแอลอีดีให้เหมาะสม จากนั้นทำการตรวจจับอีกครั้งเพื่อทดสอบความถูกต้องและสิ้นสุดการทำงานของโปรแกรม ตามรูปภาพที่ 4.21 จนถึง 4.26 เป็นการยกตัวอย่างการทำงานตามเหตุการณ์ที่พืชอยู่ในช่วงอายุการเพาะกล้าแต่ควบคุมอัตราส่วนระดับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินที่ 75% : 75% จึงต้องทำการปรับเปลี่ยนเป็นอัตราส่วน 25% : 75% ตามช่วงอายุการเพาะกล้า




รูปที่ 4.21 ตัวอย่างหน้าต่างโปรแกรมควบคุมความเข้มแสงแอลอีดีตามอัตราส่วน 75% : 75%




รูปที่ 4.22 ตัวอย่างหน้าต่างโปรแกรมเพื่อตรวจจับความเข้มแสงแอลอีดีตามอัตราส่วน 75% : 75%



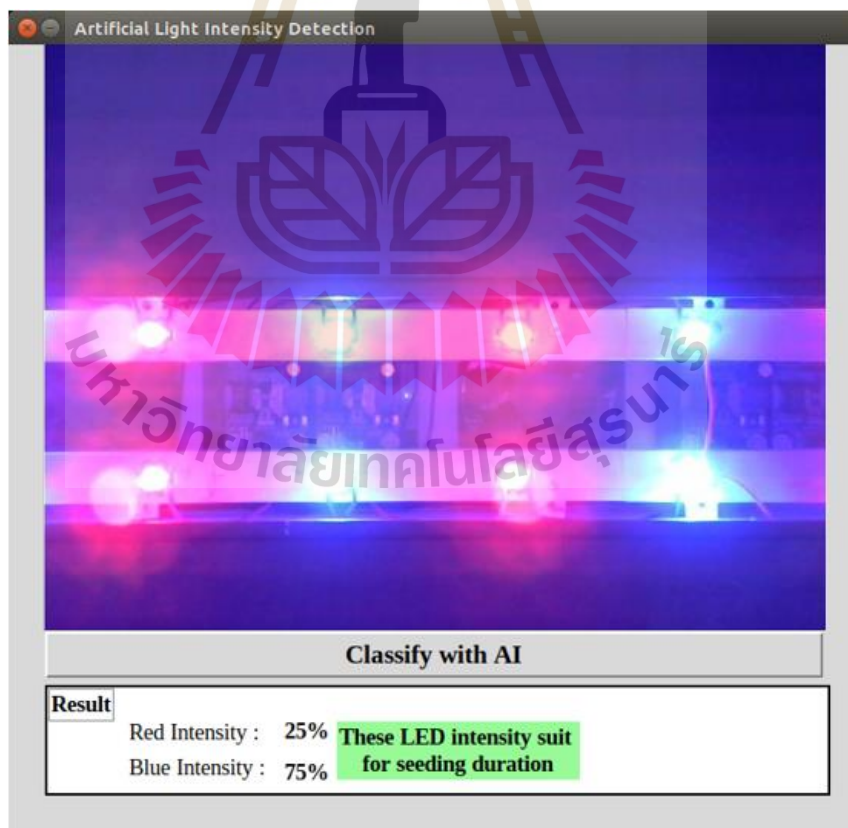
รูปที่ 4.23 ตัวอย่างหน้าต่างโปรแกรมที่ระบุสถานะและปรับเปลี่ยนความเข้มแอลอีดีเพื่อความเหมาะสม



รูปที่ 4.24 ตัวอย่างหน้าต่างการปรับเปลี่ยนความเข้มแสงให้เหมาะสมตามช่วงอายุของพืชตามเวลาจริง



รูปที่ 4.25 ตัวอย่างหน้าต่างฟังก์ชันหลังจากปรับเปลี่ยนความเข้มแสงให้เหมาะสมตามช่วงอายุของพืชตามเวลาจริง




รูปที่ 4.26 ตัวอย่างหน้าต่างการตรวจจับความเข้มแสงแอลอีดีหลังจากการปรับเปลี่ยน




#### 4.4.3 การออกแบบโปรแกรมการตรวจจับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินในเงื่อนไขสำหรับการตรวจจับที่ไม่สามารถระบุได้

รูปแบบที่สาม คือ โครงข่ายประสาทเทียมสามารถตรวจจับความเข้มแสงแอลอีดีได้ว่าระดับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินมีส่วนไม่เกินไปตามที่ระยะการเจริญเติบโตของพืช ซึ่งสัดส่วนหรืออัตราส่วนความเข้มแสงแอลอีดีสีแดงและสีน้ำเงิน 19% : 80% โดยในรูปแบบที่สามจะเป็นผลลัพธ์ที่โครงข่ายประสาทเทียมตรวจจับแล้วพบว่าไม่ถูกต้องตามช่วงอายุของพืชตามเวลาจริงและไม่สามารถระบุได้เนื่องจากโครงข่ายประสาทเทียมไม่เคยถูกฝึกฝนสำหรับอัตราส่วนดังกล่าว ถ้าเช่นนั้นจะถูกปรับเปลี่ยนระดับความเข้มแสงแอลอีดี จากนั้นทำการตรวจจับอีกครั้งเพื่อทดสอบความถูกต้องและสิ้นสุดการทำงานของโปรแกรม ตามรูปภาพที่ 4.27 จนถึง 4.28 เป็นการยกตัวอย่างการทำงานตามเหตุการณ์ที่พืชอยู่ในช่วงอายุการเพาะกล้าแต่ควบคุมอัตราส่วนระดับความเข้มแสงแอลอีดีทั้งสีแดงและสีน้ำเงินที่ 19% : 80%




รูปที่ 4.27 ตัวอย่างหน้าต่างโปรแกรมควบคุมความเข้มแสงแอลอีดีตามอัตราส่วน 19% : 80%



รูปที่ 4.28 ตัวอย่างหน้าต่างโปรแกรมเพื่อตรวจจับความเข้มแสงแอลอีดีตามอัตราส่วนที่ไม่สามารถระบุได้

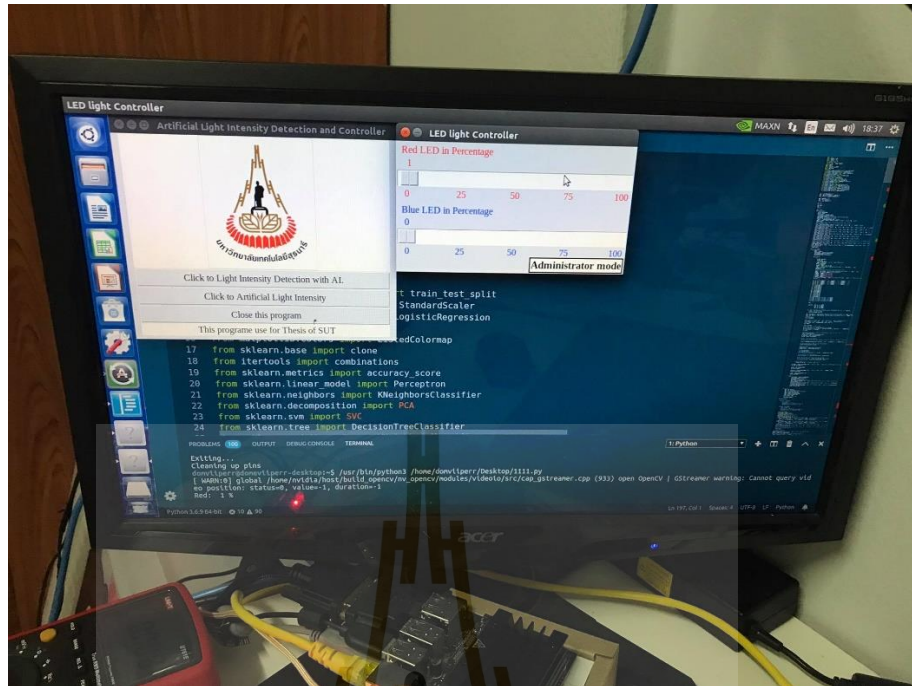
#### 4.5 การทดลองการควบคุมความสว่างของระบบควบคุมแสงแอลอีดีโดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument)

การทดลองการควบคุมความสว่างจำเป็นต้องมีการเทียบวัดกับเครื่องมือวัดทางไฟฟ้า เพื่อให้การควบคุมระดับแสงแอลอีดีมีมาตรฐานและน่าเชื่อถือ ซึ่งจะใช้เครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument) ในการวัดค่ากระแสไฟฟ้า ซึ่งรูปแบบการวัดกระแสไฟฟ้าจะเป็นไปตามรูปที่ 4.29



รูปที่ 4.29 การเชื่อมต่อวงจรเพื่อการทดลองการควบคุมความสว่างของระบบควบคุมแสงแอลอีดี โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิทัล (Digital Multimeter Instrument)

จากรูปที่ 4.29 เป็นแผนผังแสดงวงจรแสงแอลอีดีทั้งสีแดงและสีน้ำเงิน โดยจากรูปนี้ จะประกอบไปด้วย LED Driver จำนวน 5 เครื่อง แสงแอลอีดีสีน้ำเงินจำนวน 18 ดวง แสงแอลอีดีสีแดงจำนวน 16 ดวง จะเห็นว่าวงจรแสงแอลอีดีสีน้ำเงินเป็นวงจรเชื่อมต่อแบบขนานจำนวน 3 วงจร โดยแบ่งตาม LED Driver เครื่องที่ 1 ถึง เครื่องที่ 3 ดังนั้นกระแสไฟฟ้าของวงจรนี้จะถูกแบ่งจาก โหนดที่แบ่งออกเป็นสองฝั่ง โดยฝั่งแรกคือแสงแอลอีดีสีน้ำเงินดวงที่ 1 ถึงดวงที่ 3 แสงแอลอีดีสีน้ำเงินดวงที่ 7 ถึงดวงที่ 9 แสงแอลอีดีสีน้ำเงินดวงที่ 13 ถึงดวงที่ 15 จะมีกระแสระดับเท่ากับหรือใกล้เคียงกัน และอีกฝั่งคือแสงแอลอีดีสีแดงดวงที่ 4 ถึงดวงที่ 6 แสงแอลอีดีสีน้ำเงินดวงที่ 8 ถึงดวงที่ 12 แสงแอลอีดีสีน้ำเงินดวงที่ 16 ถึงดวงที่ 18 จะมีกระแสระดับเท่ากับหรือใกล้เคียงเช่นเดียวกัน ซึ่งรูปที่ 4.30 ถึง 4.33 เป็นรูปตัวอย่างการทำการเทียบว่าค่ากระแสไฟฟ้าจากเครื่องมือวัด



รูปที่ 4.30 แสดงการควบคุมระดับความเข้มแสงแอลอีดีผ่านหน้าจออินเตอร์



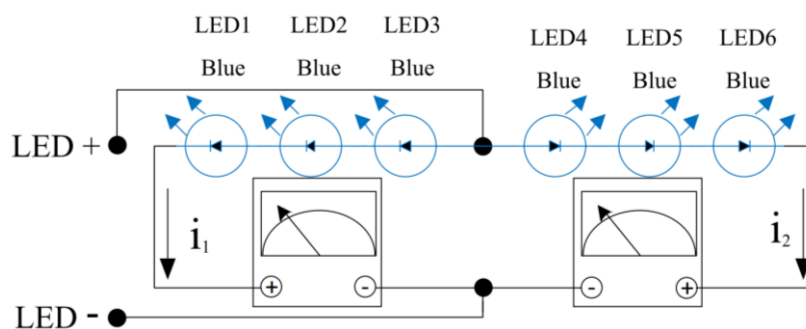
รูปที่ 4.31 แสดงการจัดวางอุปกรณ์ควบคุมการส่องสว่างของแผงแสงแอลอีดี



รูปที่ 4.32 แสดงการเชื่อมต่อ Digital Multimeter เพื่อการทดลอง



รูปที่ 4.33 แสดงผลการวัดค่ากระแสไฟฟ้าด้วย Digital Multimeter

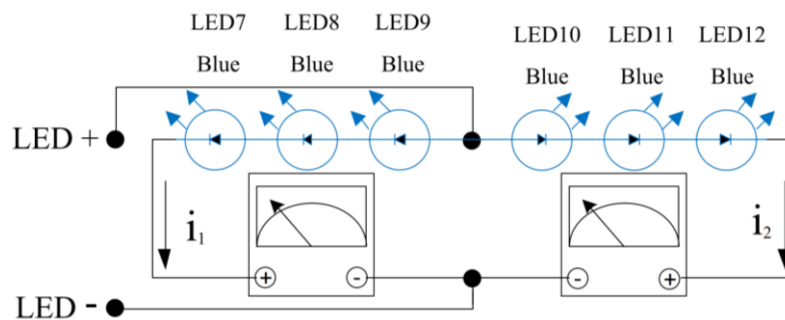


รูปที่ 4.34 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 1 - 6 โดยปรับเทียบกับ เครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument)

ตารางที่ 4.2 แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีน้ำเงิน ดวงที่ 1 - 6

ค่าความเข้มแสงแอลอีดีสีน้ำเงินในหน่วยเปอร์เซ็นต์	ค่าความเข้มแสง PPFD	ค่าระดับความสว่างของแสงแอลอีดี	$i_1$ กระแสไฟฟ้า (A) Blue LED 1 - 3	$i_2$ กระแสไฟฟ้า (A) Blue LED 4 - 6	กระแสไฟฟ้ารวม
25	10	16383.75	0.167	0.164	0.331
50	14	32767.5	0.342	0.346	0.688
75	20	49151.25	0.505	0.512	1.017
100	25	65535	0.672	0.654	1.326

จากรูปที่ 4.34 เป็นการเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 1 - 6 โดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument) ซึ่งผลการทดลองที่ได้นี้ จะถูกบันทึกค่าในตารางที่ 4.2 ซึ่งเป็นการบันทึกค่ากระแสไฟฟ้าโดยแบ่งออกเป็น 2 ค่าได้แก่ กระแสไฟฟ้า ( $i_1$ ) Blue LED 1 - 3 และ กระแสไฟฟ้า ( $i_2$ ) Blue LED 4 - 6 ในท้ายที่สุดจะนำกระแสไฟฟ้าทั้งสองนี้มารวมกัน ตามค่าในตารางนี้

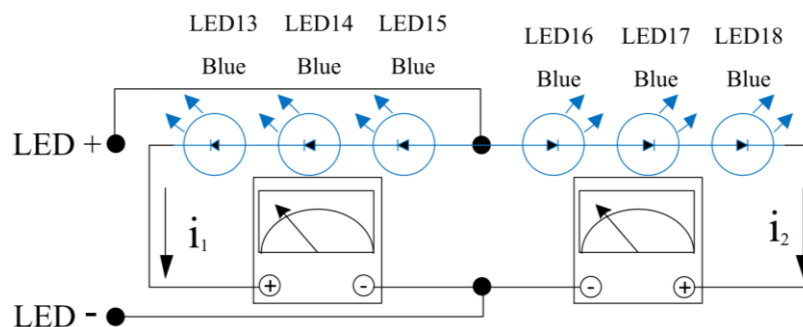


รูปที่ 4.35 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 7 - 12 โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิทัล (Digital Multimeter Instrument)

ตารางที่ 4.3 แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีน้ำเงินดวงที่ 7 - 12

ค่าความเข้มแสงแอลอีดีสีน้ำเงินในหน่วยเปอร์เซ็นต์	ค่าความเข้มแสง PPFd	ค่าระดับความสว่างของแสงแอลอีดี	$i_1$ กระแสไฟฟ้า (A) Blue LED 7 - 9	$i_2$ กระแสไฟฟ้า (A) Blue LED 10 - 12	กระแสไฟฟ้ารวม
25	10	16383.75	0.165	0.167	0.332
50	14	32767.5	0.330	0.341	0.671
75	20	49151.25	0.512	0.512	1.024
100	25	65535	0.651	0.652	1.303

จากรูปที่ 4.35 เป็นการเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 7 - 12 โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิทัล (Digital Multimeter Instrument) ซึ่งผลการทดลองที่ได้นี้ จะถูกบันทึกค่าในตารางที่ 4.3 ซึ่งเป็นการบันทึกค่ากระแสไฟฟ้าโดยแบ่งออกเป็น 2 ค่าได้แก่ กระแสไฟฟ้า ( $i_1$ ) Blue LED 7 - 9 และ กระแสไฟฟ้า ( $i_2$ ) Blue LED 10 - 12 ในท้ายที่สุดจะนำกระแสไฟฟ้าทั้งสองนี้มารวมกัน ตามค่าในตารางนี้




รูปที่ 4.36 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 13 - 18 โดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิทัล (Digital Multimeter Instrument)

ตารางที่ 4.4 แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีน้ำเงินดวงที่ 13 - 18

ค่าความเข้มแสงแอลอีดีสีน้ำเงินในหน่วยเปอร์เซ็นต์	ค่าความเข้มแสง PPF D	ค่าระดับความสว่างของแสงแอลอีดี	$i_1$ กระแสไฟฟ้า (A) Blue LED 13 - 15	$i_2$ กระแสไฟฟ้า (A) Blue LED 16 - 18	กระแสไฟฟ้ารวม
25	10	16383.75	0.167	0.168	0.335
50	14	32767.5	0.343	0.342	0.685
75	20	49151.25	0.511	0.518	1.029
100	25	65535	0.652	0.651	1.303

จากรูปที่ 4.36 เป็นการเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีน้ำเงินดวงที่ 13 - 18 โดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิทัล (Digital Multimeter Instrument) ซึ่งผลการทดลองที่ได้นี้ จะถูกบันทึกค่าในตารางที่ 4.4 ซึ่งเป็นการบันทึกค่ากระแสไฟฟ้าโดยแบ่งออกเป็น 2 ค่าได้แก่ กระแสไฟฟ้า ( $i_1$ ) Blue LED 13 - 15 และ กระแสไฟฟ้า ( $i_2$ ) Blue LED 16 - 18 ในท้ายที่สุดจะนำกระแสไฟฟ้าทั้งสองนี้มารวมกัน ตามค่าในตารางนี้






รูปที่ 4.37 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีแดงดวงที่ 1 - 8 โดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument)

ตารางที่ 4.5 แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีแดงดวงที่ 1 - 8

ค่าความเข้มแสงแอลอีดีสีแดงในหน่วยเปอร์เซ็นต์	ค่าความเข้มแสง PPF D	ค่าระดับความสว่างของแสงแอลอีดี	i กระแสไฟฟ้า (A) Red LED 1 - 8
25	14	16383.75	0.370
50	30	32767.5	0.752
75	46	49151.25	1.135
100	61	65535	1.5

จากรูปที่ 4.37 เป็นการเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีแดงดวงที่ 1 - 8 โดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument) ซึ่งผลการทดลองที่ได้นี้ จะถูกบันทึกค่าในตารางที่ 4.5 ซึ่งเป็นการบันทึกค่ากระแสไฟฟ้าคือ กระแสไฟฟ้าที่ไหลผ่าน Red Led 1 – 8



รูปที่ 4.38 การเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีแดงดวงที่ 9 - 16 โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument)

ตารางที่ 4.6 แสดงการทดลองการปรับความสว่างของอุปกรณ์ควบคุมแสงแอลอีดีสีแดงดวงที่ 9 - 18


ค่าความเข้มแสงแอลอีดีสีแดงในหน่วยเปอร์เซ็นต์	ค่าความเข้มแสง PPFd	ค่าระดับความสว่างของแสงแอลอีดี	i กระแสไฟฟ้า (A) Red LED 9 - 18
25	14	16383.75	0.370
50	30	32767.5	0.751
75	46	49151.25	1.133
100	61	65535	1.5

จากรูปที่ 4.38 เป็นการเชื่อมต่อวงจรเพื่อวัดค่ากระแสไฟฟ้าแอลอีดีสีแดงดวงที่ 9 - 18 โดยเปรียบเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument) ซึ่งผลการทดลองที่ได้นี้ จะถูกบันทึกค่าในตารางที่ 4.6 ซึ่งเป็นการบันทึกค่ากระแสไฟฟ้าคือ กระแสไฟฟ้าที่ไหลผ่าน Red Led 9 - 18

ตารางที่ 4.7 แสดงค่ากระแสไฟฟ้าเฉลี่ยทั้งหมดจากค่ากระแสไฟฟ้าของแสงแอลอีดีสีน้ำเงิน

ค่าระดับความสว่างของแสงแอลอีดี	กระแสไฟฟ้ารวม (A) ตามตารางที่ 4.1	กระแสไฟฟ้ารวม (A) ตามตารางที่ 4.2	กระแสไฟฟ้ารวม (A) ตามตารางที่ 4.3	กระแสไฟฟ้าเฉลี่ย (A)
16383.75	0.331	0.332	0.335	0.333
32767.5	0.688	0.671	0.685	0.681
49151.25	1.017	1.024	1.029	1.023
65535	1.326	1.303	1.303	1.311

จากตารางที่ 4.7 เป็นการแสดงค่ากระแสไฟฟ้าเฉลี่ยทั้งหมดจากค่ากระแสไฟฟ้าของแสงแอลอีดีสีน้ำเงิน ซึ่งจะนำค่าที่ได้เหล่านี้ไปพลอตกราฟเพื่อนำเสนอความสัมพันธ์การปรับระดับความสว่างของแสงแอลอีดีกับค่ากระแสไฟฟ้าแสงแอลอีดีสีน้ำเงินตามรูปที่ 4.39




รูปที่ 4.39 กราฟแสดงความสัมพันธ์การปรับระดับความสว่างของแสงแอลอีดีสีน้ำเงินกับค่ากระแสไฟฟ้า

จากรูปที่ 4.39 พบว่าระดับความสว่างของแสงแอลอีดีสีน้ำเงินที่ 16383.75 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีน้ำเงินอยู่ที่ 0.333 พบว่าระดับความสว่างของแสงแอลอีดีสีน้ำเงินที่ 32767.5 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีน้ำเงินอยู่ที่ 0.681 พบว่าระดับความสว่างของแสงแอลอีดีสีน้ำเงินที่ 49151.25 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีน้ำเงินอยู่ที่ 1.023 และพบว่าระดับความสว่างของแสงแอลอีดีสีน้ำเงินที่ 65535 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีน้ำเงินอยู่ที่ 1.311 ซึ่งในท้ายที่สุดพบว่าการปรับระดับความสว่างของแสงแอลอีดีสีน้ำเงินมีค่าเพิ่มขึ้น ค่ากระแสไฟฟ้าของแสงแอลอีดีสีน้ำเงินที่จ่ายให้ก็จะเพิ่มขึ้นตาม โดยที่มีแนวโน้มที่เพิ่มขึ้นทำตามเอ็กซ์โพเนนเชียลของกระแสไฟฟ้าแอลอีดีสีน้ำเงิน

ตารางที่ 4.8 แสดงค่ากระแสไฟฟ้าเฉลี่ยทั้งหมดจากค่ากระแสไฟฟ้าของแสงแอลอีดีสีแดง

ค่าระดับความสว่าง ของแสงแอลอีดี	กระแสไฟฟ้ารวม (A) ตามตารางที่ 4.4	กระแสไฟฟ้ารวม (A) ตามตารางที่ 4.5	กระแสไฟฟ้า เฉลี่ย (A)
16383.75	0.370	0.370	<b>0.370</b>
32767.5	0.752	0.751	<b>0.751</b>
49151.25	1.135	1.133	<b>1.134</b>
65535	1.5	1.5	<b>1.5</b>

จากตารางที่ 4.8 เป็นการแสดงค่ากระแสไฟฟ้าเฉลี่ยทั้งหมดจากค่ากระแสไฟฟ้าของแสงแอลอีดีสีแดง ซึ่งจะนำค่าที่ได้เหล่านี้ไปพลอตกราฟเพื่อนำเสนอความสัมพันธ์การปรับระดับความสว่างของแสงแอลอีดีกับค่ากระแสไฟฟ้าแสงแอลอีดีสีแดงตามรูปที่ 4.40



รูปที่ 4.40 กราฟแสดงความสัมพันธ์การปรับระดับความสว่างของแสงแอลอีดีสีแดงกับค่ากระแสไฟฟ้า

จากรูปที่ 4.40 พบว่าระดับความสว่างของแสงแอลอีดีสีแดงที่ 16383.75 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีแดงอยู่ที่ 0.370 พบว่าระดับความสว่างของแสงแอลอีดีสีแดงที่ 32767.5 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีแดงอยู่ที่ 0.751 พบว่าระดับความสว่างของแสงแอลอีดีสีแดงที่ 49151.25 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีแดงอยู่ที่ 1.134 และพบว่าระดับความสว่างของแสงแอลอีดีสีแดงที่ 65535 จะมีกระแสไฟฟ้าสำหรับแสงแอลอีดีสีแดงอยู่ที่ 1.5 ซึ่งในท้ายที่สุดพบว่ามีการปรับระดับความสว่างของแสงแอลอีดีสีแดงมีค่าเพิ่มขึ้น ค่ากระแสไฟฟ้าของแสงแอลอีดีสีแดงที่จ่ายให้ก็จะเพิ่มขึ้นตาม โดยที่มีแนวโน้มที่เพิ่มขึ้นทำตามเอ็กซ์โพเนนเชียลของกระแสไฟฟ้าแอลอีดีแดง

#### 4.6 การควบคุมและตรวจจັบระดับความเข้มแสงแอลอีดีนำไปใช้งานจริงกับพืชผล

ในหัวข้อนี้ผู้วิจัยนำเสนอโดยแบ่งเป็นสามหัวข้อย่อยหลัก ๆ ได้แก่ 4.6.1 ผลการทดลองการใช้งานจริงกับพืชผลรอบที่หนึ่ง 4.6.2 ผลการทดลองการใช้งานจริงกับพืชผลรอบที่สอง ซึ่งพืชผลที่ใช้เป็นตัวอย่างการทดลองคือผักกาดหอมกรีนโอ๊ค (Green Oak Lettuce) และ 4.6.3 ผลการทดสอบโปรแกรมในการควบคุมและการตรวจจັบระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผล และในท้ายที่สุด ขั้นตอนการติดตั้งและการจัดวางอุปกรณ์เพื่อใช้ในการทดสอบ จะเป็นไปตามรูปที่ 4.41 จนถึงรูปที่ 4.46 ดังนี้



รูปที่ 4.41 แสดงการเตรียมอุปกรณ์ทั้งหมดในการควบคุมและตรวจจັบระดับความเข้มแสงแอลอีดี



รูปที่ 4.42 แสดงในส่วนการติดตั้งอุปกรณ์กล่องบรรจุไมโครคอนโทรลเลอร์และบอร์ดควบคุมแสง



รูปที่ 4.43 แสดงในส่วนการติดตั้งอุปกรณ์ภายในกล่องบรรจุไมโครคอนโทรลเลอร์และบอร์ดควบคุมแสง



รูปที่ 4.44 แสดงในส่วนการติดตั้งอุปกรณ์ภายในกล่องบรรจุ แปลงแหล่งจ่ายกระแสสลับเป็นกระแสตรง



รูปที่ 4.45 แสดงในส่วนการควบคุมด้วยโปรแกรมที่ออกแบบผ่านการแสดงภาพหน้าจอกอมพิวเตอร์



รูปที่ 4.46 ตัวอย่างการแสดงผลความสว่างหลังการควบคุมแสงแอลอีดี



รูปที่ 4.47 ตัวอย่างการเพาะต้นกล้าผักกาดหอมกรีนโอ๊คในถาดเพาะต้นกล้าจากแสงดวงอาทิตย์






รูปที่ 4.48 ตัวอย่างผักกาดหอมกรีนโอ๊คในถาดเพาะต้นกล้าจากแสงดวงอาทิตย์



รูปที่ 4.49 ตัวอย่างการเพาะต้นกล้าผักกาดหอมกรีนโอ๊คในถาดเพาะต้นกล้าจากแสงแอลอีดีแบบปรับค่าได้



รูปที่ 4.50 ตัวอย่างผักกาดหอมกรีนโอ๊คในถาดเพาะต้นกล้าจากแสงแอลอีดีแบบปรับค่าได้



รูปที่ 4.51 ตัวอย่างการวัดขนาดความสูงของลำต้นผักกาดหอมกรีนโอ๊ค



รูปที่ 4.52 ตัวอย่างการวัดขนาดความกว้างของลำต้นผักกาดหอมกรีนโอ๊ค

จากรูปที่ 4.51 และ 4.52 เป็นตัวอย่างการเก็บข้อมูลขนาดความสูงและความกว้างของลำต้นกรีนโอ๊คด้วยเครื่องมือวัดเวอร์เนียคาลิเปอร์ (Vernier Caliper)



รูปที่ 4.53 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) ครั้งที่หนึ่ง



รูปที่ 4.54 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) ครั้งที่สอง



รูปที่ 4.55 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) ครั้งที่สาม



ป

รูปที่ 4.56 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) โดยเฉลี่ยค่าทั้งหมด



รูปที่ 4.57 ตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) กับลำต้นผักกาดหอมกรีนโอ๊ค

จากรูปที่ 4.53 ถึง 4.57 เป็นตัวอย่างการเก็บข้อมูลปริมาณคลอโรฟิลล์ (SPAD Unit) ด้วยเครื่องมือวัด Chlorophyll ซึ่งในการวัดแต่ละลำต้นจะทำการวัดที่ใบของพืชจำนวน 3 ใบต่อ 1 จำนวนลำต้น ซึ่งรูปที่ 4.53 4.54 และ 4.55 ตามลำดับ จากนั้นทำการเฉลี่ยโดยกดปุ่ม Average ตามรูปที่ 4.56 และรูปที่ 4.57 เป็นตัวอย่างการวัดปริมาณคลอโรฟิลล์ (SPAD Unit) กับลำต้นผักกาดหอมกรีนโอ๊ค


ในส่วนสุดท้ายจะเป็นการนำเสนอการวัดน้ำหนักลำต้นและรากของผักกาดหอมกรีนโอ๊ค ซึ่งจะถูกนำเสนอ ตามตัวอย่างรูปที่ 4.58 ถึง รูปที่ 4.60



รูปที่ 4.58 ตัวอย่างลำต้นและรากของผักกาดหอมกรีนโอ๊ค โดยส่วนแรกคือ ผักกาดหอมกรีนโอ๊คที่ได้จากแสงแอลอีดีแบบปรับค่าได้ (ด้านบน) และผักกาดหอมกรีนโอ๊คที่ได้จากแสงดวงอาทิตย์ (ด้านล่าง)




รูปที่ 4.59 ตัวอย่างการเก็บข้อมูลน้ำหนักรากของฝักกาดหอมกรีน ไอ้ค



รูปที่ 4.60 ตัวอย่างการเก็บข้อมูลน้ำหนักลำต้นของฝักกาดหอมกรีน ไอ้ค

#### 4.6.1 ผลการทดลองการใช้งานจริงกับพืชผลรอบที่ 1

การทดลองการปลูกผักกาดหอมกรีนโอ๊ค (Green Oak Lettuce) รอบที่ 1 จะทำการแบ่งการลองแหล่งกำเนิดแสงออกเป็นสองแบบ คือ แหล่งกำเนิดแสงแอลอีดีปรับค่าได้ที่ได้นำเสนอไป จำนวนการใช้พืชผล 10 ต้น และแหล่งกำเนิดแสงจากดวงอาทิตย์ จำนวนการใช้พืชผล 10 ต้น ซึ่งจะนำทั้งสองแบบมาเปรียบเทียบกัน เพื่อทดสอบประสิทธิภาพของอุปกรณ์ รวมถึงวิธีการที่ได้นำเสนอโดยผู้วิจัยมีความถูกต้อง มีความน่าเชื่อถือ และมีประสิทธิภาพเพียงพอในการนำไปใช้งานจริง และในท้ายที่สุดผู้วิจัยทำการปลูกพืชผลแบบกระถางแทนการปลูกพืชผลแบบไฮโดรโปนิกส์ ฤดูกาลในการปลูก เป็นฤดูร้อน ซึ่งอุณหภูมิอยู่ที่ 30 – 38 องศา โดยจำนวนวันการปลูกในรอบที่ 1 อยู่ที่ 45 วัน ดังนั้นอุณหภูมิเฉลี่ยจากจำนวนการปลูกคือ 33 องศา และสถานที่ในการปลูกคือหอพักวิภาวี ซึ่งเป็นห้องพักของผู้วิจัย โดยเลือกปลูกพืชผลที่หน้าห้องพัก ท้ายที่สุด ผู้วิจัยนำเสนอตัวอย่างปลูกผักกาดหอมกรีนโอ๊คด้วยแสงแอลอีดีปรับค่าและแสงดวงอาทิตย์ในรอบที่ 1 ตามรูปที่ 4.61 ถึงรูปที่ 4.63



รูปที่ 4.61 ตัวอย่างปลูกผักกาดหอมกรีนโอ๊คด้วยแสงแอลอีดีปรับค่าได้รอบที่ 1





รูปที่ 4.62 ตัวอย่างปลูกผักกาดหอมกรีน โฉลกด้วยแสงดวงอาทิตย์ได้รอบที่ 1 ส่วนที่ 1



รูปที่ 4.63 ตัวอย่างปลูกผักกาดหอมกรีน โฉลกด้วยแสงดวงอาทิตย์ได้รอบที่ 1 ส่วนที่ 2

ตารางที่ 4.9 แสดงการเจริญเติบโตของผักกาดหอมกรีนโอ๊คโดยใช้แสงแอลอีดีปรับค่าได้รอบที่ 1

วันที่		แสงแอลอีดีปรับค่าได้										ความสูงเฉลี่ยกรีนโอ๊ค
		ความสูง (เซนติเมตร) ของกรีนโอ๊ค										
		ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10	
*2	16/2/2564	2.28	3.98	1.9	1.07	3.34	2.09	1.72	0.94	1.6	1.85	2.077
*4	18/2/2564	2.52	4.29	2.11	1.47	3.96	2.28	1.98	0.96	1.8	1.89	2.326
*6	20/2/2564	2.59	4.61	2.26	2.37	4.52	2.47	2.13	1.05	2.32	1.98	2.63
*8	22/2/2564	3	5.05	2.69	2.94	4.77	2.61	2.2	1.23	3.12	2.25	2.986
*10	24/2/2564	3.01	5.12	2.91	3.11	4.89	2.9	2.3	1.7	3.17	2.29	3.14
*12	26/2/2564	3.22	6.05	3.09	3.12	5.17	3	3.02	2.33	3.37	2.57	3.494
*14	28/2/2564	3.93	6.33	3.11	3.35	5.37	3.43	3.72	2.38	3.8	3.49	3.891
*16	1/3/2564	4.12	6.55	3.62	3.7	5.8	3.8	3.86	2.49	3.97	4.02	4.193
18	3/3/2564	4.12	7.02	3.63	4.14	6.91	5.69	3.89	3.19	4.98	4.19	4.776
20	5/3/2564	4.39	7.32	4.31	4.88	6.96	6.2	4.27	3.3	5.09	4.47	5.119
22	7/3/2564	4.64	7.34	4.49	4.92	6.97	6.46	4.7	4.02	5.78	4.89	5.421
24	9/3/2564	4.8	7.76	4.73	4.99	7.04	6.73	4.78	4.03	6.42	4.92	5.62
26	11/3/2564	4.88	8.67	4.76	5.39	7.62	6.92	5.04	4.71	6.44	5.08	5.951
28	13/3/2564	5.16	9.5	4.96	5.76	8.13	7.23	5.44	4.73	6.62	5.32	6.285
30	15/3/2564	5.43	9.56	5.18	6.31	9.26	7.3	5.83	5.08	7.56	5.33	6.684
32	17/3/2564	5.54	9.69	5.26	7.02	9.39	7.36	6.37	5.11	7.64	5.35	6.873
34	19/3/2564	5.55	10.11	5.84	7.02	9.85	7.42	6.48	5.25	7.69	5.5	7.071
36	21/3/2564	6.03	10.27	5.97	7.52	11.32	8.94	7.7	5.33	8.11	5.57	7.676
38	23/3/2564	6.09	10.44	6.07	7.63	11.39	8.99	7.78	5.34	8.2	6.12	7.805
40	25/3/2564	6.42	10.57	6.16	8.84	11.91	9.25	8.18	5.58	8.25	6.55	8.171
42	27/3/2564	6.48	10.74	6.25	9.19	12.09	9.9	9.03	5.61	8.85	7.57	8.494
44	29/3/2564	6.7	11.26	6.4	9.23	12.23	9.9	9.25	5.9	9.04	8.21	8.748

\* หมายถึงวันที่ผักกาดหอมกรีนโอ๊คยังคงถูกเพาะต้นกล้าในถาดเพาะซึ่งมีจำนวนต้นกล้า 80 ต้น โดยทำการสุ่มตรวจจำนวน 10 ต้นที่คาดว่าสามารถเจริญเติบโตได้ดีที่สุด

ตารางที่ 4.10 แสดงการเจริญเติบโตของผักกาดหอมกรีนโอ๊คโดยใช้แสงดวงอาทิตย์รอบที่ 1

วันที่		แสงดวงอาทิตย์										ความสูงเฉลี่ยกรีนโอ๊ค
		ความสูง (เซนติเมตร) ของกรีนโอ๊ค										
		ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10	
*2	16/2/2564	3.34	1.73	2.64	1.63	1.1	1.45	1.93	3.38	1.14	1.83	2.017
*4	18/2/2564	3.45	1.93	2.88	2.16	1.12	2.19	2.58	3.42	1.23	1.96	2.292
*6	20/2/2564	3.78	2.05	2.96	2.22	1.69	2.68	3.06	3.74	1.41	2.22	2.581
*8	22/2/2564	4.42	2.65	3.17	3.27	1.83	2.91	3.76	4.16	1.59	2.59	3.035
*10	24/2/2564	5.16	2.75	3.18	3.4	2.31	2.96	4.01	4.32	1.82	2.82	3.273
*12	26/2/2564	5.5	2.78	3.22	3.45	2.44	3.55	4.33	4.39	2.23	3.02	3.491
*14	28/2/2564	5.68	3	3.24	3.63	2.44	3.69	5.04	4.46	2.95	3.14	3.727
*16	1/3/2564	6.38	3.36	4.06	3.86	2.54	3.92	5.05	4.61	3.18	3.81	4.077
18	3/3/2564	6.88	3.47	4.27	4.33	2.63	3.93	5.63	4.67	3.57	3.94	4.332
20	5/3/2564	6.99	3.66	4.66	4.41	3.12	4.53	5.78	4.76	3.85	4.31	4.607
22	7/3/2564	7.3	3.69	4.75	4.64	3.62	4.62	5.84	5.15	3.97	4.46	4.804
24	9/3/2564	7.48	4.28	4.83	4.78	3.9	4.63	6.07	6.2	4.02	4.81	5.1
26	11/3/2564	8.14	4.37	4.9	4.89	4.3	4.76	6.18	6.25	4.16	4.82	5.277
28	13/3/2564	8.84	4.48	5.02	5.04	4.7	5.03	6.52	6.57	4.27	4.97	5.544
30	15/3/2564	8.9	4.57	5.31	5.18	4.89	5.1	7.07	7.03	4.5	5.05	5.76
32	17/3/2564	9.02	4.79	5.69	5.18	5.29	5.19	7.5	7.47	4.51	5.64	6.028
34	19/3/2564	9.63	4.95	5.74	5.23	5.36	5.23	7.59	7.88	4.55	5.9	6.206
36	21/3/2564	9.65	5.02	5.74	5.31	5.43	5.89	7.85	8.36	4.76	6.01	6.402
38	23/3/2564	10.49	5.46	6.17	5.63	5.54	6.45	7.9	8.44	4.77	6.29	6.714
40	25/3/2564	10.67	5.5	6.4	5.7	5.59	6.53	8.37	8.51	5.46	6.76	6.949
42	27/3/2564	11.6	5.89	6.46	5.78	5.68	6.73	9.01	8.83	5.91	6.89	7.278
44	29/3/2564	11.66	6.18	6.84	5.79	5.96	6.96	9.27	9.27	6.21	7.37	7.551

\* หมายถึงวันที่ผักกาดหอมกรีนโอ๊คยังคงถูกเพาะต้นกล้าในถาดเพาะซึ่งมีจำนวนต้นกล้า 80 ต้น โดยทำการสุ่มตรวจจำนวน 10 ต้นที่คาดว่าจะสามารถเจริญเติบโตได้ดีที่สุด

ตารางที่ 4.11 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน ไอ้คจากแสงแอลอีดีปรับค่าได้ รอบที่ 1 หลังการเก็บเกี่ยว

พารามิเตอร์	แสงแอลอีดีปรับค่าได้									
	ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10
ความสูง (เซนติเมตร)	7.11	11.87	6.52	9.33	12.4	10.15	9.53	6.03	9.46	8.64
ความกว้าง (เซนติเมตร)	19.5	22.7	20.5	21.6	23	20.3	20.95	19.2	21.2	20.1
น้ำหนักของราก (กรัม)	8.31	10.9	8.56	11.49	9	10.58	13.5	5.6	8.3	8.92
น้ำหนักของต้น (กรัม)	38.04	43.44	37	45.6	34.61	46.88	34.11	30.62	32.85	31.18
ปริมาณคลอโรฟิลล์ (SPAD Unit)	24.6	23	22.9	23.8	24.4	26.3	27.6	24	23.5	25.6

ตารางที่ 4.12 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน ไอ้คจากแสงดวงอาทิตย์ รอบที่ 1 หลังการเก็บเกี่ยว

พารามิเตอร์	แสงดวงอาทิตย์									
	ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10
ความสูง (เซนติเมตร)	11.7	6.4	7.01	6.02	6.05	7.25	9.46	9.33	6.52	7.5
ความกว้าง (เซนติเมตร)	21	20.5	17	19.1	19.2	20.3	21.2	17.54	20.5	18.53
น้ำหนักของราก (กรัม)	5.52	6.27	7.61	9.65	10.78	8.9	7.32	8.28	9.14	9.15
น้ำหนักของต้น (กรัม)	28.62	28.52	37.09	46.86	42.65	30.81	29.91	36.45	35.61	43.45
ปริมาณคลอโรฟิลล์ (SPAD Unit)	21.1	22.1	22.0	22.6	23.2	21.9	19.9	20.5	21.0	20.5

ตารางที่ 4.13 สรุปผลการทดลองการใช้งานจริงกับผักกาดหอมกรีน ไอ้ครอบที่ 1 หลังการเก็บเกี่ยว

พารามิเตอร์	กรีนไอ้ค	
	แสงแอลอีดีปรับค่าได้	แสงดวงอาทิตย์
ความสูง (เซนติเมตร)	9.104	7.72
ความกว้าง (เซนติเมตร)	20.905	19.48
น้ำหนักของราก (กรัม)	9.516	8.262
น้ำหนักของต้น (กรัม)	37.433	35.997
ปริมาณคลอโรฟิลล์ (SPAD Unit)	24.57	21.48

จากตารางที่ 4.13 เป็นการสรุปผลการทดลองการใช้งานจริงกับผักกาดหอมกรีนโอ๊ครอบที่ 1 หลังการเก็บเกี่ยว ซึ่งพบว่าค่าความสูง (เซนติเมตร) ความกว้าง (เซนติเมตร) น้ำหนักของราก (กรัม) น้ำหนักของต้น (กรัม) และปริมาณคลอโรฟิลล์ (SPAD Unit) ที่ได้จากแสงแอลอีดีปรับค่าได้มีค่าพารามิเตอร์ที่มากกว่าจากแสงดวงอาทิตย์

#### 4.6.2 ผลการทดลองการใช้งานจริงกับพืชผลรอบที่ 2

การทดลองการปลูกผักกาดหอมกรีนโอ๊ค (Green Oak Lettuce) รอบที่ 2 จะทำการทดลองแบบการทดลองการปลูกแบบรอบที่ 1 ทุกประการ เพื่อเน้นย้ำผลการทดสอบและประสิทธิภาพในการทดลอง ทำยที่สุด ผู้วิจัยนำเสนอตัวอย่างปลูกผักกาดหอมกรีนโอ๊คด้วยแสงแอลอีดีปรับค่าและแสงดวงอาทิตย์ในรอบที่ 2 ตามรูปที่ 4.64 ถึง 4.66



รูปที่ 4.64 ตัวอย่างปลูกผักกาดหอมกรีนโอ๊คด้วยแสงแอลอีดีปรับค่าได้รอบที่ 2



รูปที่ 4.65 ตัวอย่างปลูกผักกาดหอมกรีน โฉลกด้วยแสงดวงอาทิตย์ได้รอบที่ 2 ส่วนที่ 1



รูปที่ 4.66 ตัวอย่างปลูกผักกาดหอมกรีน โฉลกด้วยแสงดวงอาทิตย์ได้รอบที่ 2 ส่วนที่ 2

ตารางที่ 4.14 แสดงการเจริญเติบโตของผักกาดหอมกรีน โอ๊คโดยใช้แสงแอลอีดีปรับค่าได้รอบที่ 2

วันที่		แสงแอลอีดีปรับค่าได้										ความสูงเฉลี่ยกรีนโอ๊ค
		ความสูง (เซนติเมตร) ของกรีนโอ๊ค										
		ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10	
*2	1/4/2564	3.03	2.69	2.71	1.27	2.72	2.81	1.64	1.47	2.06	1.91	2.231
*4	3/4/2564	3.11	3.09	2.78	1.9	2.74	3.41	1.68	1.57	2.2	2.56	2.504
*6	5/4/2564	3.13	3.15	3.2	2.23	2.83	3.43	1.75	1.95	2.35	2.69	2.671
*8	7/4/2564	3.39	3.55	3.28	2.48	3.22	3.88	1.86	2.18	2.39	2.84	2.907
*10	9/4/2564	3.44	3.88	3.82	2.89	3.42	4.1	2.3	2.83	2.88	3.29	3.285
*12	11/4/2564	3.46	4.2	3.96	4.11	3.51	4.25	2.33	3.21	3.46	3.36	3.585
*14	13/4/2564	4.35	4.42	3.98	4.81	3.88	5.5	3.05	3.86	3.77	3.45	4.107
*16	15/4/2564	4.81	5.11	4.43	4.82	4.01	5.53	3.18	4.08	4.12	3.6	4.369
18	17/4/2564	4.88	6.05	4.76	5.03	4.53	6.51	3.21	4.11	4.21	3.87	4.716
20	19/4/2564	4.92	6.5	4.96	5.48	6.5	6.57	3.38	4.35	4.3	3.89	5.085
22	21/4/2564	5.02	6.67	5.9	6.51	6.72	6.65	3.58	4.43	4.42	3.91	5.381
24	23/4/2564	5.36	6.75	5.98	6.54	7.02	6.71	3.97	4.5	4.8	3.92	5.555
26	25/4/2564	5.48	6.9	6.23	6.71	8.43	6.73	4.08	4.51	5.18	4.3	5.855
28	27/4/2564	6.79	6.96	6.29	6.73	8.49	6.95	4.22	4.84	5.31	4.59	6.117
30	29/4/2564	6.99	7.14	6.36	6.91	8.9	7.02	4.92	5.29	7.17	4.97	6.567
32	1/5/2564	7	7.83	6.59	7.51	9.18	7.36	5.12	5.69	7.34	5.09	6.871
34	3/5/2564	7.19	8.17	6.65	7.95	9.32	7.38	5.25	5.83	7.56	5.12	7.042
36	5/5/2564	7.45	9.03	8.23	8.19	9.61	7.67	5.44	5.85	7.98	5.22	7.467
38	7/5/2564	7.49	9.16	8.37	8.32	9.63	8.13	6.14	5.85	8.24	5.61	7.694
40	9/5/2564	7.65	9.28	9.03	8.36	10.38	8.26	6.51	5.87	8.4	5.88	7.962
42	11/5/2564	8.05	9.57	9.21	8.55	10.41	8.61	6.76	6.26	8.82	5.89	8.213
44	13/5/2564	8.23	10.12	9.42	9.13	10.96	9.21	8.7	6.38	8.84	6.1	8.706

\* หมายถึงวันที่ผักกาดหอมกรีน โอ๊คยังคงถูกเพาะต้นกล้าในถาดเพาะซึ่งมีจำนวนต้นกล้า 80 ต้น โดยทำการสุ่มตรวจจำนวน 10 ต้นที่คาดว่าจะสามารถเจริญเติบโตได้ดีที่สุด

ตารางที่ 4.15 แสดงการเจริญเติบโตของผักกาดหอมกรีนโอ๊คโดยใช้แสงดวงอาทิตย์รอบที่ 2

วันที่		แสงดวงอาทิตย์										ความสูงเฉลี่ยกรีนโอ๊ค
		ความสูง (เซนติเมตร) ของกรีนโอ๊ค										
		ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10	
*2	1/4/2564	2.34	2.07	1.37	1.81	2.66	3.14	1.91	1.04	1.19	2.24	1.977
*4	3/4/2564	2.49	2.56	1.51	2.4	2.92	3.18	1.93	1.32	1.33	2.74	2.238
*6	5/4/2564	2.55	3.21	1.65	2.62	3.06	3.22	2.11	1.48	1.45	2.82	2.417
*8	7/4/2564	3.26	3.59	1.83	2.91	3.13	3.22	2.77	1.58	1.47	3.98	2.774
*10	9/4/2564	3.51	3.65	1.84	3.01	3.35	4.08	2.82	1.69	1.75	4.19	2.989
*12	11/4/2564	4.02	4.49	2.16	3.03	3.4	4.26	3.04	1.98	1.85	4.3	3.253
*14	13/4/2564	4.47	5.07	2.29	3.1	3.67	4.56	3.07	2.4	2.15	4.62	3.54
*16	15/4/2564	4.77	5.13	2.7	3.2	3.92	5.14	3.09	2.48	2.42	4.64	3.749
18	17/4/2564	4.8	5.26	2.74	3.66	3.93	5.92	3.2	2.54	2.48	4.66	3.919
20	19/4/2564	5.31	5.98	2.79	4.16	3.97	6.03	3.2	2.6	2.76	5.19	4.199
22	21/4/2564	5.71	6.04	2.95	4.35	3.98	6.21	3.25	2.64	3.36	5.39	4.388
24	23/4/2564	5.75	6.13	3.82	4.65	5.03	6.33	3.64	2.68	3.61	-	4.63
26	25/4/2564	5.91	6.3	4.14	4.65	5.05	6.4	4.09	3.02	3.64	-	4.8
28	27/4/2564	6.35	6.39	4.39	5.58	5.22	6.4	5.53	3.13	3.96	-	5.22
30	29/4/2564	6.6	6.65	4.43	5.75	5.46	6.48	5.64	3.39	4.03	-	5.38
32	1/5/2564	6.88	7.13	4.52	5.8	5.56	6.51	6.02	3.53	4.17	-	5.57
34	3/5/2564	7.19	7.25	4.97	5.89	6.15	6.7	6.23	4.43	4.26	-	5.9
36	5/5/2564	7.41	8.33	5.35	6.3	6.31	6.86	6.56	4.54	4.82	-	6.28
38	7/5/2564	7.48	8.69	5.83	6.4	6.84	6.97	6.61	4.69	4.93	-	6.49
40	9/5/2564	7.64	8.9	6.08	6.79	6.97	7.08	6.64	4.97	4.97	-	6.67
42	11/5/2564	8.08	8.94	6.11	6.96	8.28	7.08	6.66	5	5.03	-	6.9
44	13/5/2564	8.35	9.78	6.31	7.22	8.32	7.17	6.78	5.56	5.46	-	7.22

\* หมายถึงวันที่ผักกาดหอมกรีนโอ๊คยังคงถูกเพาะต้นกล้าในถาดเพาะซึ่งมีจำนวนต้นกล้า 80 ต้น โดยทำการสุ่มตรวจจำนวน 10 ต้นที่คาดว่าจะสามารถเจริญเติบโตได้ดีที่สุด



ตารางที่ 4.16 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน ไอ้คจากแสงแอลอีดีปรับ  
ค่าได้รอบที่ 2 หลังการเก็บเกี่ยว

พารามิเตอร์	แสงแอลอีดีปรับค่าได้									
	ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10
ความสูง (เซนติเมตร)	8.32	10.12	9.45	9.3	11.12	9.53	8.7	6.55	9.14	6.58
ความกว้าง (เซนติเมตร)	19.43	21.36	21.5	20.36	24.1	19.3	19.7	18.84	19.79	17.56
น้ำหนักของราก (กรัม)	7.35	7.49	7.84	11.00	8.49	9.22	7.04	10.23	9.01	12.21
น้ำหนักของต้น (กรัม)	27.54	31.28	33.18	39.09	34.99	40.82	30.32	44.24	31.94	48.46
ปริมาณคลอโรฟิลล์ (SPAD Unit)	23.1	24.1	28.0	23.6	23.2	21.9	24.9	20.5	21.0	28.5

ตารางที่ 4.17 แสดงผลการทดลองกับการใช้งานจริงกับผักกาดหอมกรีน ไอ้คจากแสงดวงอาทิตย์  
รอบที่ 2 หลังการเก็บเกี่ยว

พารามิเตอร์	แสงดวงอาทิตย์									
	ต้นที่ 1	ต้นที่ 2	ต้นที่ 3	ต้นที่ 4	ต้นที่ 5	ต้นที่ 6	ต้นที่ 7	ต้นที่ 8	ต้นที่ 9	ต้นที่ 10
ความสูง (เซนติเมตร)	8.6	10.2	6.35	7.83	8.38	7.26	6.93	5.7	5.86	-
ความกว้าง (เซนติเมตร)	18.08	19.7	18.17	19.12	17.5	19.15	20.28	19.62	17.4	-
น้ำหนักของราก (กรัม)	6.16	8.95	5.4	9.65	5.68	8.13	6.82	9.18	9.82	-
น้ำหนักของต้น (กรัม)	24.12	26.8	30.15	45.18	40.36	28.5	32.21	38.45	36.5	-
ปริมาณคลอโรฟิลล์ (SPAD Unit)	19.1	20.5	20.7	21.9	20.9	20.4	23	19.6	19.5	-

ตารางที่ 4.18 สรุปผลการทดลองการใช้งานจริงกับผักกาดหอมกรีน ไอ้ครอบที่ 2 หลังการเก็บเกี่ยว

พารามิเตอร์	กรีนไอ้ค	
	แสงแอลอีดีปรับค่าได้	แสงดวงอาทิตย์
ความสูง (เซนติเมตร)	8.881	7.46
ความกว้าง (เซนติเมตร)	20.194	18.78
น้ำหนักของราก (กรัม)	8.988	7.754
น้ำหนักของต้น (กรัม)	36.186	33.585
ปริมาณคลอโรฟิลล์ (SPAD Unit)	23.88	20.62

จากตารางที่ 4.18 เป็นการสรุปผลการทดลองการใช้งานจริงกับผักกาดหอม กรีนโอ๊ครอบที่ 2 หลังการเก็บเกี่ยว ซึ่งพบว่าค่าความสูง (เซนติเมตร) ความกว้าง (เซนติเมตร) น้ำหนักของราก (กรัม) น้ำหนักของต้น (กรัม) และปริมาณคลอโรฟิลล์ (SPAD Unit) ที่ได้จากแสง แอลอีดีปรับค่าได้มีค่าพารามิเตอร์ที่มากกว่าจากแสงดวงอาทิตย์

#### 4.6.3 ผลการทดสอบโปรแกรมในการควบคุมและการตรวจจับระดับความเข้มแสง แอลอีดีในการใช้งานร่วมกับพืชผล

ในส่วนของหัวข้อย่อยนี้ ผู้วิจัยนำเสนอผลการทดสอบโปรแกรมโดยแสดงผลลัพธ์ เป็นเงื่อนไขของการตรวจจับระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 1 และ รอบที่ 2 ซึ่งผลการทดสอบจะถูกนำเสนอตามตารางที่ 4.19 และ 4.20 ตามลำดับ

ตารางที่ 4.19 แสดงผลการทดสอบโปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 1

วันที่	ระยะการเจริญเติบโตของพืชผล	ค่าความเข้มแสงแอลอีดีแดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่กำหนดให้กับพืชผล (%)	ผลลัพธ์ด้วยเงื่อนไขในการตรวจจับ		
			การตรวจจับถูกต้อง	การตรวจจับไม่ถูกต้อง	การตรวจจับไม่สามารถระบุได้
1	Seeding	25 : 75	✓		
2	Seeding	25 : 75	✓		
3	Seeding	25 : 75	✓		
4	Seeding	25 : 75	✓		
5	Seeding	25 : 75	✓		
6	Seeding	25 : 75	✓		
7	Seeding	25 : 75	✓		
8	Seeding	25 : 75	✓		
9	Seeding	25 : 75	✓		
10	Seeding	25 : 75	✓		
11	Seeding	25 : 75	✓		
12	Seeding	25 : 75	✓		

ตารางที่ 4.19 แสดงผลการทดสอบ โปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับระดับความ  
เข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 1 (ต่อ)

วันที่	ระยะการเจริญเติบโตของพืชผล	ค่าความเข้มแสงแอลอีดีที่แดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่กำหนดให้กับพืชผล (%)	ผลลัพธ์ด้วยเงื่อนไขในการตรวจจับ		
			การตรวจจับถูกต้อง	การตรวจจับไม่ถูกต้อง	การตรวจจับไม่สามารถระบุได้
13	Seeding	25 : 75	✓		
14	Seeding	25 : 75	✓		
15	Seeding	25 : 75	✓		
16	Seeding	25 : 75	✓		
17	Seeding	25 : 75	✓		
18	Seeding	25 : 75	✓		
19	Seeding	25 : 75	✓		
20	Seeding	25 : 75	✓		
21	Seeding	25 : 75	✓		
22	Seeding	25 : 75	✓		
23	Seeding	25 : 75	✓		
24	Seeding	25 : 75	✓		
25	Seeding	25 : 75	✓		
26	Vegative Growth (V.G.)	50 : 50	✓		
27	Vegative Growth (V.G.)	50 : 50	✓		
28	Vegative Growth (V.G.)	50 : 50	✓		
29	Vegative Growth (V.G.)	50 : 50	✓		

ตารางที่ 4.19 แสดงผลการทดสอบ โปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับระดับความ  
เข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 1 (ต่อ)

วันที่	ระยะการเจริญเติบโตของพืชผล	ค่าความเข้มแสงแอลอีดีที่แดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่กำหนดให้กับพืชผล (%)	ผลลัพธ์ด้วยเงื่อนไขในการตรวจจับ		
			การตรวจจับถูกต้อง	การตรวจจับไม่ถูกต้อง	การตรวจจับไม่สามารถระบุได้
30	Vegative Growth (V.G.)	50 : 50	✓		
31	Vegative Growth (V.G.)	50 : 50	✓		
32	Vegative Growth (V.G.)	50 : 50	✓		
33	Vegative Growth (V.G.)	50 : 50	✓		
34	Vegative Growth (V.G.)	50 : 50	✓		
35	Vegative Growth (V.G.)	50 : 50			✓
36	Vegative Growth (V.G.)	50 : 50	✓		
37	Vegative Growth (V.G.)	50 : 50	✓		
38	Vegative Growth (V.G.)	50 : 50	✓		
39	Vegative Growth (V.G.)	50 : 50	✓		
40	Vegative Growth (V.G.)	50 : 50	✓		

ตารางที่ 4.19 แสดงผลการทดสอบ โปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับระดับความ  
เข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 1 (ต่อ)

วันที่	ระยะการเจริญเติบโตของพืชผล	ค่าความเข้มแสงแอลอีดีที่แดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่กำหนดให้กับพืชผล (%)	ผลลัพธ์ด้วยเงื่อนไขในการตรวจจับ		
			การตรวจจับถูกต้อง	การตรวจจับไม่ถูกต้อง	การตรวจจับไม่สามารถระบุได้
41	Vegative Growth (V.G.)	50 : 50	✓		
42	Vegative Growth (V.G.)	50 : 50		✓	
43	Vegative Growth (V.G.)	50 : 50	✓		
44	Vegative Growth (V.G.)	50 : 50	✓		
45	Vegative Growth (V.G.)	50 : 50	✓		

ตามตารางที่ 4.19 จากผลการทดลองได้มีการสังเกตการณ์ช่วงอายุการเจริญเติบโตของพืชรอบที่ 1 ซึ่งพบว่าช่วงอายุตั้งแต่วันที่ 1 (ถ้าต้นทำการงอกขึ้นมาจากพื้นดินปลูก) จนถึงวันที่ 25 เป็นช่วงอายุการเพาะกล้า (Seeding) และช่วงอายุตั้งแต่วันที่ 26 จนถึงวันที่ 45 เป็นช่วงอายุการเจริญเติบโต (Vegative Growth) ได้ทำการตรวจจับระดับความเข้มแสงแอลอีดีว่าถูกต้องหรือไม่ด้วยเงื่อนไขในการตรวจจับที่ภู่านำเสนอในหัวข้อที่ 4.4 ซึ่งประกอบไปด้วยเงื่อนไขทั้งหมดสามเงื่อนไข ในการทดสอบจริง ผลลัพธ์ที่ได้จากนำไปใช้งานจริงกับพืชผลรอบที่ 1 ผลลัพธ์ที่ได้ในช่วงอายุการเพาะกล้า (Seeding) มีผลลัพธ์ของเงื่อนไขการตรวจจับถูกต้องอยู่ที่ 25 วัน และผลลัพธ์ที่ได้ในช่วงอายุการเจริญเติบโต (Vegative Growth) มีผลลัพธ์ของเงื่อนไขการตรวจจับถูกต้องอยู่ที่ 18 วัน จากทั้งหมด 20 วัน ซึ่งในผลลัพธ์ที่ผิดพลาดไปมี 2 วันได้แก่วันที่ 35 ที่มีผลลัพธ์ผิดพลาดไปเป็นเงื่อนไขการตรวจจับไม่สามารถระบุได้และวันที่ 42 ที่มีผลลัพธ์ผิดพลาดไปเป็นเงื่อนไขการตรวจจับไม่ถูกต้อง

ตารางที่ 4.20 แสดงผลการทดสอบ โปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับระดับความ  
เข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 2

วันที่	ระยะการเจริญเติบโตของพืชผล	ค่าความเข้มแสงแอลอีดีที่แดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่กำหนดให้กับพืชผล (%)	ผลลัพธ์ด้วยเงื่อนไขในการตรวจจับ		
			การตรวจจับถูกต้อง	การตรวจจับไม่ถูกต้อง	การตรวจจับไม่สามารถระบุได้
1	Seeding	25 : 75	✓		
2	Seeding	25 : 75	✓		
3	Seeding	25 : 75	✓		
4	Seeding	25 : 75	✓		
5	Seeding	25 : 75	✓		
6	Seeding	25 : 75	✓		
7	Seeding	25 : 75	✓		
8	Seeding	25 : 75	✓		
9	Seeding	25 : 75	✓		
10	Seeding	25 : 75	✓		
11	Seeding	25 : 75	✓		
12	Seeding	25 : 75	✓		
13	Seeding	25 : 75	✓		
14	Seeding	25 : 75	✓		
15	Seeding	25 : 75	✓		
16	Seeding	25 : 75			✓
17	Seeding	25 : 75	✓		
18	Seeding	25 : 75	✓		
19	Seeding	25 : 75	✓		
20	Seeding	25 : 75	✓		
21	Seeding	25 : 75	✓		
22	Seeding	25 : 75	✓		

ตารางที่ 4.20 แสดงผลการทดสอบ โปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับระดับความ  
เข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 2 (ต่อ)

วันที่	ระยะการเจริญเติบโตของพืชผล	ค่าความเข้มแสงแอลอีดีที่แสดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่กำหนดให้กับพืชผล (%)	ผลลัพธ์ด้วยเงื่อนไขในการตรวจจับ		
			การตรวจจับถูกต้อง	การตรวจจับไม่ถูกต้อง	การตรวจจับไม่สามารถระบุได้
23	Seeding	25 : 75	✓		
24	Seeding	25 : 75	✓		
25	Seeding	25 : 75	✓		
26	Vegative Growth (V.G.)	50 : 50	✓		
27	Vegative Growth (V.G.)	50 : 50	✓		
28	Vegative Growth (V.G.)	50 : 50	✓		
29	Vegative Growth (V.G.)	50 : 50	✓		
30	Vegative Growth (V.G.)	50 : 50	✓		
31	Vegative Growth (V.G.)	50 : 50	✓		
32	Vegative Growth (V.G.)	50 : 50	✓		
33	Vegative Growth (V.G.)	50 : 50	✓		
34	Vegative Growth (V.G.)	50 : 50	✓		

ตารางที่ 4.20 แสดงผลการทดสอบ โปรแกรมด้วยผลลัพธ์ในเงื่อนไขของการตรวจจับระดับความ  
เข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลรอบที่ 2 (ต่อ)

วันที่	ระยะการเจริญเติบโตของพืชผล	ค่าความเข้มแสงแอลอีดีที่แดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่กำหนดให้กับพืชผล (%)	ผลลัพธ์ด้วยเงื่อนไขในการตรวจจับ		
			การตรวจจับถูกต้อง	การตรวจจับไม่ถูกต้อง	การตรวจจับไม่สามารถระบุได้
35	Vegative Growth (V.G.)	50 : 50	✓		
36	Vegative Growth (V.G.)	50 : 50	✓		
37	Vegative Growth (V.G.)	50 : 50	✓		
38	Vegative Growth (V.G.)	50 : 50	✓		
39	Vegative Growth (V.G.)	50 : 50	✓		
40	Vegative Growth (V.G.)	50 : 50	✓		
41	Vegative Growth (V.G.)	50 : 50	✓		
42	Vegative Growth (V.G.)	50 : 50	✓		
43	Vegative Growth (V.G.)	50 : 50	✓		
44	Vegative Growth (V.G.)	50 : 50		✓	
45	Vegative Growth (V.G.)	50 : 50	✓		



ตามตารางที่ 4.20 จากผลการทดลองได้มีการสังเกตการณ์ช่วงอายุการเจริญเติบโตของพืชรอบที่ 2 ซึ่งพบว่าช่วงอายุตั้งแต่วันที่ 1 (ถ้าต้นทำการงอกขึ้นมาจากพื้นดินปลูก) จนถึงวันที่ 25 เป็นช่วงอายุการเพาะกล้า (Seeding) จึงทำการควบคุมระดับความเข้มแสงแอลอีดีสีแดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่ 25 : 75 และช่วงอายุตั้งแต่วันที่ 26 จนถึงวันที่ 45 เป็นช่วงอายุการเจริญเติบโต (Vegative Growth) จึงทำการควบคุมระดับความเข้มแสงแอลอีดีสีแดงต่อสีน้ำเงินในหน่วยเปอร์เซ็นต์ที่ 50 : 50 จากนั้นทำการตรวจจับระดับความเข้มแสงแอลอีดีว่าถูกต้องหรือไม่ ด้วยเงื่อนไขในการตรวจจับที่ถูกลำเสนอในหัวข้อที่ 4.4 ซึ่งประกอบไปด้วยเงื่อนไขทั้งหมดสามเงื่อนไข ในกรณีที่เงื่อนไขมีการตรวจจับถูกต้อง จะเป็นกรณีที่ดีที่สุดสำหรับการตรวจจับ ดังนั้นถ้าหากการปลูกทั้งหมด 25 วัน ในทำการตรวจจับแล้วพบว่าผลลัพ์ของเงื่อนไขมีการตรวจจับถูกต้องตลอด 25 วัน แสดงว่า ประสิทธิภาพของการตรวจจับด้วยวิธีการที่ผู้วิจัยออกแบบมีความถูกต้องแม่นยำสูงสุด แต่ในการทดสอบจริง ผลลัพ์ที่ได้จากนำไปใช้งานจริงกับพืชผลรอบที่ 1 ผลลัพ์ที่ได้ในช่วงอายุการเพาะกล้า (Seeding) มีผลลัพ์ของเงื่อนไขการตรวจจับถูกต้องอยู่ที่ 24 วัน จากทั้งหมด 25 วัน ซึ่งในผลลัพ์ที่ผิดพลาดไปมี 1 วัน ได้แก่วันที่ 16 ที่มีผลลัพ์ผิดพลาดไปเป็นเงื่อนไขการตรวจจับไม่สามารถระบุได้ และผลลัพ์ที่ได้ในช่วงอายุการเจริญเติบโต (Vagative Growth) มีผลลัพ์ของเงื่อนไขการตรวจจับถูกต้องอยู่ที่ 19 วัน จากทั้งหมด 20 วัน ซึ่งในผลลัพ์ที่ผิดพลาดไปมี 1 วัน ได้แก่วันที่ 44 ที่มีผลลัพ์ผิดพลาดไปเป็นเงื่อนไขการตรวจจับไม่ถูกต้อง

จากผลลัพ์ที่ได้ตามตารางที่ 4.19 และ 4.20 จะนำมาเปรียบเทียบประสิทธิภาพความถูกต้องตามตารางที่ 4.21

ตารางที่ 4.21 ผลการทดสอบโปรแกรมในการควบคุมและการตรวจจับระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลตามเงื่อนไขในการตรวจจับ

อันดับรอบผลลัพ์ในการตรวจจับ	ระยะการเจริญเติบโตของพืชผล	ความถูกต้อง (%)	เฉลี่ย (%)
ผลลัพ์การตรวจจับในรอบที่ 1	Seeding	100	95
	Vegative Growth	90	
ผลลัพ์การตรวจจับในรอบที่ 2	Seeding	96	95.5
	Vegative Growth	95	

จากตารางที่ 4.20 เป็นผลการทดสอบโปรแกรมในการควบคุมและการตรวจจับระดับความเข้มแสงแอลอีดีในการใช้งานร่วมกับพืชผลตามเงื่อนไขในการตรวจจับ ซึ่งนำมา

เปรียบเทียบกันด้วยความถูกต้องในหน่วยเปอร์เซ็นต์ จากการเก็บผลตามตารางที่ 4.18 และ 4.19 ดังนั้นผลลัพธ์ที่ได้ทั้งในการตรวจจับในรอบที่ 1 และ รอบที่ 2 คือ 95 % และ 95.5 % ตามลำดับ ซึ่งเป็นค่าความถูกต้องอยู่ในระดับที่ดีมาก แสดงถึงความแม่นยำและประสิทธิภาพสูงสำหรับวิธีที่ผู้วิจัยได้นำเสนอตั้งแต่การออกแบบ วิธีการ จนถึงผลลัพธ์ที่ได้

#### 4.7 สรุป

เนื้อหาในบทที่ 4 เป็นการนำเสนอวิธีการดำเนินงานและผลการทดสอบในส่วนที่ 2 การสร้างระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคนิคปัญญาประดิษฐ์ โดยมีรายละเอียดดังนี้

1. การออกแบบระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยเทคโนโลยีปัญญาประดิษฐ์ จะแบ่งระบบออกเป็นสองส่วนได้แก่ ส่วนของการสังเกตการณ์เจริญเติบโตของพืชเพื่อควบคุมระดับความเข้มแสงแอลอีดีให้เหมาะสมตามช่วงการเจริญเติบโตของผักกาดหอมกรีน โอ๊ค (Green Oak Lettuce) และส่วนของการตรวจจับความเข้มแสงแอลอีดีด้วยปัญญาประดิษฐ์ โดยระบบสองส่วนนี้จำเป็นอย่างยิ่งสำหรับให้ระบบทำงานสอดคล้องกัน

2. การออกแบบการสร้างและโปรแกรมระบบควบคุมและตรวจจับตรวจจับความระดับความเข้มแสงแอลอีดี ในส่วนนี้ผู้วิจัยได้นำเสนอการสร้างอุปกรณ์สำหรับการควบคุมแสงแอลอีดีรวมไปถึงการตรวจจับความเข้มแสงแอลอีดี ซึ่งในส่วนนี้จะถูกเรียกว่าส่วนฮาร์ดแวร์ โดยอุปกรณ์ที่มีส่วนสำคัญสำหรับการควบคุมและการตรวจจับความเข้มแสงแอลอีดีคือบอร์ดไมโครคอนโทรลเลอร์ Nvidia Jetson Nano Developer Kit จากนั้นทำการออกแบบโปรแกรมบนระบบปฏิบัติการของบอร์ดไมโครคอนโทรลเลอร์ เพื่อที่จะสามารถทำงานได้อย่างสะดวก อาทิ เช่น สามารถควบคุมแสงแอลอีดีสีแดงและสีน้ำเงินผ่านหน้าจอกอมพิวเตอร์ มีกล้องเพื่อตรวจจับภาพแสงแอลอีดี ใช้ปัญญาประดิษฐ์จำแนกประเภทภาพที่ตรวจจับ จากนั้นทำการระบุภาพที่ตรวจจับมีระดับความเข้มแสงแอลอีดีในหน่วยเปอร์เซ็นต์ และมีการระบุผลลัพธ์ระดับความเข้มแสงแอลอีดีว่ามีเหมาะสมต่อช่วงอายุของผักกาดหอมกรีน โอ๊คหรือไม่ ถ้าไม่จะมีระบบแนะนำผู้ใช้ ในการปรับความเข้มแสงแอลอีดีตามช่วงอายุให้เลือกตามการสังเกตการณ์

3. การทดลองการควบคุมความสว่างของระบบแสงแอลอีดีโดยปรับเทียบกับเครื่องมือวัดค่าทางไฟฟ้าแบบดิจิตอล (Digital Multimeter Instrument) ผลที่ได้พบว่า การปรับระดับความสว่างของแสงแอลอีดีสีแดงมีค่าเพิ่มขึ้น ค่ากระแสไฟฟ้าของแสงแอลอีดีสีแดงที่จ่ายให้ก็จะเพิ่มขึ้นตาม โดยที่มีแนวโน้มที่เพิ่มขึ้นทำตามเอ็กซ์โพเนนเชียลของกระแสไฟฟ้าแอลอีดีแดง

4. ผลการทดสอบการควบคุมและตรวจจับความระดับความเข้มแสงแอลอีดีนำไปใช้งานจริงกับพืชผล ในส่วนนี้ผู้วิจัยนำเสนอการนำแสงแอลอีดีมาใช้งานร่วมกับผักกาดหอมกรีนโอ๊ค (Green Oak Lettuce) ซึ่งทำการปลูกทั้งหมดสองรอบด้วยกัน โดยผลที่ได้พบว่า แสงแอลอีดีทั้งสีแดงและสีน้ำเงินที่มีพลังงานต่ำและมีสเปกตรัมเฉพาะเจาะจง จะมีการกระตุ้นการเจริญเติบโตได้ดี และสามารถกระตุ้นเฉพาะส่วนของพืชตามที่เราต้องการให้มีการเจริญเติบโตที่ดีได้ เช่น กระตุ้นในส่วนการเพาะเมล็ดหรือการอนุบาลพืชให้เจริญเติบโตได้ดีจากการเน้นปริมาณแสงแอลอีดีสีน้ำเงินหรือกระตุ้นในส่วนของใบที่กว้างกว่าเดิมและลำต้นมีขนาดที่สูงขึ้นจากการเน้นปริมาณแสงแอลอีดีสีแดง เมื่อเปรียบเทียบกับแสงดวงอาทิตย์ที่อาจจะมีขนาดของใบและลำต้นที่น้อยกว่าเล็กน้อยกว่า แต่อย่างไรก็ตาม ในความคิดเห็นของผู้วิจัยขอเสนอแนะว่า ควรปลูกด้วยแสงแอลอีดีสีแดงและสีน้ำเงิน แต่เพิ่มในส่วนของแสงดวงอาทิตย์หรือนำแสงแอลอีดีสีขาวมาใช้งานร่วม เพื่อให้เกิดประโยชน์สูงสุด

5. ผลการทดสอบโปรแกรมในการการควบคุมและตรวจจับความระดับความเข้มแสงแอลอีดีนำไปใช้งานจริงกับพืชผล พบว่าค่าความถูกต้องอยู่ในระดับที่ดีมาก แสดงถึงความแม่นยำและประสิทธิภาพสูงสำหรับวิธีที่ผู้วิจัยได้นำเสนอตั้งแต่การออกแบบ วิธีการ จนถึงผลลัพธ์ที่ได้

## บทที่ 5

### ข้อสรุปของโครงการ

#### 5.1 สรุปเนื้อหาวิทยานิพนธ์

ในปัจจุบันการปลูกพืชผลโดยใช้พลังงานแสงจากแอลอีดี (Light-Emitter Diode) ในการเกษตรสามารถลดการสิ้นเปลืองพลังงานได้อย่างมีประสิทธิภาพ รวมไปถึงยังสามารถควบคุมอุณหภูมิและสเปกตรัมที่แตกต่างกันและปรับแหล่งกำเนิดแสงได้อย่างยืดหยุ่นตามความต้องการช่วงอายุการเจริญเติบโตของพืชเพื่อเร่งอัตราการเติบโต มีประสิทธิภาพมากยิ่งขึ้น และการใช้พลังงานแสงแอลอีดีเป็นสิ่งที่แตกต่างจากการใช้พลังงานแสงจากดวงอาทิตย์และหลอดไฟชนิดที่ต่าง ๆ ที่รู้จักกัน โดยพื้นฐานแล้ว สิ่งที่น่าทึ่งกว่าคือการพัฒนาอย่างรวดเร็วของเทคโนโลยีแสงแอลอีดี ทำให้คุณสมบัติประหยัดพลังงานดีกว่าแหล่งกำเนิดแสงแบบเดิม ยิ่งไปกว่านี้คือการมาของปัญญาประดิษฐ์ (Artificial Intelligence) ที่มีระบบการทำงานเสมือนสมองมนุษย์ โดยมีแนวโน้มที่ในอนาคตจะมีการนำปัญญาประดิษฐ์เข้ามาแทรกอยู่ในเทคโนโลยีและนวัตกรรมต่าง ๆ ซึ่งจะนำไปสู่การเพิ่มพูนทั้งด้านมูลค่าและตอบโจทย์ในทางความต้องการของผู้ใช้งานทั้งในด้านธุรกิจด้านอุตสาหกรรม และด้านงานวิจัย ที่ให้ทั้งความรวดเร็ว และแม่นยำ ดังนั้นจึงได้ทำการคิดค้นเพื่อการปลูกพืชให้มีประสิทธิภาพ ก็คือการนำปัญญาประดิษฐ์มาประยุกต์ร่วมกับชุดอุปกรณ์พลังงานแสงแอลอีดี

ดังนั้นวิทยานิพนธ์ฉบับนี้จึงได้นำเสนอระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ โดยสรุปเนื้อหาวิทยานิพนธ์ได้ดังนี้

1. การออกแบบระบบตรวจจับความเข้มแสงแอลอีดีอัจฉริยะในโรงเรือนผ่านเหตุการณ์จำลอง โดยเป็นการออกแบบเหตุการณ์การเก็บข้อมูลเพื่อสกัดคุณลักษณะเฉพาะและการออกแบบเหตุการณ์ของเป้าหมายเพื่อนำข้อมูลที่ได้นี้ ไปวิเคราะห์และพัฒนาต่อในด้านฮาร์ดแวร์ของระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือน

2. การเตรียมข้อมูลในการฝึกฝนและทดสอบกับโครงข่ายประสาทเทียมและการทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมในการทำนายความเข้มแสงแอลอีดี เป็นการอธิบายถึงรายละเอียดของการเตรียมชุดข้อมูลในการฝึกฝนกับทดสอบ โดยแบ่งการเตรียมชุดข้อมูลหลัก ๆ ออกเป็น 2 ปริภูมิสี RGB และ ปริภูมิสี HSV จากนั้นทำการคัดเลือกโครงข่ายประสาทเทียมเพื่อเปรียบเทียบถึงค่าคุณลักษณะเฉพาะแบบใดมีประสิทธิภาพ มีความเหมาะสมและสามารถ

นำไปใช้งานได้จริง ซึ่งพบว่าชุดข้อมูลในปริภูมิสี HSV มีประสิทธิภาพและเหมาะสมกับโครงข่ายประสาทเทียมแรนด้อมฟอเรสต์ (Random Forest) ที่นำมาใช้งานร่วมกัน เพื่อให้ค่าความถูกต้อง (Accuracy) ในการจำแนกประเภท (Classification) ของข้อมูลและประสิทธิภาพสูงสุด (Performance)

3. ผลการทดสอบการควบคุมและตรวจจับความระดับความเข้มแสงแอลอีดีนำไปใช้งานจริงกับพืชผล โดยพบว่าการใช้แสงแอลอีดีแบบปรับค่าได้สามารถผลการเจริญเติบโตที่ดีได้ โดยจะเป็นส่วนของการการเพาะเมล็ดหรือการอนุบาลพืชและเน้นเฉพาะส่วน อาทิ เช่น ต้องการใบของพืช ลำต้น หรือ ดอกที่ใหญ่ขึ้น เป็นต้น แต่อย่างไรก็ตาม เพื่อให้ได้ประโยชน์สูงสุด จำเป็นต้องมีการใช้แสงจากดวงอาทิตย์ควบคู่ไปพร้อมกับการใช้แสงแอลอีดี เพื่อไม่เกิดปัญหาการยืดตัวของพืชผล และท้ายที่สุดในส่วนของการทดสอบโปรแกรมในการการควบคุมและตรวจจับความระดับความเข้มแสงแอลอีดีนำไปใช้งานจริงกับพืชผล พบว่าค่าความถูกต้องอยู่ในระดับที่ดีมาก แต่อย่างไรก็ตาม ยังคงมีความผิดพลาดเล็กน้อย ซึ่งอยู่ในเกณฑ์ที่พอรับได้ของผู้วิจัย ในท้ายที่สุดยังคงมีพัฒนาการวิจัยต่อเพื่อให้เกิดประโยชน์สูงสุด

## 5.2 ข้อเสนอแนะและแนวทางในการพัฒนาต่อไป

ผลการทดสอบระบบควบคุมแสงแอลอีดีอัจฉริยะในโรงเรือนโดยใช้เทคโนโลยีปัญญาประดิษฐ์ มีข้อเสนอแนะและแนวทางการพัฒนาในอนาคตดังนี้

1. ระบบซอฟต์แวร์ที่ใช้ ถูกพัฒนาขึ้นมาเพื่อใช้ร่วมกับผักกาดหอมกรีนโอ๊ค (Green Oak Lettuce) ดังนั้นในอนาคต ถ้าหากมีการนำไปใช้งานจริงกับพืชผลอื่น ๆ ผู้วิจัยจำเป็นต้องออกแบบระบบขึ้นมาใหม่ เพื่อให้เหมาะสมต่อการใช้งานร่วมกับพืชผลในอนาคต

2. พัฒนาระบบซอฟต์แวร์ให้สามารถใช้งานร่วมกับเครือข่ายไร้สาย เพื่อให้งานวิจัยมีประสิทธิภาพมากยิ่งขึ้นและทำให้สามารถทำงานสะดวกเพิ่มขึ้น


3. พัฒนาระบบซอฟต์แวร์ในส่วนของปัญญาประดิษฐ์ให้มีความสามารถยิ่งขึ้น ซึ่งจะนำมาใช้ในส่วนในการช่วยผู้ดูแลในการตัดสินใจและสังเกตการณ์เกี่ยวกับช่วงอายุการเจริญเติบโตของพืช

4. เนื่องจากระบบซอฟต์แวร์ที่ใช้ในส่วนของปัญญาประดิษฐ์เป็นการใช้การเรียนรู้แบบเครื่อง (Machine Learning) ที่มีความยุ่งยากในการเก็บข้อมูล ซึ่งทำให้งานวิจัยหรือการนำไปใช้งาน จำเป็นอย่างยิ่งในการใช้เวลาในการเก็บข้อมูล ดังนั้นในอนาคตนั้นหวังอย่างยิ่งในการพัฒนาเป็นการเรียนรู้แบบเชิงลึก (Deep Learning) ที่จะสามารถข้ามขั้นตอนในส่วนของการเก็บข้อมูล เพื่อลดระยะเวลาในส่วนนี้ สะดวกต่อการใช้งานมากยิ่งขึ้น และมีประสิทธิภาพสูงทั้งในด้านการใช้งานและค่าความถูกต้อง

## รายการอ้างอิง

- Olle, M., and Viršile, A. (2013). The effects of light-emitting diode lighting on greenhouse plant growth and quality. **Agricultural and food science**. 22 (2): 223-234.
- Gómez, C., and Izzo, L. G. (2018). Increasing efficiency of crop production with LEDs. **AIMS Agriculture and Food**. 3 (2): 135-153.
- Jou, J. H., Yu, H. H., Tung, F. C., Chiang, C. H., He, Z. K., and Wei, M. K. (2017). A replacement for incandescent bulbs: high-efficiency blue-hazard free organic light-emitting diodes. **Journal of Materials Chemistry C**. 5 (1): 176-182.
- Cortes, C., and Vapnik, V. (1995). Support-vector networks. **Machine learning**. 20 (3), 273-297.
- Freund, Y., and Mason, L. (1999). The alternating decision tree learning algorithm. In **Machine Learning: Proceedings of the Sixteenth International Conference** (Vol. 99, pp. 124-133). San Francisco, CA: Morgan Kaufmann Publishers Inc.
- Breiman, L. (2001). Random forests. **Machine learning**. 45 (1): 5-32.
- Reeves, S. J., and Zhe, Z. (1999). Sequential algorithms for observation selection. **IEEE Transactions on Signal Processing**. 47 (1): 123-132.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. **the Journal of machine Learning research**. 12: 2825-2830.
- Gonzalez, R. C., Woods, R. E., and Eddins, S. L. U. (2004). **Digital Image Processing Using MATLAB**. Pearson Prentice Hall. *Upper Saddle River, New Jersey*.
- Waveform Lighting, (2020). Convert Lux to PPF – Online Calculator [On-line]. Available: <https://www.waveformlighting.com/horticulture/convert-lux-to-ppfd-online-calculator>
- McKinney, W. (2010). Data structures for statistical computing in python. In **Proceedings of the 9th Python in Science Conference** (Vol. 445, pp. 51-56). Texas, Austin: SciPy Organizers
- Kaleem, A. B. D. U. L., Ghori, K. M., Khanzada, Z. A. H. R. A., and Malik, M. N. (2011). Address standardization using supervised machine learning. **Interpretation**. 1 (2): 10.

- Oliphant, T. E. (2006). **A guide to NumPy** (Vol. 1, p. 85). USA: Trelgol Publishing.
- Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. **IEEE Annals of the History of Computing**, 9 (03): 90-95.
- Møller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. **Neural networks**, 6 (4): 525-533.
- LEDGardener, (2017). Lumens, PAR, PPF, and PPFd: Measuring COB Grow Light Output.: LEDGardener [On-line]. Available: <https://ledgardener.com/lumens-par-ppf-and-ppfd-measuring-cob-grow-light-output/>
- Jolliffe, I. T. (1986). Principal components in regression analysis. In **Principal component analysis** (pp. 129-155). Springer, New York, NY.
- Bello-Bello, J. J., Martínez-Estrada, E., Caamal-Velázquez, J. H., and Morales-Ramos, V. (2016). Effect of LED light quality on in vitro shoot proliferation and growth of vanilla (*Vanilla planifolia* Andrews). **African Journal of Biotechnology**, 15 (8): 272-277.
- นภัทร วัจนเทพินทร์ และ ไชยยันต์ บุญมี. (2560). ไดโอดเปล่งแสงสีอะไรเหมาะสมกับการปลูกพืช?. **Thai Science and Technology Journal**. 158-176.



ภาคผนวก ก

บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา

มหาวิทยาลัยเทคโนโลยีสุรนารี



## รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

- P. Kumsawat, T. Hoprasertwong, W. Pathonsuwan, N. Sawangsawai, K. Attakitmongcol, and A. Srikaew, “**Comparative Study of Machine Learning Models for Important Feature Selection in the LEDs Intensity Detection**”, Proc. Of The SUT International Virtual Conference on Science and Technology (IVCST 2020), pp. 116-122., August 28, 2020, Suranaree University of Technology, Nakhon Ratchasima, Thailand.
- P. Kumsawat, W. Pathonsuwan, N. Sawangsawai, T. Hoprasertwong, K. Attakitmongcol, and A. Srikaew, “**Design of the RF Measuring Sensor Network for Low – power Radio Frequency Transceiver Detection System**”, Proc. Of The SUT International Virtual Conference on Science and Technology (IVCST 2020), pp. 109-115., August 28, 2020, Suranaree University of Technology, Nakhon Ratchasima, Thailand.
- P. Kumsawat, N. Sawangsawai, W. Pathonsuwan, T. Hoprasertwong, K. Attakitmongcol, and A. Srikaew, “**PM 2.5 Monitoring System Using Wireless Sensor Networks for Smart City**”, Proc. Of The SUT International Virtual Conference on Science and Technology (IVCST 2020), pp. 123-128., August 28, 2020, Suranaree University of Technology, Nakhon Ratchasima, Thailand.
- P. Kumsawat, T. Hoprasertwong, A. Srikaew, and K. Attakitmongcol, “**Artificial Light Intensity Detection in Greenhouse Horticulture based on Artificial Intelligence Technique**”, Suranaree J. of Science and Technology (SJST), November 04, 2020 (Accepted), Suranaree University of Technology, Nakhon Ratchasima, Thailand. **(In the process of publication)**
- P. Kumsawat, W. Pathonsuwan, N. Sawangsawai, T. Hoprasertwong, A. Srikaew, and K. Attakitmongcol, “**PM 2.5 Monitoring System Using Wireless Sensor Networks for Smart City**”, Suranaree J. of Science and Technology (SJST), June 18, 2021 (Accepted), Suranaree University of Technology, Nakhon Ratchasima, Thailand. **(In the process of publication)**

EAT0021

## Comparative Study of Machine Learning Models for Important Feature Selection in the LEDs Intensity Detection

P. Kumsawat<sup>1,\*</sup>, T. Hoprasertrwong<sup>1</sup>, W. Pathonsuwan<sup>1</sup>, N. Sawangawai<sup>1</sup>, K. Attakitmongcol<sup>2</sup>, and A. Srikaew<sup>2</sup>

<sup>1</sup> School of Telecommunication Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima, 30000, Thailand.

<sup>2</sup> School of Electrical Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima, 30000, Thailand.

\* Corresponding Author: prayoth@sut.ac.th

**Abstract:** Detection of LEDs light intensity is an important part of the automated greenhouse lighting control system. In order to precisely control the LEDs light intensity, we have applied machine learning techniques to implement important feature selection for the LEDs light intensity detection. The most suitable machine learning model can provide the most accurate LEDs light intensity detection results. In this work, we have compared 3 machine learning models which are SVM with Gaussian kernel model, decision tree model, and random forest model. Then, we proposed a feature selection method using the Sequential Backward Selection algorithm with our data to find the best model. In this work, we have used digital cameras to capture images to detect LEDs light intensity in different light intensity conditions. Experimental results show that the proposed process provides high accuracy in the detection of LEDs light intensity.

**Keywords:** Machine learning, regression model, sequential backward selection algorithm.

### 1. Introduction

Weather condition plays an important role in determining the pace of plant growth. Extreme weather has frustrated many vegetable gardeners and farmers. However, the need of healthy food such as vegetables and fruits has increased dramatically. Thus, various methods were invented to help with this matter. One way to work around these issues is the development of LEDs artificial lighting equipment in the greenhouse. The cultivation in greenhouse allows us to control the environment, resulting in maximum resource efficiency. There are some previous researches about the effects of LED to plant growth [1], the method to increase production efficiency with LED [2], and LED improvement to increase efficiency [3]. In order to precisely control the LEDs light intensity, we have used machine learning (ML) techniques to control the LEDs artificial light intensity. To the best of our knowledge, most of the practical machine

learning techniques use supervised learning. However, the supervised learning requires feature extraction process for real world data and then converts it to a dataset for use during training and testing. Therefore, we must verify that the feature extraction is effective enough for the machine learning models.

The procedure of choosing the suitable machine learning model is as follows. First, pictures of LEDs are obtained by using the digital camera for LEDs light intensity detection. Next, we extracted the outstanding feature using our method. Then, we got and assigned our dataset to class label. Our dataset is divided into 2 types which are input dataset and target dataset. We have chosen 3 models for comparison which are the Support Vector Machine with Gaussian kernel model [4], Decision tree model [5] and Random forest model [6]. Each model will be applied to the Sequential Backward Selection (SBS) algorithm [7]. Finally, the model which gives the best feature selection is the most suitable model for our work. In this paper, we propose a comparison study of machine learning models for importance feature selection in LEDs intensity detection. The feature extraction must be effective enough for the machine learning algorithm.

This paper is organized as follows. In Section 2, the proposed method for feature importance selection in the LEDs intensity detection, dataset collection and preparation are given and discussed. In Section 3, the experimental results are shown. Finally, the conclusions are presented in Section 4.

## 2. Proposed Methods

This section presents the details of comparative study of machine learning models for importance feature selection in LEDs intensity detection. The details of the proposed method can be characterized into 4 steps as: data collection, data preparation, applying learning curves and feature selections. The block diagram of the proposed method is shown in Figure 1.

First, we collect data and define a data class which consists of input classes and target classes. The data preparation is applied to use with the machine learning model from Scikit-learn [8] which is accomplished by standardizing data. Next, we employ the standardized data as the input to machine learning model and plot the learning curve to analyze and prove the accuracy and suitability of our data. Then, we use the machine learning model to cooperate with SBS algorithm. At this process, we can distinguish the differences in the quality of our data and the machine learning model. Finally, we have a suitable and efficient machine learning model. Then, we plot the classification accuracy to analyze feature importance. These results will be applied to the light control system for the greenhouse.

Our experiment was performed on a laptop computer with AMD Ryzen 5 2500U central processing unit and Radeon Vega mobile graphic processing unit. We have used Python as our creative platform and Sublime text 3 as a code creator. In data preparation process, we have stored dataset with a proper format and defined input class and target class for stored dataset. Figure 1 shows the block diagram of our proposed method.

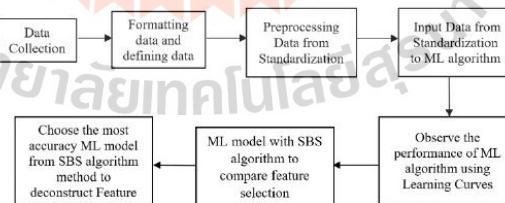



Figure 1. Block diagram of the proposed method.

### 2.1 Data Collection

To train the model for performing various actions, we simulate various events with red and blue color channels. We snap pictures of LED from simulation using Logitech C310 HD Webcam. Next, we convert the images from RGB to HSV color spaces using image processing algorithm in MATLAB R2018b [9]. Then, we define a rectangular box to extract HSV sub-image from the original HSV image. This process is based on RGB color channel intensity. Then, we calculate the average values of the intensity and store them in a table which will be later used as a condition with the light measurement using the Photosynthesis Photon Flux Density (PPFD) [10]. Figure 2 shows data collection process of the proposed method. Subfigures (1)-(4) show input image from Logitech C310 HD Webcam, converted image from RGB to HSV image, rectangular box to extract HSV sub-image and HSV sub-image with intensity extraction in each pixel, respectively. Subfigures (5)-(7) show the red, green, blue color intensity of each pixel for each sub-image, average values of the color intensity for each sub-image and average values of the color intensity with PPFDF values, respectively.



**Figure 2.** Data collection process of the proposed method.

### 2.2 Data Preparation

Since each machine learning model has different performance characteristics, to choose the most accurate model, we have to make comparison and decide which one is the most appropriate. The class labels are encoded as integer values.

We have prepared dataset and divided it into 2 types are as follows [11].

1.) Input data from feature extraction, consisting of red, blue, green color channels (intensity) and PPFDF measurement.

2.) Target data from circumstance consisting of red intensity of 25%, 50%, 75%, 100% blue intensity 25%, 50%, 75%, and 100%.

Next, we perform encoding on this data. Obviously, the input data is an integer, but the target data is still a string. Hence, we converted it from a string to an integer, which will get 8 labels. Labels 1-4 are 25% - 100% red intensity and labels 5-8 are 25% - 100% blue intensity. To simplify and enhance training, we have used standardization technique proposed in [12]. The equation of feature scaling technique is given in Equation (1).


$$F_{std} = \frac{F - \mu_F}{\sigma_F} \quad (1)$$

where  $F_{std}$  represents the new data,  $F$  is input data,  $\mu_F$  is the sample mean of a particular feature, and  $\sigma_F$  is the standard deviation.

### 2.3 Applying Learning Curves

Learning curves are a diagnostic tool in machine learning. It is created by plotting the model learning performance over experience. In this Sub-Section, we have used Equation (1) to prepare the data and applied it to 3 various models. Figure 3(a)-3(c) show the learning curves using SVM with Gaussian kernel model, Decision tree model, and Random forest model, respectively. The learning curves and validation curves cultivate the performance of a learning algorithm.

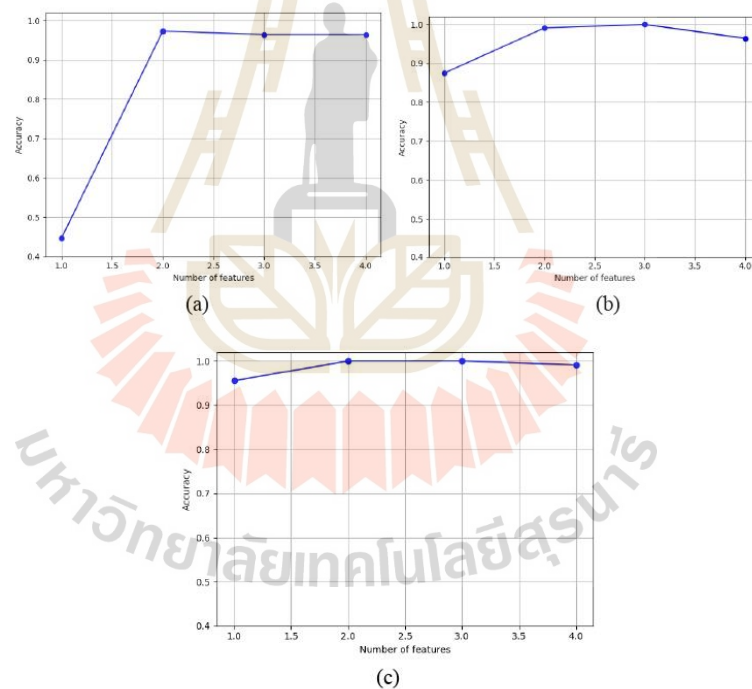
Furthermore, the vertical axis represents the accuracy of the training and validation sections in term of probability from 0-1 which is equivalent to accuracy from 0-100%. The horizontal axis is the number of training examples from 0-400. We have used learning curves to distinguish whether a learning algorithm has a riddle. From Figure 3, the learning curves of 3 models have the same trend where the blue line (training accuracy) in the Y axis equals 1(100%) as desired accuracy. However, all 3 curves in green line (Validation accuracy) have different trend. We have analyzed these differences and found that the accuracy at the starting point of 3 green curves are different. Figure 3(a) is at 0.312 while Figure 3(b) is at 0.481 and Figure 3(c) is at 0.49 accuracy. All 3 methods are performed using the same number of training examples at 75. By comparing the results at the beginning of the Validation accuracy curve, The SVM with Gaussian kernel model in Figure 3(a) seems to be the lowest, followed by the Decision tree model shown in Figure 3(b). The best model is the Random forest model which gives the highest accuracy at starting point as shown in Figure 3(c).



**Figure 3.** Plot of the learning curves. (a) SVM with Gaussian kernel model, (b) Decision tree model, and (c) Random forest model.

#### 2.4 Feature Selection

Feature selection is the process of selecting a subset of relevant features for use in the machine learning model construction. It is also called variable selection or attribute selection. In this work, we have used the Sequential Backward Selection as a feature selection algorithm. By comparison of the number of features per feature, high accuracy can be achieved. First, we took the information from previous sub-sections for training through the relevant model. Then, we apply SBS which is effective in selecting the important features. The results of classification accuracy are shown in Figure 4. In case when the number of features equals 1, the SVM model has an accuracy of 0.3, while the Decision tree model and the random forest have an accuracy of 0.88 and 0.95, respectively. From Figure 4, the vertical axis represents the classification accuracy in term of probability from 0-1 which is equivalent to accuracy from 0-100%. The horizontal axis is the number of features from 1 to 4 as red, green, blue, and PFD measurement. the result shows that the optimal performance is the random forest model. Next, we identify the highest accuracy of each models. The results show that the SVM, Decision tree and random forest models have accuracy of 0.975, 1.0 and 1.0, respectively. Finally, we perform the analysis of the number of features that affects the classification accuracy. When we compare the number of features that has the highest accuracy among 3 cases, the results are as follows: In Figure 4(a) for SVM, the number of features that has the highest accuracy equals 2 including the red color channel and the PFD measurement.



**Figure 4.** Plots of the classification accuracy. (a) SVM with Gaussian kernel model, (b) Decision tree model, and (c) Random forest model.

In Figure 4(b) for Decision tree, the number equals 3 including Red color channel, Green color channel and PPF measurement. Finally, in Figure 4(c) for Random forest, there are two numbers of features that give the same highest accuracy which are 2 and 3. We choose numbers of features 2 including Red color channel and PPF measurement. For a fair comparison, we have compared the accuracy at the number of features which is equal to 2 among all 3 models. From the results, we are able to choose the appropriate method for feature importance selection. The main conclusion here is that the Random forest model is the best model.

### 3. Experimental results

In our experiment, we apply the Sequential Backward Selection (SBS) algorithm for features selection to Support Vector Machine with Gaussian kernel model (SVM – Radial Basis Function), Decision tree model, and Random forest model. The experimental results and discussion are as follows:

We compare 3 machine learning models to find the optimal model for specifying feature importance values. The results we obtained show that the Random Forest model is the best algorithm for selecting features importance in our dataset. Figure 5 shows a plot that ranks the feature importance in horizontal bar. From Figure 5, 4 features in our comparison consist of “Red intensity”, “Green intensity”, “Blue intensity”, and “PPFD measurement”. We choose Random forest model from our comparative study to assess feature importance. We also considered the classification accuracy by plotting the accuracy vs the number of training examples as in the Figure 4. From experimental results, we can conclude from assessing feature importance with the Random Forest model that PPF measurement, Red intensity are the most classification extraction features in the LEDs intensity dataset. From Figure 5, the feature importance values of PPF measurement and Red intensity are 0.300619 and 0.299217, respectively. They are the most feature significations. If we define the threshold value of the classification accuracy with a value of 0.5, both features are extremely important in setting a feature label to classification, prediction, and system enhancement.




Figure 5. Plot of the different features in the LEDs intensity datasets.

### 4. Conclusion

In this work, we evaluated feature signification based on Sequential Backward Selection algorithm. First, we have compared 3 machine learning models: SVM with Gaussian kernel model, decision tree model, and random forest model to see which one is the most effective and suitable model for our dataset. Then, we applied the Sequential Backward Selection

algorithm to learn appropriate behaviour in both training and testing sections. Finally, we found that the best model is random forest model. Thus, we applied this model to assess feature importance and obtained a satisfied and highly reliable response to our LEDs light intensity. The results of this work can be applied to implement automated greenhouse LEDs lighting control system.

### 5. Acknowledgments

This work was supported by a grant from Suranaree University of Technology, Nakhon Ratchasima, Thailand.

### 6. References

- [1] Olle M. and Viršile A., 2013. *The effects of light-emitting diode lighting on greenhouse plant growth and quality*. Agricultural and food science. pp. 223-234.
- [2] Gómez C. and Izzo L. G., 2018. *Increasing efficiency of crop production with LEDs*. AIMS Agriculture and Food. pp. 135.
- [3] Jou J. H., Yu H. H., Tung F. C., Chiang C. H., He Z. K. and Wei M. K., 2017. *A replacement for incandescent bulbs: high-efficiency blue-hazard free organic light-emitting diodes*. Journal of Materials Chemistry C. pp. 176-182.
- [4] Cortes C. and Vladimir V., 1995. *Support-vector networks*. Machine learning. pp. 273-297.
- [5] Freund Y. and Llew M., 1999. *The alternating decision tree learning algorithm*. International Conference on Machine Learning. pp. 124-133.
- [6] Breiman L. 2001. *Random forests*. Machine learning. pp. 5-32.
- [7] Reeves S. J. and Zhao Z., 1999. *Sequential algorithms for observation selection*. IEEE Transactions on Signal Processing. pp. 123-132.
- [8] Pedregosa F., et al. 2011. *Scikit-learn: Machine learning in Python*. the Journal of machine Learning research. pp. 2825-2830.
- [9] Gonzalez R. C., Richard E. W. and Steven L. E. 2004. *Digital image processing using MATLAB*. Pearson Education India.
- [10] waveformlighting.com, 2020. *Convert Lux to PPF*. [Internet] Available at: <<https://www.waveformlighting.com/horticulture/convert-lux-to-ppfd-online-calculator>> [updated 2020 Jan 24].
- [11] McKinney W., 2010. *Data structures for statistical computing in python*. Proceedings of the 9th Python in Science Conference. pp. 51-56.
- [12] Kaleem A. B. D. U. L., et al. 2011. *Address standardization using supervised machine learning*. International Conference on Computer Communication and Management. pp. 441-445.
- [13] Oliphant T. E., 2006 *NumPy: A guide to NumPy*. USA: Trelgol Publishing.
- [14] Hunter J. D. 2007. *Matplotlib: A 2D graphics environment*. Computing in science & engineering. pp. 90-95.



EAT0020

## Design of The RF Measuring Sensor Network for Low-power Radio Frequency Transceiver Detection System

P. Kumsawat<sup>1,\*</sup>, W. Pathonsuwan<sup>1</sup>, N. Sawangsawai<sup>1</sup>, T. Hoprasertwong<sup>1</sup>,  
R. Wongsan<sup>1</sup>, K. Attakitmongcol<sup>2</sup>, and A. Srikaew<sup>2</sup>

<sup>1</sup> School of Telecommunication Engineering, Institute of Engineering, Suranaree University of Technology, 111 University Avenue, Nakhon Ratchasima, 30000, Thailand.

<sup>2</sup> School of Electrical Engineering, Institute of Engineering, Suranaree University of Technology, 111 University Avenue, Nakhon Ratchasima, 30000, Thailand.

\* Corresponding Author: prayoth@sut.ac.th

**Abstract.** This paper presents a design and development of the RF measuring sensor network for low-power RF transceiver detection system. The proposed system uses an active directional antenna and spectrum analyzer to detect interfering frequencies and power spectrum of the wireless signals. Furthermore, we apply microcontroller to control the RF switch in order to select detection methods whether using a spectrum analyser or service set identifiers using a WIFI receiver module. The microcontroller module is connected to the GPS and digital compass modules mounted on the active directional antenna for determining the position and direction of the antenna. This method is able to accurately measure the power of signal, triangulate the source of interference, and identify WIFI access points.

**Keywords:** Low-power detection system, RF measuring sensor network, radio frequency interference.

### 1. Introduction

Nowadays, the trend of using wireless devices in various areas is increasing rapidly and consequence, there is a great chance of radio frequency interference. This problem can cause a severe impact on the operation of neighboring communication devices to the point that it cannot be used. For example, the radio frequency radiation from the mobile base station interferes with the operation of the BTS train control in Bangkok. This causes the train delay and affects a lot of passengers. Therefore, having a highly accurate interference detector will help us to fix the problems quickly and efficiently. In Thailand, the National Broadcasting and Telecommunication Commission (NBTC) has a duty under the law to manage the frequency spectrum and to ensure the efficient use of the frequency spectrum in order to prevent severe frequency interference. The Office of the NBTC is responsible for monitoring and supervising the frequency usage to support all spectrum management information in Thailand. The frequency allocation can be divided into 2 types which are the frequency that must be licensed

and frequency bands that do not need a license. However, the non-licensed frequency band requires a low transmission power and does not cover any interference that may occur. If a frequency that does not require a license is requested to be inspected, the Office of NBTC needs to know the location of the frequency interference source exactly to effectively monitor the use of the frequency. However, in the event that an interference occurs and the location of the WIFI access point is unclear or they want to check the distribution of the WIFI usage in one area, it will take a long time to solve these problems.

This paper presents a design and development of the RF measuring sensor network (RFMSN) for low-power RF transceivers. This is to enable the Office of NBTC to have an effective inspection system in the future. In this work, the RF measuring sensor network based on 3G/4G mobile phone network and Lora WAN technology have been implemented. The proposed network can monitor the usage of low-power RF transceivers in the inspection areas. Furthermore, we have developed a smart tracking scheme using GPS module and digital compass. The software coding of the implementation was accomplished by using C/C++ and Python.

This paper is organized as follows. In Section 2, the literature review of tracking system and the RF measuring sensor network are given and discussed. The design and development of our radio frequency detection system for low-power RF transceivers is described in Section 3. In Section 4, the experimental results are shown. Finally, the conclusions are presented in Section 5.

## 2. Literature Review

In recent years, GPS and GSM modules are widely used in the field of vehicle tracking because of its high efficiency and easy realization [1-3]. For instance, [1] presented a vehicle tracking system with high performance GPS/GPRS. This system also has LPG gas leakage sensor and temperature sensor. If there is a problem of the LPG gas leak, it will send a warning message to mobile phone of the vehicle owners using SIM908 module. Thengal *et al.* proposed an efficient vehicle tracking system using the GPS and the GSM modules [2]. The information of vehicle location is displayed in the form of a map on a web server. Hattarge *et al.* proposed a GPS tracking on Lorawan technology combined with an Android application for a smart transport system [3]. This system can be implemented in a real-life environment. Lora is a type of communication technology that focuses on the long-range communication and low power. Zourmand *et al.* presented a Lora technology and applied it to the Internet of Things (IoT) [4]. Lora is responsible for testable quality and efficiency of the Lora network. Yang proposed a detection and control of machine operation in various environmental condition using Lora technology [5]. National instruments presented an introduction to wireless LAN measurement [6]. For wireless LAN communication, the spectrum measurements can characterize the performance of the transmitters.


## 3. Proposed Method

This section presents the design of the RF measuring sensor network (RFMSN) which consists of the RF measuring sensor node and the RF measuring sensor gateway for installation in mobile vehicles. The main devices of the RFMSN node system include active directional antenna, spectrum analyzer, WIFI transceiver, RF switch, GPS module, and digital compass module. The RFMSN gateway is equipped with a raspberry Pi microprocessor module and a Lora module. The RFMSN gateway also has a 3G/4G mobile communication module connected to its interface board, allowing TCP/IP, USB or RS232 serial communication with the cloud computing. Furthermore, we have used a dedicated LAN connection for connecting the RFMSN gateway to laptop computer.


In our proposed system, an active directional antenna and spectrum analyser are applied to determine the type and frequency of interfering signal, especially for narrow band interference. Furthermore, GPS and digital compass mounted on that antenna are used to triangulate the source of the signal interference. Therefore, the designed system is able to precisely detect the source of interference signal.

The RF measuring sensor network can be used to detect frequency interferences in any areas that have been requested for inspection. If there is a 3G/4G mobile network in the inspection area, the system will send all the captured data to the Google Firebase database via the 3G/4G mobile network, which is considered as the main datalink of the proposed system. The block diagram of the communication system in this case is shown in Figure 1.


If there is no 3G/4G mobile network in the inspection area, the data transmitted from the signal detector will be sent outside that area via the supported datalink Lorawan to the RFMSN gateway that has access to the 3G/4G mobile phone network. Then, the RFMSN gateway will upload the relevant information to the Google Firebase database. In our proposed system, the range of Lorawan to achieve wireless communication is up to 3 km with a maximum data rate of 256 kbps. The block diagram of the communication system in this case is shown in Figure 2. Experimental setup and device connection are presented in Figure 3.



**Figure 1.** Block diagram of the communication system with 3G/4G mobile phone network.



**Figure 2.** Block diagram of the communication system without 3G/4G mobile phone network.



**Figure 3.** (a) Experimental setup and device connection, (b) control box and (c) RF Switch.

#### 4. Experimental Results and Discussion

In this section, some experimental results are given to demonstrate the effectiveness of the proposed wireless signal detection system. The experimental results and discussion are as follows:

##### 4.1. Testing the signal received from the WIFI transmitter

Firstly, we performed a preliminary study to see how the type of antenna would affect the performance of the detection system. The test was performed by sending the WIFI signal at the 2.4 GHz Channel 11 (2.451-2.473 GHz) using the original monopole antenna that came with the WIFI transmitter WAVLINK AC600 model, and using the Hyper LOG active directional antenna as a receiving antenna. Then, we change the transmitting antenna to Vivaldi antenna, and perform testing with the distance between the transmitter and receiver varying from 5 m to 200 m. In addition, the antenna is sent and received with horizontal polarization. The signal levels received from spectrum analyzer are shown in Table 1. From Table 1, changing the transmitting antenna from the monopole antenna to the Vivaldi antenna yields higher power level about 5 dBm.

**Table 1.** Measuring result of the receiving signal from WIFI transmitter.

Distance (m)	Received power (dBm)		Effective Radiated Power (dBm)	
	Monopole Antenna	Vivaldi Antenna	Monopole Antenna	Vivaldi Antenna
5	3.5	4.0	12.5	13.0
25	-3.0	1.0	20.0	24.0
50	-10.0	-3.0	19.0	26.0
100	-23.0	-14.0	12.0	21.0
150	-28.0	-23.0	10.6	15.2
200	-31.0	-26.0	10.1	15.1

By measuring the value of received power, we can calculate the value of effective radiated power (*ERP*). To check if the *ERP* of the WIFI transmitters found meets the requirement by law, *ERP* was calculated using the Equation (1), where  $P_r$  is the power that can be received in front of the antenna,  $R$  is the distance between the WIFI receiver and the WIFI transmitter,  $G_r$  is gain of the receiver antenna (The antenna tested has gain 45 dBi) and  $\lambda$  is the wavelength.


$$ERP(dBm) = P_r(dBm) - G_r(dBi) + 20\log_{10}\left(\frac{4\pi R}{\lambda}\right) \quad (1)$$

##### 4.2. Testing the RF switch controller

In our proposed system, the RF switch is installed in the RF measuring sensor network. It is used as an optional connection of the active directional antenna to the spectrum analyzer or to the WIFI transceiver. Therefore, the RF switch is controlled by a microcontroller to select the detection methods, whether to take the signal received from the antenna to analyze the frequency spectrum and signal strength or to find the SSID of the WIFI transmitter. Figure 3(c) shows the RF switch model EV1HMC8038LP4C. In this work, an RF signal received from active directional antenna is applied to the incoming transmission line of the RF switch. The Signal Vu- PC software provides users ability to analyze RF and vector signals. Furthermore, we have used WIFI analyzer software to identify nearby WIFI access points. To

validate the RF switch performance, several tests were conducted with the focus on WIFI signal strength and frequency spectrum of the wireless signal. The test results of the RF Switch are as follows:

In case of the RF switch “ON”, the received signal is pass through the spectrum analyzer. The proposed detection system can measure the magnitude of an input signal versus frequency. Figure 4 presents the spectral results of the wireless signal detection using spectrum analyzer. From the Figure 4 (a), the spectrum displaying on the Signal Vu-PC program will appear and the magnitude spectrum of the signal will be higher. On the other hand, in case of the RF switch “OFF”, the received signal is pass through the WIFI transceiver. The proposed detection system cloud finds all the SSID of the WIFI access point from that signal. Figure 4 (b) presents the wireless signal detection system using WIFI transceiver. In this case, spectrum measurement results have not changed since the spectrum analyzer is not used. The results confirm that the RF switch can actually select the desired path of signal.



**Figure 4.** Spectral of the signal in question, (a) RF switch “ON” and (b) RF switch “OFF”.

#### 4.3 Testing GPS and digital compass

GPS and digital compass serve to determine the location of the antenna, the direction of the antenna and the orientation of the antenna in three axes. In this work, GPS and digital compass are connected to the microcontroller for reading the relevant information and sending the data to the Fires base, a cloud computing database. The results of the GPS module positioning are compared with the portable satellite receiver (Garmin eTrex 10 GPS). In comparison of the coordinates of the position, there is an average error of 2.5 m which is within the acceptable range. A cloud computing database is shown in Figure 5.



**Figure 5.** A cloud computing database.



Figure 6. The location of the WIFI signal source shown on the Google map.



Figure 7. Radio frequency detection system GUI.

#### 4.4 Testing the radio frequency detection system for low-power RF transceivers.

The test scenario began with the installation of a high-power WIFI access point device in the building. The WIFI access point is assumed as one of the interfering sources. Then, we have used the proposed system to detect the interfering source. In this work, the active directional antenna and real-time spectrum analyzer can rapidly identify most interference sources and signal strength. Furthermore, GPS and digital compass mounted on the antenna are used to determine the position and direction of the antenna. From the principles of triangulation, it can calculate the intersection of the antenna direction to determine the location of the interfering source. Figure 6 presents the location of the WIFI access point device on the Google map. Radio frequency detection system GUI and display are also presented in Figure 7. With the user-friendly GUI of our software, this mapping allows bearing lines to be marked on the map to triangulate the source of the signal interference on the Google map. Therefore, the proposed system can enable interference hunting and easily triangulate the interfering source.

#### Conclusion

This article presents a design and development of the RF measuring sensor network for low-power RF transceivers detection system. In the proposed network, an active directional antenna and spectrum analyzer were applied to determine the type and frequency of interfering signal. The microcontroller was connected to GPS and digital compass modules for determining the position and direction of the active directional antenna. Furthermore, GPS and digital compass mounted on the active directional antenna were used to triangulate the source of the signal interference. The data communication between sensor node and gateway is based on technology used in the 3G/4G mobile phone network and LoRaWAN technology. Therefore, this method is able to accurately measure the power of wireless signal, triangulate the source

of interference, and identify user groups. The experimental results show that the designed system can precisely detect the sources of the interfering signal.

#### Acknowledgments

This work was supported by a grant from Office of The National Broadcasting and Telecommunications Commission under Grant BT2-01/2-61. The authors also would like to thank Suranaree University of Technology for all great supports.

#### References

- [1] Shinde P.A. and Mane, Y.B. 2015. Advanced vehicle monitoring and tracking system based on Raspberry Pi. *IEEE 9<sup>th</sup> International Conference on Intelligent Systems and Control (ISCO)*, pp.1-6.
- [2] A.P. Saikia, Thengal, N. Rastogi, A Medhi, R. Srivastava and K. Datta, 2017. Parameter sensing and object tracking using global positioning system," 2016 Sixth International Symposium on Embedded Computing and System Design (ISED), p. 289-293.
- [3] Hattarge, S. Kekre A. and Kothari, A. 2019. LORAWAN based GPS tracking of city-buses for smart public transport system. *First International Conference on Secure Cyber Computing and Communication (ICSCCC)*, p.265-269.
- [4] Zoumand, A. Kun Hing, A.L. Wai Hung C. and Abdul Rehman, M. 2019. Internet of Things (IoT) using Lora technology. *IEEE International Conference on Automatic Control and Intelligent Systems (T2CACIS)*, p. 324-330.
- [5] Yang, Y. 2020. Design and application of intelligent agriculture service system with Lora-based on wireless sensor network. *International Conference on Computer Engineering and Application (ICCEA)*, p.712-716.
- [6] National Instruments, "Introduction to Wireless LAN Measurements," 2019, [pdf] Available at: <[http://download.ni.com/evaluation/rf/Introduction\\_to\\_WLAN\\_Testing.pdf](http://download.ni.com/evaluation/rf/Introduction_to_WLAN_Testing.pdf)>.



EAT0022

## PM 2.5 Monitoring System using Wireless Sensor Networks for Smart City

P Kumsawat<sup>1,\*</sup>, N Sawangsawai<sup>1</sup>, W Pathonsuwan<sup>1</sup>, T Hoprasertwong<sup>1</sup>,  
K Attakitmongkol<sup>2</sup> and A Srikaew<sup>2</sup>

<sup>1</sup> School of Telecommunication Engineering, Institute of Engineering, Suranaree University of Technology, 111 University Avenue, Nakhon Ratchasima, Thailand.

<sup>2</sup> School of Electrical Engineering, Institute of Engineering, Suranaree University of Technology, 111 University Avenue, Nakhon Ratchasima, Thailand.

\* Corresponding Author: prayoth@sut.ac.th

**Abstract.** Air pollution caused by fine particulate matter 2.5 (PM 2.5) is a leading health crisis for people around the world including Thailand. This paper proposes a low-cost and real-time PM 2.5 monitoring system using wireless sensor network and the Internet of Things (IoT). The system is designed to monitor PM 2.5 via Blynk application on smart phone and via LCD monitor by showing the detection results in the Air Quality Index (AQI) which is easy to understand. Furthermore, our system is calibrated with the standard instrument to ensure accuracy and reliability. The results show that our low-cost system is able to provide a reliable real-time monitoring of the PM 2.5 condition.

**Keywords:** Air quality index, particulate matter 2.5, wireless sensor network, smart city

### 1. Introduction

PM 2.5 (particulate matter less than 2.5 micrometers in diameter) is a harmful air pollutant which is one of the major environmental risk to health. The sources of PM 2.5 are from, for example, engine combustion of vehicles, open burning, industry and power plants. It can be related to the cause of lung cancer, ischemic heart disease, stroke, asthma and other problems in respiratory system. Therefore, it is urgent to look for ways to monitor the PM 2.5 pollution in order to protect oneself by wearing specific mask or avoiding the area where PM 2.5 concentration exceeds the guideline.

In this paper, a real-time PM 2.5 monitoring system is developed by using particulate matter sensor (SPS 30 sensor) [1] which is a high quality sensor. It uses laser scattering technique to radiate suspending particle in the air. Since there have been many studies on the Internet of Thing (IoT) and the wireless sensor network (WSN) for smart cities [2-5], we have applied both of them to our system for monitoring and recording the PM 2.5 information and also for creating a medium to share it. We use a powerful microcontroller ESP32 with built-in Wi-fi and Bluetooth to implement the IoT. It will share the information received from the



WSN by using air card to the LCD display and the Blynk application on smart phone. The result of PM 2.5 concentration will be shown in the Air Quality Index (AQI) and color code which is easy to interpret. Our system can run on solar power and batteries which can operate 24 hours a day.

The paper is structured as follows. In section 2, we describe the methodology of the design of our PM 2.5 monitoring system. The experimental results of the system from testing and actual recording are given and explained in section 3. Finally, the conclusion will be discussed in section 4.

## 2. The Proposed Methods

In this section, we explain the module of our proposed PM 2.5 monitoring system. Our system is equipped with a 40W solar panel as a power source and a 12 V battery as a power storage. There is also a component called solar charger which is connected between solar panel and battery in order to avoid overcharging which can cause permanent battery damage and loss of functionality over time. Then, there is a 5V 3A voltage regulator board which will supply constant 5 V to all other devices including air card and microcontroller ESP32. Air card is a wireless adapter for transmitting and receiving data in a cellular network to microcontroller ESP32. The microcontroller ESP32 was applied to control the operation of SPS30 sensor and control the wireless data transmission. SPS30 is the main sensor which is used to measure the concentration of PM 2.5. It is a compact, high quality, optical particle sensor. The detection result will also be shown on the LCD display. The hardware connection of the proposed system is given in Figure. 1. and Figure 2(a).




Figure 1. Diagram for hardware connection of PM 2.5 Monitoring System.

Figure 2(b) shows our PM 2.5 monitoring setup at the station 1. In our experiment, there will be total of 3 stations. The system can transmit PM 2.5 information to the ThingSpeak cloud computing. By using the smart phone and Blynk application, anyone can see the PM 2.5 monitoring results of all 3 stations.

## 3. Experimental Results

In this section, we show the result of PM 2.5 monitoring. Figure 3 gives a result PM 2.5 concentration at Station 1 in  $\mu\text{g}/\text{m}^3$ . The results from our system with SPS30 sensor are also compared with the ones from Air Visual application [6] which has become one of the most

reliable sources of air quality data. The solid and the dashed lines represent the PM 2.5 dust concentration by the SPS30 sensor of PM 2.5 monitoring system and Air Visual application, respectively. From the result, we found that the data obtained by the SPS30 sensor and Air Visual application is related. The relationship can be written by

$$y = 1.52x \quad (1)$$

$$R^2 = 0.84 \quad (2)$$

where  $y$  is the PM 2.5 dust concentration by Air Visual application and  $x$  is the PM 2.5 dust concentration by SPS30 sensor of PM 2.5 monitoring system. The  $R^2$  (R-square) is 0.84 or 84%. The values of  $x$  can be calibrated by using Equation (1). Figure 4 shows the comparison between both data after calibration.

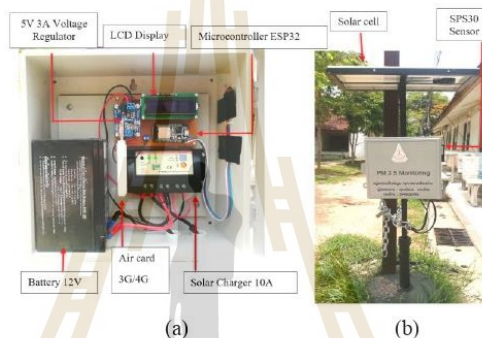


Figure 2. (a) Hardware Connection and (b) System setup of Station 1.




Figure 3. Comparison of PM 2.5 dust concentration from Air Visual and SPS30 sensor.

In Figure 5, the comparison is made in Air Quality Index (AQI). The concentration of PM 2.5 in Figure 1 can be converted to the Air Quality Index by using the following Equation [7]


$$[AQI]_i = \left\{ \left( \frac{I_{\max} - I_{\min}}{C_{\max} - C_{\min}} \right) \times (C_i - C_{\min}) \right\} + I_{\min} \quad (3)$$

where  $AQI_i$  is the Air Quality Index.  $C_i$  is the PM 2.5 concentration from the sensor.  $C_{max}$  and  $C_{min}$  are the maximum and minimum of PM 2.5 dust concentration range.  $I_{max}$  and  $I_{min}$  are the maximum and minimum values of Air Quality Index corresponding to  $C_{max}$  and  $C_{min}$ , respectively. The PM 2.5 concentration in Air Quality Index from both sources are also found to be related. The relationship can be described by


$$y = 1.44x \quad (4)$$

$$R^2 = 0.88 \quad (5)$$

where  $y$  is the PM 2.5 dust concentration by Air Visual application and  $x$  is the PM 2.5 dust concentration by SPS30 sensor in Air Quality Index. The  $R^2$  (R-square) is 0.88 or 88%. Figure 6 shows the comparison between both data after the value of  $x$  is calibrated.




**Figure 4.** Comparison of PM 2.5 dust concentration from Air Visual and SPS30 sensor after calibration.

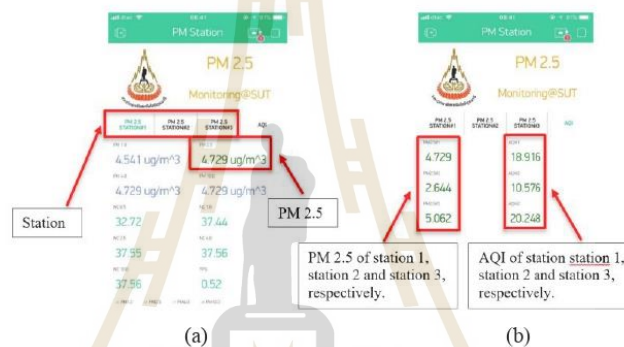


**Figure 5.** Comparison of Air Quality Index from Air Visual and SPS30 sensor.

In Figure 6, it can be seen that the Air Quality Index from the Air Visual is slightly higher than the one from the SPS30 sensor. This might be because the two sensors are not exactly installed at the same place. The location of the Air Visual sensor is closer to the center of the city where there is more traffic than the one of the SPS30 sensor.



**Figure 6.** Comparison of Air Quality Index from Air Visual and SPS30 sensor after calibration.



**Figure 7.** (a) PM 2.5 of station 1, station 2 and station 3 and (b) PM 2.5 and AQI of station 1, station 2 and station 3 on Blynk application.

#### 4. Conclusions

We propose a method for PM 2.5 monitoring system by using wireless sensor networks and the SPS30 sensor which can detect small particles using laser scattering technique. The microcontroller ESP32 was applied to control the operation of SPS30 sensor and control the wireless data communication. It also shares the information received from the WSN to the LCD display and the Blynk application on smart phone. The system can operate 24 hours by using electrical power from solar cells and battery. Our results have been compared and calibrated with the ones from Air Visual application to ensure reliability. The results show that our proposed low-cost system is able to provide a reliable real-time monitoring of the PM 2.5 condition. Thus, it can be used as a prototype of PM 2.5 monitoring product for smart cities. For suggestion, in order to reduce the error of AQI between Air visual application and our PM 2.5 monitoring system, one might try to move the SPS30 sensor closer to the position where the sensor of Air visual is installed.

#### Acknowledgments

This work was supported by a grant from Suranaree University of Technology, Nakhon Ratchasima, Thailand.

**References**

- [1] Livio, L. Sensirion Particulate Matter Premium PM 2.5 Sensor (SPS30). [Internet] Switzerland: Environmental Sensors. Available at: <https://www.sensirion.com/en/environmental-sensors/particulate-matter-sensors-pm25/> [updated 2019 Dec 23].
- [2] Taha, M., Garcia, L., Jimenez, J.M. and Lloret, J. 2018. Wireless technologies for IoT in smart cities. *Network Protocols and Algorithms*, p. 23-64.
- [3] Sikder, A.K., Acar, A., Aksu, H., Uluagac, A.S., Akkaya, K. and Conti, M., 2018. IoT-enabled smart lighting systems for smart cities. 2018 *IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC)*, Las Vegas, p. 639-645.
- [4] Mary, M.C.V.S., Devaraj, G.P., Theepak, T.A., Pushparaj, D.J. and Esther, J.M., 2018. Intelligent energy efficient street light controlling system based on IoT for smart city. 2018 *International Conference on Smart Systems and Inventive Technology (ICSSIT)*, Tirunelveli, India, p. 551-554.
- [5] Qin, X., Xian, X., Deng, Y. and Wang, D. 2019. Micro quartz tuning fork-based PM2.5 sensor for personal exposure monitoring. *IEEE Sensors J.*, 19(7):2482-2489.
- [6] Airvisual.com, [Internet] Thailand: Air Visual. Available at: <https://www.airvisual.com/thailand/nakhon-ratchasima>. [updated 2019 Dec 23].
- [7] Wikipedia.org. Air Quality Index [Internet]. Computing the AQI and the table of air quality index level. Available at: [https://en.wikipedia.org/wiki/Air\\_quality\\_index](https://en.wikipedia.org/wiki/Air_quality_index). [updated 2019 Dec 27]



1       **ARTIFICIAL LIGHT INTENSITY DETECTION IN**  
2       **GREENHOUSE HORTICULTURE BASED ON**  
3       **ARTIFICIAL INTELLIGENCE TECHNIQUE**

4  
5       **Running head: Light intensity detection using AI**

6  
7       **Prayoth Kumsawat<sup>\*</sup>, Thanakorn Hoprasertwong,**  
8       **Arthit Srikaew, and Kitti Attakitmongcol**

9  
10       *School of Telecommunication Engineering, Institute of Engineering, Suranaree*  
11       *University of Technology, Nakhon Ratchasima, 30000, Thailand.*

12       *\*E-mail: prayoth@sut.ac.th*

13  
14       **Abstract**

15       **Accurate detection of LED light intensity is important in many applications**  
16       **especially in the analysis of plant growth in greenhouse horticulture which has**  
17       **now become essential due to the need to control many parameters such as**  
18       **temperature, humidity and light intensity to grow specific plant. In this paper,**  
19       **we propose artificial LED light intensity detection in greenhouse horticulture**  
20       **by applying the Shallow Neural Network. We simulate various light intensity**  
21       **scenarios and use camera to capture the pictures. Then, these pictures will be**

22 **used to train the Neural Network. The experimental results show that the**  
23 **algorithm can detect the LED light intensity accurately.**

24

25 **Keywords: Neural network, Artificial light, Backpropagation neural network,**  
26 **Light intensity**

27

## 28 **Introduction**

29 Nowadays, weather and environment are not always favorable for  
30 agriculture. In addition, people have turned their attention to eat more fruits and  
31 vegetables than before. Therefore, various methods have been invented to grow  
32 plants efficiently. One of those is growing vegetables using artificial LED light in  
33 the greenhouse, which has widely been studied and developed, such as in (Olle and  
34 Viršile, 2013; Gómez and Izzo, 2018). However, the intensity of light has direct  
35 effect to the photosynthesis and growth rate of the plant. Thus, it is necessary to  
36 provide the artificial light with suitable intensity in the greenhouse.

37 In order to apply artificial intelligence technique to detect light intensity, it  
38 is necessary to have a camera to capture images of the light source from the LEDs.  
39 Then, these images will be used to train and test algorithm based on the Shallow  
40 Neural Network. Normally, Shallow Neural Network is the definition of a qualified  
41 Neural Network consisting of one hidden layer and trained only in supervised way  
42 (backpropagation) whereas the Neural Network with many hidden layer is known  
43 as the Deep Neural Network. Thus, depth of the Neural Network describes the  
44 number of hidden layers. The Shallow Neural Network is named to compare with

45 the Deep Neural Network (Stephen Judd, 1987). However, if we use the Shallow  
46 Neural Network directly, this might be an overfitting problem. We can solve this  
47 problem by studying the improving Neural Network in (Rosin and Fierens, 1995).

48 In this paper, we propose algorithm to detect the LED light intensity and  
49 compare the effectiveness of our method with the other work in (Banik et al., 2018).

50

## 51 **Materials and Methods**

52 Our proposed method starts from backpropagation algorithm (Rojas, 1996).  
53 First, we simulate various events with red and blue color channels. We snap pictures  
54 of LED from simulation using Logitech C310 HD Webcam. Next, we convert the  
55 images from RGB to HSV color spaces using image processing algorithm  
56 (Gonzalez and Woods, 2002). Then, we define the rectangular box to extract HSV  
57 sub-image from the original HSV image. This process is based on RGB color  
58 channel intensity. Then, we calculate the average values of the intensity and store  
59 them in a table which will be later used as a condition with the light measurement  
60 using the Photosynthesis Photon Flux Density (PPFD).

61 In our method, there are four main feature values: Red, blue, green intensity  
62 and PPFD value from the MQ-200 Quantum sensor metering instrument. This  
63 method is classified as small data sets and complexity at low to medium levels  
64 which is appropriate to implement the Shallow Neural Network with this dataset.  
65 In comparison to the Deep Neural Network, the Deep Neural Network may yield  
66 slightly more accurate results but it consumes much more computational resources



67 and processing time than the Shallow Neural Network which requires much smaller  
68 number of hidden layers.

69 Finally, we employ the scaled conjugate gradient algorithm (Moller, 1993)  
70 to train LED color intensity and classify pattern by the Shallow Neural Network  
71 toolbox. Figure 1 shows the block diagram of our proposed method.

## 72 **Experimental setup**

73 Our algorithm collects sample data to create a new data set using Principle  
74 Component Analysis (PCA). This data set will be later used in the Shallow Neural  
75 Network algorithm. Our design uses 640 data sets, which have already been tested  
76 and found to be the most appropriate amount for training, validating and testing the  
77 Neural Network. We designed a total of 10 events that maintain blue intensities at  
78 0%, 25%, 50%, 75% and 100%, maintain red intensities at 0%, 25%, 50%, 75%  
79 and 100% respectively. Then, in each of the above events, we maintain the color  
80 saturation value, which increases the color intensity (red) from events where we  
81 maintain the blue intensity. We will increase the red color by 25% => 50% => 75%  
82 => 100% respectively. In the event of maintaining the red intensity, we will increase  
83 it the same way. Initially, we were interested in 1 event with 4 LEDs (1 LED image  
84 is equal to 4 red LEDs and 4 blue LEDs. For example, the event that keeps the blue  
85 intensity at 25% and then increases the red by 25%, indicates that we will be  
86 interested in 4 red LEDs or the event that, keeps the red intensity to 50% and  
87 increase the blue by 75%, indicates that we are interested in 4 blue LEDs.)

88 We have designed the events in accordance with the random variable set at  
89 640 random variables. In summary, we collect 4 LED images per event and

90 consequently one event contains 16 data set. Finally, there will be a total of 40  
91 events and 640 data set.

#### 92 **RGB Color space to HSV Color space**

93 First, we snap pictures with the blue intensity of 25 % and various red  
94 intensity of 25, 50, 75 and 100 % in RGB as shown in Figure 2. Then, the pictures  
95 on Figure 2 are converted to HSV color space in Figure 3.

96 The RGB color space is composed of red, green, and blue dimensions.  
97 RGB color space is an image data obtained from the Logitech C310 HD Webcam.  
98 It is converted to the HSV color space, which consists of light frequency  
99 difference (Hue), hue saturation (Saturation) and the brightness of the color  
100 (Value). When the image data is converted to HSV color space, the color  
101 saturation level is applied to the Neural Network based on the Red, Green, and  
102 Blue dimensions. This makes the range of every pixel of the image 0 to 255. To  
103 demonstrate the effectiveness of data preparation, this reduces the computation  
104 time and complexity for data preparation using Principal Component Analysis  
105 (PCA) in further step.

106 In our method, HSV color space is a better way for extracting important  
107 eigenvalues of the images as compared to the RGB color space. In the simulation  
108 event of the LED intensity detection, it is difficult to distinguish between 2  
109 images in RGB color space. For example, in an event where the blue intensity is  
110 0% and then the red LED intensity is increased by 25% => 50% => 75% =>  
111 100%. It is very difficult to observe a difference in the intensity of red LEDs in  
112 RGB color space. Thus, it is also difficult to find the distinctive features in the

113 images. This makes the image extraction less effective. However, after the image  
114 is converted to HSV color space, it is easier to notice the differences between 2  
115 images with different intensities. The images of the same light intensities in both  
116 color spaces are illustrated in Figure 2 and Figure 3.

#### 117 **Data management**

118 This section describes the process of extracting information from images.  
119 First, we consider Figure 3(a) which shows the picture with blue and red intensity  
120 of 25 % in HSV color space. Next, we determine 4 rectangular boxes as in Figure  
121 4(1). Only the pixel values in these boxes will be extracted in the next step. In  
122 Figure 4(2), the picture in Figure 4(1) will be extracted into 4 sub-images (A)-(D).  
123 Then, for each sub- image, we extract the intensity in each pixel where  
124  $I_{R_1}$ ,  $I_{G_1}$ ,  $I_{B_1}$  represent the color intensity of red, green, and blue at pixel#1. We  
125 continue this process to every pixel in each sub- image where n is the number of  
126 total pixels. Finally, we calculate the average values of the color intensity of red,  
127 green, and blue for each sub-image as in Figure 4(4). This process will be repeated  
128 to Figure 3(b), Figure 3(c) , Figure 3(d), and all 40 events that we create.

129 Once we find all average values from all 40 events from pictures in HSV  
130 domain, we have the data of size 640 x 3 which is defined as raw data. Then, we  
131 apply the Principal Component Analysis (PCA) (Jolliffe, 1986) to the raw data to  
132 reduce redundancy as in (Quivirach, 2011).

133 After, we exploit the PCA to transform our raw data to new data set, we  
134 compare the results in 3D axis as in Figure 5(a) and Figure 5(b). We can see that  
135 after using the PCA in Figure 5(b), data is better organized than the raw one in

136 Figure 5(a). Well-organized data normally yields good result in analysis and  
137 classification.

#### 138 **Shallow neural network**

139 In this section, we describe our method of pattern classification using the  
140 Shallow Neural Network. As part of MATLAB R2018b, we use MATLAB and  
141 choose backpropagation algorithm (Moller, 1993) to train the new data from using  
142 the PCA. We also use 3 color values from the conversion by PCA and use PPF  
143 value (LEDGardener, 2017), another important data obtained from the light  
144 measuring instrument, MQ-200 quantum sensor with a handheld meter. Figure 6  
145 shows our final network setting which defines all 4 inputs as red, green, blue, and  
146 PPF intensities. The number of hidden layer for this algorithm is 50 and since  
147 there are 8 target values(categories) associated with each vector input, the number  
148 of neuron output is 8.

149

#### 150 **Results and Discussion**

151 In our experiment, we use our dataset in three sections, which are the  
152 training section, the testing section, and the validating section. We use 70% of  
153 dataset in the training process, 15% in testing the network and 15% for algorithm  
154 validation. The target is to detect the percentage of red and blue intensity. If the  
155 detection is correct (the algorithm can classify the number of percentage of red and  
156 blue intensity), the output is 1. If not, the output is 0.

157 Figure 7 shows and compares the plot of the training, testing and validating  
158 efficiency. Figure 8 shows the confusion matrix, which both output and target class  
159 are in percentage. Table 1 shows the accuracy for each color channel.

160 In Figure 7, we noticed that the cross-entropy of validating section yields  
161 the best result. It gives cross-entropy of 0.0015 at 9884 epochs. This demonstrates  
162 that data set prepared for the neural network is suitable and the neural network has  
163 moderate to excellent performance. When we observe an important aspect of  
164 training and testing, the results of training and testing Neural Network have positive  
165 trend or the trend has identical direction with the one that shows superb  
166 performance. We consider to implement further hardware development for LED  
167 light intensity detection in greenhouses. Finally, we consider very low cross entropy  
168 validation performance. The validation efficiency is very low because the Neural  
169 Network learning dataset is very difficult or the data set for validating the neural  
170 network is uncomplicated.

171 In Figure 8, a confusion matrix of size 8x8, with a total of 640 datasets is  
172 demonstrated. We can see that 80 sets of red are 25% intensity, 80 sets of red are  
173 50% intensity, 80 sets of red are 75% intensity, 80 sets of red are 100% intensity,  
174 80 sets of blue are 25% intensity, 80 sets of blue are 50% intensity, 80 sets of blue  
175 are 75% intensity, and 80 sets of blue are 100% intensity. In this confusion matrix,  
176 the outputs class is similar to the detection class. It can be seen that high accuracy  
177 of detection relates to the target class or actual class. However, there is an error at  
178 position 1 (80 sets of red are 25% intensity). The algorithm can detect 76 sets from

179 80 sets. The other 4 cannot be detected correctly. The overall performance of the  
180 algorithm has an efficiency of 99.4%.

181 Table 1 shows the comparison between our work with the previous work in  
182 (Banik et al., 2018). The comparison is made at the environmental light according  
183 to (Banik et al., 2018). Therefore, we have to convert the light measurement unit  
184 from lux to PPFD by the method described in (Waveform lighting, 2020). When  
185 the results in (Banik et al., 2018) is converted to PPFD, it matches one of our design  
186 event. However, there is one situation at low blue color intensity which does not  
187 match to our design. So the comparison cannot be made. From the results, it has  
188 been shown that our method yields higher accuracy than previous work in  
189 Multivariate regression model (Banik et al., 2018) and Boosting neural network.  
190 (Banik et al., 2018).

191 From the results of our method, detection in the red and blue components  
192 has accuracy up to 98.75% and 100%, respectively. This shows that the Shallow  
193 Neural Network is an effective tool.

194

### 195 **Conclusion**

196 In this paper, we propose a method to detect LED light intensity using the  
197 Shallow Neural Network. First, we use camera to capture pictures of light source  
198 with different intensity and then convert them from RGB color space to HSV color  
199 space. Then, we rearrange the pixel values of the image into a matrix, find the  
200 average values of three color components and use PCA to transform the data. We  
201 finally use this dataset to train, test and validate the Shallow Neural Network.

202 Our result has been shown that the proposed algorithm can detect the LED  
203 light in red and blue components accurately and yields the detection better than the  
204 result in (Banik et al., 2018).

205

#### 206 **Acknowledgement**

207 This work was supported by a grant from Suranaree University of  
208 Technology, Nakhon Ratchasima, Thailand. The authors would like to thank the  
209 Thailand Research Fund and Commission on Higher Education for all great  
210 supports.

211

#### 212 **References**

- 213 Olle, M. and Viršile, A. (2013). The effects of light-emitting diode lighting on  
214 greenhouse plant growth and quality. *Agri. and Food Sci.*, 22(2):223-234.
- 215 Gómez, C. and Izzo, L.G. (2018). Increasing efficiency of crop production with  
216 LEDs. *AIMS Agri. and Food.*, 3(2):135-153.
- 217 Judd, S. (1988). On the complexity of loading shallow neural networks. *J.*  
218 *Complex.*, 4(3):177-192.
- 219 Rosin, P.L. and Fierens, F. (1995). Improving neural network generalization.  
220 *Proceedings of International Geoscience and Remote Sensing Symposium*  
221 *(IGARSS)*; July 10-14, 1995; Firenze, Italy, p. 1255-1257.
- 222 Banik, P. P. , Saha, R. , and Kim, K. D. (2018). Regression analysis for LED color  
223 detection of visual-MIMO system. *Opt. Commun.*, 413:121-130.

- 224 Banik, P.P. , Saha, R. ,Kwon, T.H. and Kim, K.D. (2018). LED Color Detection of  
225 Visual- MIMO System Using Boosting Neural Network Algorithm.  
226 Proceedings of the 10th International Conference on Ubiquitous and Future  
227 Networks (ICUFN); July 3-6, 2018; Prague, Czech Republic, p. 685-688.
- 228 Rojas, R. (1996). The Backpropagation Algorithm. In: Neural Networks - A  
229 Systematic Introduction. Varga, P., (eds). Springer-Verlag, Berlin, p. 149-  
230 188.
- 231 Gonzalez, R. C. and Woods, R. E. (2002). Digital Image Processing Using  
232 MATLAB. 2nd ed. Prentice Hall, New Jersey, 793p.
- 233 Moller, M.F. (1993). A Scaled Conjugate Gradient Algorithm For Fast Supervised  
234 Learning. Neural Networks, 6:525-533.
- 235 Jolliffe, I.T. (1986). Principal Component Analysis. 2nd ed. Springer . NY, 518p.
- 236 Ouivirach, K. (2011). Writing PCA on MATLAB.: Ouivirach, K. Available from:  
237 [https://www.kanouivirach.com/2011/02/develop-pca-in-matlab-by-](https://www.kanouivirach.com/2011/02/develop-pca-in-matlab-by-yourself/)  
238 [yourself/](https://www.kanouivirach.com/2011/02/develop-pca-in-matlab-by-yourself/). Accessed date: Jan 24, 2020.
- 239 LEDGardener. (2017). Lumens, PAR, PPF, and PPF: Measuring COB Grow  
240 Light Output. : LEDGardener. Available from:  
241 [https://ledgardener.com/lumens-par-ppf-and-ppfd-measuring-cob-grow-](https://ledgardener.com/lumens-par-ppf-and-ppfd-measuring-cob-grow-light-output/)  
242 [light-output/](https://ledgardener.com/lumens-par-ppf-and-ppfd-measuring-cob-grow-light-output/). Accessed date: Jan 24, 2020.
- 243 Waveform lighting. (2020). Convert Lux to PPF. Waveform lighting. Available  
244 from: [https://www.waveformlighting.com/horticulture/convert-lux-to-](https://www.waveformlighting.com/horticulture/convert-lux-to-ppfd-online-calculator)  
245 [ppfd-online-calculator](https://www.waveformlighting.com/horticulture/convert-lux-to-ppfd-online-calculator). Accessed date: Jan 24, 2020.
- 246



247

**Table 1. Accuracy of color intensity for each color channel**

248

Name of the method	Environmental light ( $\mu\text{mol/s/m}^2$ )	Color channel	Accuracy (%)
Multivariate regression model (Banik et al., 2018)	13 (Low)	Red	90.93
		Blue	87.33
	57 (Strong)	Red	89.76
		Blue	87.20
BNN model (Banik et al., 2018)	13 (Low)	Red	93.2
		Blue	92.27
	57 (Strong)	Red	93.23
		Blue	91.45
Our proposed method	13 (Low)	Red	99.99
		Blue	-
	57 (Strong)	Red	99.99
		Blue	99.99

249

250

251

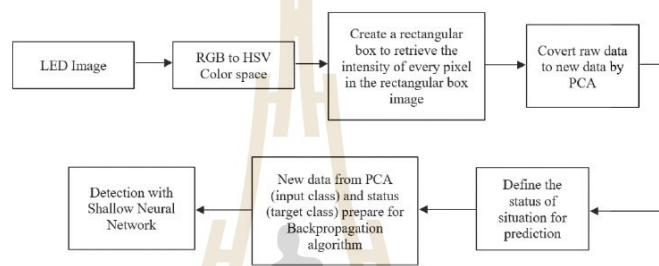
252

253

254

255

256  
257  
258  
259  
260



261

Figure 1. Block diagram for our operating process

262

263

264

265

266

267

268

269

270

271

272

273

274



275

276

277

278

279



280

281

282

283

284

285

286

287

288

289

290

291

292


293

294

295

296

Figure 2. Simulation of the blue intensity 25% in RGB color space. (a) red intensity 25%, (b) red intensity 50%, (c) red intensity 75%, and (d) red intensity 100%




297

298

299

300



301

302

303

304

305

306

307

308

309

310

311

312

313

314

315

316

317

318

319

Figure 3. Simulation of the blue intensity 25% in HSV color space. (a) red intensity 25%, (b) red intensity 50%, (c) red intensity 75%, and (d) red intensity 100%




320

321

322

323



324

325

326

327

328

329

330

331

332

333

334

335

336

337

338

339

340

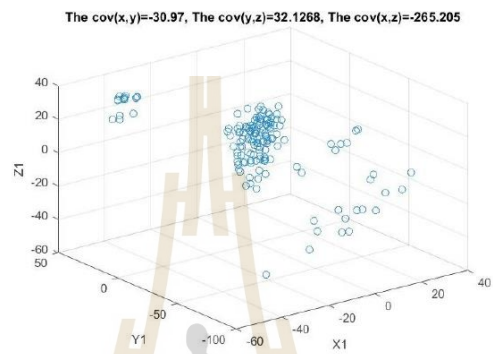
Figure 4. Schematic sketch of proposed method.



341

342


343



344

345

The new cov(x,y)=-172.0893, The new cov(y,z)=187.6848, The new cov(x,z)=47.149



346

347

348

Figure 5. (a) 3D graph of Raw data, and (b) 3D graph of New data.

349

350

351

352

353


354

355

356

357

358



359

360

Figure 6. The network diagram

361

362

363

364

365

366

367

368

369

370

371


372

373

374




375  
376  
377  
378  
379  
380  
381



382  
383  
384  
385  
386  
387  
388  
389  
390  
391

Figure 7. Plot the Training, the Validation, and the Test performance (Left)





392

393

394

395

396

397

398

**Confusion Matrix**

Output Class	1	2	3	4	5	6	7	8	Accuracy
1	76 11.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	80 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	80 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	80 12.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	4 0.6%	0 0.0%	0 0.0%	0 0.0%	80 12.5%	0 0.0%	0 0.0%	0 0.0%	96.2% 4.8%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	80 12.5%	0 0.0%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	80 12.5%	0 0.0%	100% 0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	80 12.5%	100% 0.0%
Accuracy	85.0%	100%	100%	100%	100%	100%	100%	100%	99.4% 0.6%

399

400

**Figure 8. The confusion matrix (Right)**



1 **PM 2.5 MONITORING SYSTEM USING WIRELESS**  
2 **SENSOR NETWORKS FOR SMART CITY**

3

4 **Running head: PM 2.5 detection using Wireless Sensor**

5

6 **Prayoth Kumsawat\*, Nitchamon Sawangsawai, Wongsathon**

7 **Pathonsuwan, Thanakorn Hoprasertwong, Arthit Srikaew,**

8 **and Kitti Attakitmongcol**

9

10 *School of Telecommunication Engineering, Institute of Engineering, Suranaree*

11 *University of Technology, Nakhon Ratchasima, 30000, Thailand.*

12 *E-mail: prayoth@sut.ac.th*

13 *\* Corresponding author*

14

15 **Abstract**

16 **Air pollution caused by fine particulate matter 2.5 (PM 2.5) is a leading health**  
17 **crisis for people around the world including Thailand. This paper proposes a**  
18 **low-cost and real-time PM 2.5 monitoring system using wireless sensor**  
19 **network and the Internet of Things (IoT). The system is designed to monitor**  
20 **PM 2.5 via Blynk application on smart phone and via LCD monitor by showing**  
21 **the detection results in the Air Quality Index (AQI) which is easy to**  
22 **understand. Furthermore, our system is calibrated with the standard**

23 **instrument to ensure accuracy and reliability. The results show that our low-**  
24 **cost system is able to provide a reliable real-time monitoring of the PM 2.5**  
25 **condition.**

26

27 **Keywords: air quality index, particulate matter 2.5, wireless sensor network,**  
28 **smart city**

29

### 30 **Introduction**

31 PM 2.5 (particulate matter less than 2.5 micrometers in diameter) is a harmful air  
32 pollutant which is one of the major environmental risk to health. The sources of PM  
33 2.5 are from, for example, engine combustion of vehicles, open burning, industry  
34 and power plants. It can be related to the cause of lung cancer, ischemic heart  
35 disease, stroke, asthma and other problems in respiratory system. Therefore, it is  
36 urgent to look for ways to monitor the PM 2.5 pollution in order to protect oneself  
37 by wearing specific mask or avoiding the area where PM 2.5 concentration exceeds  
38 the guideline.

39 In this paper, a real-time PM 2.5 monitoring system is developed using  
40 particulate matter sensor or SPS 30 sensor (Livio, 2019) which is a high quality  
41 sensor. It uses laser scattering technique to radiate suspending particle in the air and  
42 uses Sensirion's innovative anti-contamination technology. Thus, a sensor service  
43 life can be last over eight years. This technology enables accurate measurements  
44 from the device's first use, which comes with miniature and ultra-slim. Moreover,  
45 the SPS30 sensor provides users with the estimated mass concertation and the

46 number of particles of PM 1.0, PM 2.5, PM 4.0, and PM 10.0 which the mass  
47 concentration range of the sensor is between 1 to 1000  $\mu\text{g}/\text{m}^3$ . Since there have  
48 been many studies on the Internet of Thing (IoT) and the wireless sensor network  
49 (WSN) for smart cities (Mary *et al.*, 2018; Sikder *et al.*, 2018; Taha *et al.*, 2018;  
50 Qin *et al.*, 2019), we have applied both of them to our system for monitoring and  
51 recording the PM 2.5 information and also for creating a medium to share it. We  
52 use a powerful microcontroller ESP32 with built-in Wi-fi and Bluetooth to  
53 implement the IoT. It will share the information received from the WSN by using  
54 air card to the LCD display and the Blynk application on smart phone. The result  
55 of PM 2.5 concentration will be shown in the Air Quality Index (AQI) and color  
56 code which is easy to interpret. Our system can run on solar power and batteries  
57 which can operate 24 hour a day. The accurate results of the PM 2.5 monitoring  
58 system are referred to and compared from the Air Visual application.

59 The paper is structured as follows. In section 2, we describe the  
60 methodology of the design of our PM 2.5 monitoring system. The experimental  
61 results of the system from testing and actual recording are given and explained in  
62 section 3. Finally, the conclusion will be discussed in section 4.

### 64 **The Proposed Methods**

65 In this section, we explain the module of our proposed PM 2.5 monitoring system.  
66 Our system is equipped with a 40 watt solar panel as a power source and a 12 volt  
67 battery as a power storage. There is also a component called solar charger which is  
68 connected between solar panel and battery in order to avoid overcharging which

69 can cause permanent battery damage and loss of functionality over time. Then, there  
70 is a 5 volt 3 amp voltage regulator board which will supply constant 5 volt to all  
71 other devices including air card and microcontroller ESP32. Air card is a wireless  
72 adapter for transmitting and receiving data in a cellular network to microcontroller  
73 ESP32. The microcontroller ESP32 was applied to control the operation of SPS30  
74 sensor and control the wireless data transmission. SPS30 sensor is the main sensor  
75 which is used to measure the concentration of PM 2.5. It is a compact, high quality,  
76 optical particle sensor. The detection result will also be shown on the LCD display.  
77 The hardware connection of the proposed system is given in Figures 1 and 2(a). PM  
78 2.5 concentration result from the monitor system is used to compare with two  
79 standard PM 2.5 detection monitors. Firstly, the Xiaomi PM 2.5 Air Quality  
80 Monitor, the standard equipment for PM 2.5 detection in real-time, uses light  
81 scattering techniques to detect particles in the air and can offer accurate  
82 information. Secondly, the Air Visual application which is widely used for detect  
83 PM 2.5, AQI, temperature, weather and also direction and speed of wind in real-  
84 time, supports both iOS and Android. Moreover, the application will show the color  
85 level of air quality in the measured area and provides a graph of air pollution trends  
86 for 24 hours retrospective that is free to use. One of the Air Visual detection system  
87 station is located in Nakhon Ratchasima, this application is able to check the  
88 backward data and forecast the air quality in a specific area of globalization.

89 In Figure 2(b) shows our PM 2.5 monitoring setup at the station 1. In our  
90 experiment, there will be total of 3 stations. The system can transmit PM 2.5

91 information to the ThingSpeak cloud computing. By using the smart phone and  
 92 Blynk application, anyone can see the PM 2.5 monitoring results of all 3 stations.

93

#### 94 **Experimental Setup**

95 In this section, we show the results of PM 2.5 monitoring system and compare them  
 96 with the ones using Xiaomi PM 2.5 Air Quality Monitor with Air Visual application  
 97 that detecting simultaneously. Figure 3 and Figure 4 give the results of PM 2.5  
 98 concentration from SPS30 sensor in  $\mu\text{g}/\text{m}^3$ . The results from our system with SPS30  
 99 sensor are also compared with the ones from Xiaomi PM 2.5 Air Quality Monitor.  
 100 The solid and the dashed lines represent the PM 2.5 dust concentration by the SPS30  
 101 sensor of PM 2.5 monitoring system and Xiaomi PM 2.5 Air Quality Monitor,  
 102 respectively. From the result, we found that the data obtained by the SPS30 sensor  
 103 and Xiaomi PM 2.5 Air Quality Monitor is related. The relationship can be written  
 104 by

$$105 \quad y = 1.85x \quad (1)$$

$$106 \quad R^2 = 0.99 \quad (2)$$

107 where  $y$  is the PM 2.5 dust concentration by Air Visual application and  $x$  is the PM  
 108 2.5 dust concentration by SPS30 sensor of PM 2.5 monitoring system. The  $R^2$  (R-  
 109 square) is 0.99 or 99%. The values of  $x$  can be calibrated by using Equation (1).  
 110 Figure 5 and Figure 6 show the comparison between both data after calibration.

111 The results from our system with SPS30 sensor are also compared with the  
 112 ones from Air Visual application (Air visual, 2019) which has become one of the  
 most reliable sources of air quality data show in Figure 7. The solid and the dashed

113 lines represent the PM 2.5 dust concentration by the SPS30 sensor of PM 2.5  
 114 monitoring system and Air Visual application, respectively. From the result, we  
 115 found that the data obtained by the SPS30 sensor and Air Visual application is  
 116 related. The relationship can be written by

$$117 \quad y = 1.52x \quad (3)$$

$$R^2 = 0.84 \quad (4)$$

118 where  $y$  is the PM 2.5 dust concentration by Air Visual application and  $x$  is the PM  
 119 2.5 dust concentration by SPS30 sensor of PM 2.5 monitoring system. The  $R^2$  (R-  
 120 square) is 0.84 or 84%. The values of  $x$  can be calibrated by using Equation (3).  
 121 Figure 8 shows the comparison between both data after calibration.

122 In Figure 9, the comparison is made in Air Quality Index (AQI). The  
 123 concentration of PM 2.5 in Figure 1 can be converted to the Air Quality Index by  
 124 using the following equation (Air Quality Index, 2019)

$$125 \quad [AQI]_i = \left\{ \left( \frac{I_{max} - I_{min}}{C_{max} - C_{min}} \right) \times (C_i - C_{min}) \right\} + I_{min} \quad (5)$$

126 where  $AQI_i$  is the Air Quality Index.  $C_i$  is the PM 2.5 concentration from the  
 127 sensor.  $C_{max}$  and  $C_{min}$  are the maximum and minimum of PM 2.5 dust  
 128 concentration range in the Table 1.  $I_{max}$  and  $I_{min}$  are the maximum and minimum  
 129 values of Air Quality Index corresponding to  $C_{max}$  and  $C_{min}$ , respectively. The PM  
 130 2.5 concentration in Air Quality Index from both sources are also found to be  
 131 related. The relationship can be described by

$$132 \quad y = 1.44x \quad (6)$$

$$R^2 = 0.88 \quad (7)$$

133 where  $y$  is the PM 2.5 dust concentration by Air Visual application and  $x$  is the PM  
134 2.5 dust concentration by SPS30 sensor in Air Quality Index. The  $R^2$  (R-square) is  
135 0.88 or 88%. Figure 10 shows the comparison between both data after the value of  
136  $x$  is calibrated

137 In Figure 10, it can be seen that the Air Quality Index from the Air Visual  
138 is slightly higher than the one from the SPS30 sensor. This might be because the  
139 two sensors are not exactly installed at the same place. The location of the Air  
140 Visual sensor is closer to the center of the city where there is more traffic than the  
141 one of the SPS30 sensor.

142

### 143 **Conclusions**

144 We propose a method for PM 2.5 monitoring system by using wireless sensor  
145 networks and the SPS30 sensor which can detect small particles using laser  
146 scattering technique. The microcontroller ESP32 was applied to control the  
147 operation of SPS30 sensor and control the wireless data communication. It also  
148 shares the information received from the WSN to the LCD display and the Blynk  
149 application on smart phone shown in Figure 11. The system can operate 24 h by  
150 using electrical power from solar cells and battery. Our results have been compared  
151 and calibrated with the ones from Air Visual application to ensure reliability. The  
152 results show that our proposed low-cost system is able to provide a reliable real-  
153 time monitoring of the PM 2.5 condition. Thus, it can be used as a prototype of PM  
154 2.5 monitoring product for smart cities. For suggestion, in order to reduce the error  
155 of AQI between Air visual application and our PM 2.5 monitoring system, one



156 might try to move the SPS30 sensor closer to the position where the sensor of Air  
157 visual is installed.

158

### 159 **Acknowledgement**

160 This work was supported by a grant from Suranaree University of Technology,  
161 Nakhon Ratchasima, Thailand.

162

### 163 **References**

164 Livio, L. (2017). Sensirion Particulate Matter Premium PM 2.5 Sensor (SPS30).

165 Available from: [https://www.sensirion.com/en/environmental-](https://www.sensirion.com/en/environmental-sensors/particulate-matter-sensors-pm25/)  
166 [sensors/particulate-matter-sensors-pm25/](https://www.sensirion.com/en/environmental-sensors/particulate-matter-sensors-pm25/). Accessed date: Dec 23, 2019.

167 García-García, L., Jimenez, J.M., Abdullah, M.T.A., and Lloret, J. (2018). Wireless  
168 technologies for IoT in smart cities. *Network Protocols and Algorithms*,  
169 10(1):23-64.

170 Sikder, A.K., Acar, A., Aksu, H., Uluagac, A.S., Akkaya, K., and Conti, M. (2018).  
171 IoT-enabled smart lighting systems for smart cities. 2018 IEEE 8th Annual  
172 Computing and Communication Workshop and Conference (CCWC). Las  
173 Vegas, p. 639-645.

174 Mary, M.C.V.S., Devaraj, G.P., Theepak, T.A., Pushparaj, D.J., and Esther, J.M.  
175 (2018). Intelligent energy efficient street light controlling system based on  
176 iot for smart city. 2018 International Conference on Smart Systems and  
177 Inventive Technology (ICSSIT). Tirunelveli, India, p. 551-554.

- 178 Qin, X., Xian, X., Deng, Y., Wang, D., Tsow, F., Forzani, E., and Tao, N. (2018).  
179 Micro Quartz Tuning Fork-Based PM 2.5 Sensor for Personal Exposure  
180 Monitoring. IEEE Sensors Journal, 19(7):2,482-2,489.
- 181 Airvisual.com. Thailand: Air Visual. Available from: [https://www.airvisual.com/  
182 thailand/nakhon-ratchasima](https://www.airvisual.com/thailand/nakhon-ratchasima). Accessed date: Dec 23, 2019.
- 183 Wikipedia.org. Computing the AQI and the table of air quality index level.  
184 Available from: [https://en.wikipedia.org/wiki/Air\\_quality\\_index](https://en.wikipedia.org/wiki/Air_quality_index). Accessed  
185 date: Dec 27, 2019.
- 186



มหาวิทยาลัยเทคโนโลยีสุรนารี


187 **Table 1. Air Quality Index PM 2.5 (PM 2.5 AQI)**

AQI values	PM 2.5 (ug/m <sup>3</sup> )	Air Pollution Level	Healthy Implication
0-50	0-12	Good	Air quality is considered satisfactory, and air pollution poses little or no risk.
51-100	12.1-35.4	Moderate	Air quality is acceptable; however, for some pollutants there may be a moderate health concern for a very small number of people who are unusually sensitive to air pollution.
101-150	35.5-55.5	Unhealthy for Sensitive Groups	Members of sensitive groups may experience health effects. The general public is not likely to be affected.
151-200	55.6-150.4	Unhealthy	Everyone may begin to experience health effects; members of sensitive groups may experience more serious health effects.
201-300	150.5-250.4	Very Unhealthy	Health warnings of emergency conditions. The entire population is more likely to be affected.
300-500	250.5-500	Hazardous	Health alert; everyone may experience more serious health effects.

188

189

190



191

192


193

194

195


Figure 1. Diagram for hardware connection of PM 2.5 Monitoring System

มหาวิทยาลัยเทคโนโลยีสุรนารี



**Figure 2. (a) Hardware Connection and (b) System setup of Station 1**

201



202


203

204 **Figure 3. Comparison of PM 2.5 dust concentration from Xiaomi PM 2.5 Air**  
 205 **Quality Monitor**

206



207



208


209

210 **Figure 4. Comparison of PM 2.5 dust concentration from Xiaomi PM 2.5 Air**211 **Quality Monitor**

212



213



214


215

216 **Figure 5. Comparison of PM 2.5 dust concentration from Xiaomi PM 2.5 Air**


217 **Quality Monitor after calibration.**

218

219







220

221

222 **Figure 6. Comparison of PM 2.5 dust concentration from Xiaomi PM 2.5 Air**


223 **Quality Monitor after calibration**

224

225



226



227


228

229


Figure 7. Comparison of PM 2.5 dust concentration from Air Visual and SPS30 sensor

230

231



232




233


234

235 **Figure 8. Comparison of PM 2.5 dust concentration from Air Visual and SPS30 sensor**236 **after calibration**

237



238



239


240

241 **Figure 9. Comparison of Air Quality Index from Air Visual and SPS30 sensor**

242

243





244

245

246 **Figure 10. Comparison of Air Quality Index from Air Visual and SPS30 sensor after**  
 247 **calibration**

248




249



250

251

(a)



252

253

(b)

254 Figure 11. (a) PM 2.5 of station 1, station 2 and station 3 and (b) PM 2.5 and AQI of  
 255 station 1, station 2 and station 3 on Blynk application

## ประวัติผู้เขียน

นายชนกร หอประเสริฐวงศ์ เกิดเมื่อวันที่ 10 ธันวาคม พุทธศักราช 2539 ที่จังหวัดอุบลราชธานี ได้เริ่มศึกษาชั้นประถมศึกษาที่โรงเรียนมารีย์นิรมล จังหวัดอุบลราชธานี และสำเร็จการศึกษาระดับมัธยมศึกษาปีที่ 1-6 แผนกวิทยาศาสตร์-คณิตศาสตร์ จากโรงเรียนเบ็ญจะมะมหาราช จังหวัดอุบลราชธานี จากนั้นได้เข้าศึกษาต่อในระดับปริญญาตรี สำนักวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมโทรคมนาคม มหาวิทยาลัยเทคโนโลยีสุรนารี เมื่อปีพุทธศักราช 2558 และสำเร็จการศึกษาปริญญาตรีในปีพุทธศักราช 2562 ด้วยเกรดเฉลี่ย 3.80 (เกียรตินิยมอันดับหนึ่ง) จากนั้นได้เข้าศึกษาต่อในระดับปริญญาโท สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี

ระหว่างศึกษาได้นำเสนอบทความและเข้าร่วมประชุมในงานประชุมนานาชาติ The SUT International Virtual Conference on Science and Technology (IVCST 2020) ณ มหาวิทยาลัยเทคโนโลยีสุรนารี จังหวัดนครราชสีมา วันที่ 28 สิงหาคม พ.ศ. 2563



มหาวิทยาลัยเทคโนโลยีสุรนารี