

การตรวจสอบและแยกแยะประเภทข้อบกพร่องของเซลล์สุริยะ
ด้วยการเรียนรู้เชิงลึก

INSPECTIONS AND IDENTIFICATIONS OF
SOLAR PANEL DEFECT WITH DEEP LEARNING



ปริญญานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรบัณฑิต
สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าคุณทหารลาดกระบัง

ปีการศึกษา 2563

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษานี้เท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

ปริญญาานิพนธ์ปีการศึกษา 2563

ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เรื่อง การตรวจสอบและแยกแยะประเภทข้อบกพร่องของเซลล์สุริยะด้วยการเรียนรู้เชิงลึก

INSPECTIONS AND IDENTIFICATIONS OF SOLAR PANEL DEFECT WITH DEEP
LEARNING

ผู้จัดทำ

1. นายชนพล วิจารณ์ปรีชา รหัสนักศึกษา 60010396
2. นายชนัท แสงเพิ่ม รหัสนักศึกษา 60010427
3. นายพรเทพ หล่มแสง รหัสนักศึกษา 60010659



อาจารย์ที่ปรึกษา
(ผศ.ดร.อานาจ ขาวเน)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

การตรวจสอบและแยกแยะประเภทข้อบกพร่องของเซลล์สุริยะ ด้วยการเรียนรู้เชิงลึก

นายชนพล วิจารณ์ปรีชา 60010396
นายชนัท แสงเพิ่ม 60010427
นายพรเทพ หล่มแสง 60010659
ผศ.ดร.อำนาจ ขาวเน อาจารย์ที่ปรึกษา
ปีการศึกษา 2563

บทคัดย่อ

ในปัจจุบันมีการทำฟาร์มเซลล์สุริยะขนาดใหญ่เป็นจำนวนมาก เพราะเป็นพลังงานสะอาดที่ไม่ก่อให้เกิดมลพิษ แต่สิ่งที่ผู้ใช้งานข้ามคือประสิทธิภาพของตัวเซลล์สุริยะที่จะลดลงเรื่อยๆ ผ่านอายุการใช้งานจนไม่คุ้มค่าในการใช้งานในที่สุดทำให้การตรวจสอบและบำรุงรักษาเป็นหนึ่งในสิ่งจำเป็นที่ต้องทำอยู่เสมอ

การตรวจสอบเซลล์สุริยะนั้นจะทำทุกเดือนหรือเมื่อกำลังไฟของฟาร์มเซลล์สุริยะตกต่ำกว่าขอบเขตที่กำหนดโดยวิธีการตรวจสอบที่แพร่หลายคือการเช็คด้วยกล้อง infrared เพราะสามารถเห็นปัญหาได้หลากหลาย

โครงการ Inspections and Identifications of Solar Panel defect with Deep Learning นี้มีจุดประสงค์ที่จะลดระยะเวลาการตรวจสอบปัญหาของฟาร์มเซลล์สุริยะ ด้วยการแสดงตำแหน่ง และ ประเภทของปัญหาในเซลล์สุริยะ โดยการใช้ Deep Learning มาช่วยในการประมวลผล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use ^I only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

INSPECTIONS AND IDENTIFICATIONS OF SOLAR PANEL DEFECT WITH DEEP LEARNING

Mr. Thanapon Wicharnpreecha 60010396

Mr. Tanut Saengperm 60010427

Mr. Ponthep Lomsaeng 60010659

Asst.Prof.Dr. Amnach Khawne Advisor

Academic Year 2020

Abstract

Nowadays, there are many large solar farms around the world because they produce clean energy but the most users often get overlook is efficiency drop in the solar cell during lifespan. This is the main reason why inspection and maintenance are always one of the necessities for keeping the solar cell working perfectly in full performance

Solar cell inspection should be a monthly process when the electric power of solar farm is lower than the specified range popular inspection method is to check with the infrared camera because we can see many types of solar defects through this method.

Inspections and Identifications of Solar Panel with Deep Learning project purposes to reduce solar defect inspection time by showing solar defect locations and solar defect types with using deep learning in processing

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use^{II} only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

กิตติกรรมประกาศ

ขอขอบคุณอาจารย์ อำนาจ ขาวเน อาจารย์ที่ปรึกษาซึ่งท่าน ได้ให้คำแนะนำและข้อคิดเห็นต่าง ๆ อันเป็นประโยชน์อย่างยิ่งในงานวิจัย อีกทั้งยังช่วยแก้ปัญหาต่าง ๆ ที่เกิดขึ้นระหว่างการดำเนินงานอีกด้วย

ขอขอบคุณอาจารย์และบุคลากรต่าง ๆ ในคณะวิศวกรรมศาสตร์ ภาควิชาวิศวกรรมคอมพิวเตอร์ ที่ให้คำสั่งสอน ความรู้ และคำแนะนำต่าง ๆ มาโดยตลอด รวมถึงเปิดโอกาสให้ทำโครงการ พร้อมทั้งอำนวยความสะดวกด้านสถานที่และอุปกรณ์ ส่งผลให้การทำงานสำเร็จลุล่วงไปด้วยดี

ขอขอบคุณอาจารย์และบุคลากรต่าง ๆ ในคณะวิศวกรรมศาสตร์ ที่ให้คำสั่งสอน ความรู้ และคำแนะนำต่าง ๆ มาโดยตลอด รวมถึงเปิดโอกาสให้ทำโครงการ พร้อมทั้งอำนวยความสะดวกด้านสถานที่และอุปกรณ์ ส่งผลให้การทำงานสำเร็จลุล่วงไปด้วยดี

ขอขอบคุณเพื่อนๆ ในสาขาวิชาวิศวกรรมศาสตร์ ที่คอยให้ความช่วยเหลือ คำแนะนำรวมทั้งการให้กำลังใจและความร่วมมือตลอดมา

สุดท้ายนี้ ขอขอบคุณบุพการี และครอบครัว ที่คอยเลี้ยงดู อบรมสั่งสอน สนับสนุนและให้ความสำคัญกับการศึกษา พร้อมทั้งช่วยเหลือและให้กำลังใจผู้วิจัยเสมอมาจนสำเร็จการศึกษา

ชนพล วิจารย์ปรีชา

ชนัท แสงเพิ่ม

พรเทพ หล่มแสง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	I
บทคัดย่อภาษาอังกฤษ	II
กิตติกรรมประกาศ.....	III
สารบัญ	IV
สารบัญตาราง	IX
สารบัญรูปภาพ	X
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ	1
1.2 วัตถุประสงค์ของ โครงการ	2
1.3 เป้าหมาย	2
1.4 ขอบเขต.....	2
1.5 แผนการดำเนินงาน	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	5
2.1 ทฤษฎีที่เกี่ยวข้อง.....	5
2.1.1 Solar cell.....	5
2.1.2 Object Detection.....	8
2.1.2.1 CNN (Convolutional Neural Network).....	8
2.1.2.2 YOLO	10
2.1.2.3 YOLOV2	12
2.1.2.4 YOLOV3	15

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับอาจารย์และบุคลากรเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านธุรกิจ
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use ^{IV} Only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

สารบัญ(ต่อ)

หน้า

2.1.2.5 YOLOV4	17
2.2 งานวิจัยที่เกี่ยวข้อง	24
2.2.1 Review on Infrared and Electroluminescence Imaging for PV Field Applications	24
2.2.2 Aerial Inspection Report.....	28
2.2.3 A Fast-Learning Method for Accurate and Robust Lane Detection Using Two- Stage Feature Extraction with YOLO v3	30
2.3 เครื่องมือที่ใช้ในการทดลอง	32
2.3.1 Roboflow website.....	32
2.3.2 Figma.....	32
2.3.3 Bootstrap.....	33
2.3.4 MongoDB.....	33
2.3.5 ReactJS	34
2.3.6 FastAPI.....	35
2.3.7 Uvicorn.....	35
2.3.8 Multipart.....	35
2.3.9 React-to-print.....	35
2.3.10 Axios.....	36
บทที่ 3 การออกแบบและพัฒนา.....	37
3.1 Overview	37
3.2 ความต้องการของระบบ	37
3.2.1 Functional Requirement	37

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ(ต่อ)

หน้า

3.2.2 Non-Functional Requirement	38
3.3 User Story ของระบบ	38
3.4 Use Case Diagram.....	39
3.5 Sequence Diagram.....	44
3.5.1. ผู้ใช้นำเข้ารูปภาพ.....	44
3.5.2. ผู้ใช้ทำการประมวลผลรูปภาพที่เลือกไว้.....	44
3.5.3. ผู้ใช้ทำการ export รายงาน	45
3.5.4. ผู้ใช้ทำการใช้คำแนะนำรูปภาพ	45
3.5.5. ผู้ใช้ทำการตรวจสอบรูปภาพก่อนการประมวลผล.....	46
3.5.6. ผู้ใช้ทำการลบรูปภาพที่เลือกไว้.....	46
3.5.7. ผู้ใช้ทำการเปิด/ปิด Solar defect/Rack filter button.....	47
3.5.8. ผู้ใช้ทำการตรวจสอบรายละเอียดรูปแบบปัญหาเซลล์สุริยะ	47
3.5.9. ผู้ใช้ทำการเปลี่ยนรูปภาพที่แสดงผลในหน้าแสดงผลปัญหาเซลล์สุริยะ	48
3.5.10. ผู้ใช้ทำการย้อนกลับจากหน้าแสดงผลปัญหาเซลล์สุริยะ ไปหน้านำเข้ารูปภาพ.....	48
3.6 Class Diagram	49
3.7 User Interface Design.....	50
3.8 ขั้นตอนและวิธีการจัดเตรียมชุดข้อมูล	54
3.9 การแยกประเภทปัญหาเซลล์สุริยะ	54
บทที่ 4 การทดลองและผลการทดลอง.....	56

4.1 การทดลองเปรียบเทียบการกระจายของสี่ต่อประสิทธิภาพของ YOLOV4.....	56
---	----

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ(ต่อ)

	หน้า
4.1.1 วัตถุประสงค์.....	56
4.1.2 วิธีการทดลอง.....	56
4.1.3 ผลการทดลอง	56
4.1.4 วิเคราะห์ผลการทดลอง	58
4.1.5 สรุปผลการทดลอง.....	58
4.2 การทดลองการเปรียบเทียบประสิทธิภาพของโมเดล Faster-RCNN, SSD, YOLOV4	58
4.2.1 วัตถุประสงค์ในการทดลอง.....	58
4.2.2 วิธีการทดลอง	59
4.2.3 ผลการทดลอง	60
4.2.4 วิเคราะห์ผลการทดลอง.....	62
4.2.5 สรุปผลการทดลอง.....	62
4.3 การทดลองทดสอบประสิทธิภาพของ YOLOV4.....	62
4.3.1 วัตถุประสงค์ในการทดลอง.....	62
4.3.2 วิธีการทดลอง.....	62
4.3.3 ผลการทดลอง	64
4.3.4 วิเคราะห์ผลการทดลอง.....	65
4.3.5 สรุปการทดลอง.....	65
บทที่ 5 บทสรุปผลและข้อเสนอแนะ	66
5.1 สรุปผล.....	66
5.2 ปัญหาและแนวทางแก้ไข.....	66

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ(ต่อ)

	หน้า
5.3 แนวทางและการพัฒนาต่อ	66
บรรณานุกรม.....	67



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

VIII

This material is reserved for educational use only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

สารบัญตาราง

ตาราง	หน้า
1.1 แผนการดำเนินงาน โครงการในภาคเรียนที่ 1	3
2.1 เปรียบเทียบข้อดีข้อเสียของการใช้งาน EL และ การใช้งาน IR	27
2.2 แสดงความน่าจะเป็นของการเกิด Hotspot ในแผงเซลล์สุริยะ	29
3.1 Use Case ที่ 1 (Display types, locations and numbers of solar defect)	40
3.2 Use Case ที่ 2 (Filter solar defect and racks).....	40
3.3 Use Case ที่ 3 (Display locations and numbers of rack).....	40
3.4 Use Case ที่ 4 (Check image)	41
3.5 Use Case ที่ 5 (Import images).....	41
3.6 Use Case ที่ 6 (Display file name and file size)	41
3.7 Use Case ที่ 7 (Delete images)	42
3.8 Use Case ที่ 8 (Export PDF report)	42
3.9 Use Case ที่ 9 (Display solar defect detail).....	42
3.10 Use Case ที่ 10 (Display alert when wrong picture).....	43
3.11 Use Case ที่ 11 (Image instruction).....	43
3.12 การแบ่ง dataset ออกเป็นส่วน train และ test	54
3.13 การแยกปัญหาเซลล์สุริยะ.....	54
4.1 จำนวน ground truth ของแต่ละประเภทปัญหา	59
4.2 เปรียบเทียบค่า Precision ของแต่ละ model	60
4.3 จำนวน ground truth ในแต่ละ class ทั้ง 4 ฟาร์ม ของ dataset ที่จะนำมา train.....	63
4.4 ค่า Average precision ในแต่ละ Class ในการ train 7700 iterations.....	64
4.5 ค่า Precision ในแต่ละ class ทั้ง 4 ฟาร์ม ผลลัพธ์ในการ test	65
4.6 ค่า Recall ในแต่ละฟาร์ม ผลลัพธ์ในการ test	65

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูปภาพ

รูป	หน้า
2.1 ตัวอย่าง Hotspots.....	6
2.2 ตัวอย่าง Bypass Diode.....	6
2.3 ตัวอย่าง Vegetation	7
2.4 ตัวอย่าง String Reverse Polarity.....	7
2.5 ตัวอย่าง String Short Circuit	7
2.6 ตัวอย่าง Module Hot	8
2.7 ตัวอย่าง PID	8
2.8 Convolution.....	9
2.9 Max Pooling.....	9
2.10 Flattening	10
2.11 Full connection.....	10
2.12 Detection System	11
2.13 Detection model.....	11
2.14 YOLO architecture.....	12
2.15 สมการ k-means clustering.....	12
2.16 การเปรียบเทียบ cluster IOU กับ Anchor box	13
2.17 ข้อจำกัด Bounding box prediction	13
2.18 ตารางแสดงส่วนที่เพิ่มขึ้นของ YOLOv2 เมื่อเทียบกับ YOLO.....	14
2.19 ชุดข้อมูล PASCAL VOC 2007	14
2.20 ชุดข้อมูล Microsoft COCO	15
2.21 YOLO V3 Architecture.....	16
2.22 Darknet-53 Architecture	16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use^X only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

สารบัญรูปภาพ(ต่อ)

รูป	หน้า
2.23 Anchor box.....	17
2.24 YOLO V4 Anatomy.....	18
2.25 YOLOV4 Anatomy.....	18
2.26 Backbone ใน Yolo V4.....	19
2.27 DenseNet.....	19
2.28 DenseNet.....	20
2.29 Cross Stage Partial DenseNet.....	20
2.30 การปรับลดขนาดของ CNN.....	21
2.31 ส่วนประกอบของ Neck.....	22
2.32 Bounding box.....	23
2.33 Dene Prediction.....	23
2.34 Data Augmentation.....	24
2.35 DC Combiner box overheated.....	25
2.36 PID from IR camera.....	26
2.37 PID from EL camera.....	26
2.38 Busbar Corroded.....	27
2.39 Bypass Diode Active.....	28
2.40 Vegetation.....	29
2.41 แสดงผลลัพธ์ของ Precision-recall (PR) บน KITTI และ Caltech.....	30
2.42 ตารางเปรียบเทียบ Object detection model.....	31
2.43 Roboflow website.....	32
2.44 Figma.....	33

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูปภาพ(ต่อ)

รูป	หน้า
2.45 Bootstrap	33
2.46 MongoDB	34
2.47 React JS.....	34
3.1 ภาพรวมของระบบ	37
3.2 Use Case diagram ของระบบ	39
3.3 Sequence Diagram ผู้ใช้นำเข้ารูปภาพ	44
3.4 Sequence Diagram ผู้ใช้ทำการประมวลผลรูปภาพที่เลือกไว้	44
3.5 Sequence Diagram ผู้ใช้ทำการ download รายงาน	45
3.6 Sequence Diagram ผู้ใช้ทำการใช้คำแนะนำรูปภาพ	45
3.7 Sequence Diagram ผู้ใช้ทำการตรวจสอบรูปภาพก่อนการประมวลผล	46
3.8 Sequence Diagram ผู้ใช้ทำการลบรูปภาพที่เลือกไว้	46
3.9 Sequence Diagram ผู้ใช้ทำการลบรูปภาพที่เลือกไว้	47
3.10 Sequence Diagram ผู้ใช้ทำการตรวจสอบรายละเอียดรูปแบบปัญหาเซลล์สุริยะ	47
3.11 Sequence Diagram ผู้ใช้ทำการตรวจสอบรายละเอียดรูปแบบปัญหาเซลล์สุริยะ	48
3.12 Sequence Diagram ผู้ใช้ทำการย้อนกลับจากหน้าแสดงปัญหาเซลล์สุริยะ ไปหน้านำเข้ารูปภาพ... ..	48
3.13 Class Diagram ของระบบ.....	49
3.14 การออกแบบหน้านำเข้ารูปภาพ.....	50
3.15 การออกแบบ หลังจากผู้ใช้นำเข้ารูปภาพพร้อมกันหลายรูป	50
3.16 การออกแบบ หน้าแสดงคำแนะนำการเลือกรูปภาพสำหรับผู้ใช้	51
3.17 การออกแบบ หลังจากผู้ใช้นำเข้าไฟล์ที่ไม่ได้มีนามสกุล JPEG, PNG, TIF	51
3.18 การออกแบบ progress bar ในช่วงการประมวลผล.....	52
3.19 การออกแบบ หน้าแสดงผล ตำแหน่งและประเภทปัญหาของเซลล์สุริยะ	52

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูปภาพ(ต่อ)

รูป	หน้า
3.20 การออกแบบ หน้าแสดงผลรายละเอียดรูปแบบปัญหาเซลล์สุริยะ	53
3.21 การออกแบบ หน้าแสดงตัวอย่าง report ก่อน download	53
4.1 Color distribution ของฟาร์มที่ 1	56
4.2 Color distribution ของฟาร์มที่ 2	57
4.3 Color distribution ของฟาร์มที่ 3	57
4.4 Color distribution ของฟาร์มที่ 4	58
4.5 ภาพฟาร์มเซลล์สุริยะที่ผ่านการตัดให้เป็นรูปสี่เหลี่ยมจัตุรัส	59
4.6 ผลลัพธ์จาก Model Faster-RCNN	60
4.7 ผลลัพธ์จาก Model SSD Object Detection	61
4.8 ผลลัพธ์จาก Model YOLOV4.....	61
4.9 ตัวอย่างรูปถ่าย infrared ฟาร์มเซลล์สุริยะ.....	62
4.10 ตัวอย่างรูปถ่าย infrared ฟาร์มเซลล์สุริยะ ที่ผ่านการครอบตัดแล้ว.....	63
4.11 ตัวอย่างผลการทดลอง	64

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

ในยุคปัจจุบันที่เชื้อเพลิงและถ่านหินสร้างมลภาวะมากมายทั้งในน้ำและอากาศ ทำให้ในหลายประเทศเริ่มนิยมใช้พลังงานสะอาดหรือพลังงานหมุนเวียนยกตัวอย่างเช่นพลังงานลม พลังงานน้ำและพลังงานแสงอาทิตย์ มาแทนที่การใช้พลังงานจากเชื้อเพลิงและถ่านหิน โดยที่พลังงานไฟฟ้าจากแสงอาทิตย์เป็นที่นิยมแพร่หลายมากที่สุด เนื่องจากที่ส่วนใหญ่ที่มีการใช้พลังงานไฟฟ้าจะมีแสงอาทิตย์ แต่แหล่งผลิตพลังงานไฟฟ้าจากลมและน้ำ สามารถผลิตได้ในสถานที่ที่จำกัดแค่บางพื้นที่

เซลล์สุริยะที่ใช้ผลิตพลังงานไฟฟ้าจากแสงอาทิตย์นั้นจะมีการเสื่อมประสิทธิภาพแบบที่สามารถมองเห็นได้ด้วยตาเปล่า ตัวอย่างเช่น ผุ้ตะกองที่เกาะบนแผงเซลล์สุริยะ รอยนิ้วมือ วัชพืชที่ขึ้นบนแผงเซลล์สุริยะ รอยแตกภายนอก ฟองอากาศในพื้นที่ผิวของเซลล์สุริยะ การขึ้นสนิมของกรอบเซลล์สุริยะ เป็นต้น และมีการเสื่อมประสิทธิภาพแบบที่สามารถมองเห็นได้เมื่อใช้เครื่องมือ ตัวอย่างเช่น ภาพถ่ายที่ได้จากกล้อง EL (Electroluminescence) ที่สามารถตรวจสอบการเสื่อมประสิทธิภาพประเภท Microcrack (รอยแตกภายในขนาดเล็ก) ,Electrically inactive (ส่วนที่ไฟฟ้าไม่ทำงาน) และ ภาพถ่ายที่ได้จากกล้อง Infrared ที่สามารถตรวจสอบการเสื่อมประสิทธิภาพประเภท Cell hotspot (เซลล์สุริยะร้อนเฉพาะจุด) ,Bypass circuit (เซลล์สุริยะร้อนเป็นวงกว้าง) ,Junction box (กล่องพักสายไฟร้อน) ,Connection (สายไฟในกล่องพักสายไฟร้อน) ,Module (แต่ละเซลล์เชื่อมต่อไม่ถูกต้อง) ซึ่งข้อแตกต่างระหว่างกล้อง EL กับ IR คือ EL มีความละเอียดของภาพมากกว่าทำให้ตรวจสอบปัญหาได้ดีกว่า แต่มีราคาที่สูง ส่วนกล้อง IR มีราคาที่ถูกกว่าและภาพที่ได้จากกล้อง IR มีความละเอียดของภาพต่ำกว่า EL และทั้งสองรูปแบบมองเห็นปัญหาคนละประเภทกัน

ในปัจจุบันการตรวจสอบประสิทธิภาพของเซลล์สุริยะ โดยใช้กล้อง IR จะต้องใช้ผู้เชี่ยวชาญในการตรวจสอบจุดบกพร่อง ซึ่งหากต้องตรวจสอบฟาร์มเซลล์สุริยะที่มีขนาดใหญ่ จะต้องใช้เวลานาน ทำให้มีค่าใช้จ่ายสูง โครงการ “ Inspections and Identifications of Solar Panel defect with Deep Learning ” จัดทำขึ้นเพื่อแก้ไขปัญหาดังกล่าว โดยใช้ Deep Learning มาช่วยตรวจสอบภาพเซลล์สุริยะแทนผู้เชี่ยวชาญเพื่อลดค่าใช้จ่ายและลดระยะเวลาในการตรวจสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

1.2 วัตถุประสงค์ของโครงการ

- 1) ลดระยะเวลาในการตรวจสอบประสิทธิภาพแผงเซลล์สุริยะ
- 2) ลดค่าใช้จ่ายในการจ้างผู้เชี่ยวชาญทางด้านเซลล์สุริยะมาตรวจสอบ
- 3) ลดปัญหาข้อผิดพลาดจากการตรวจสอบที่เกิดจากมนุษย์

1.3 เป้าหมาย

ใช้งานเทคโนโลยี deep learning มาตรวจสอบสภาพของเซลล์สุริยะแทนการจ้างผู้เชี่ยวชาญ เพื่อลดระยะเวลาและค่าใช้จ่ายในการตรวจสอบสภาพแผงเซลล์สุริยะและเพิ่มความแม่นยำในการตรวจสอบ

1.4 ขอบเขต

- 1) ประมวลผลด้วยข้อมูลภาพถ่ายเซลล์สุริยะจากมุมสูงด้วยอากาศยานไร้คนขับจากกล้อง infrared ที่ผ่านการทำ orthophoto map
- 2) แสดงผลปัญหา ประเภทและตำแหน่งของแผงเซลล์สุริยะให้เข้าใจง่ายต่อผู้ใช้งาน
- 3) ระบุประเภทปัญหาของแผงเซลล์สุริยะ 7 ประเภท ได้แก่ Hotspots, Bypass Diode, Vegetation, Module Hot, PID, String short, String reverse

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.5 แผนการดำเนินงาน

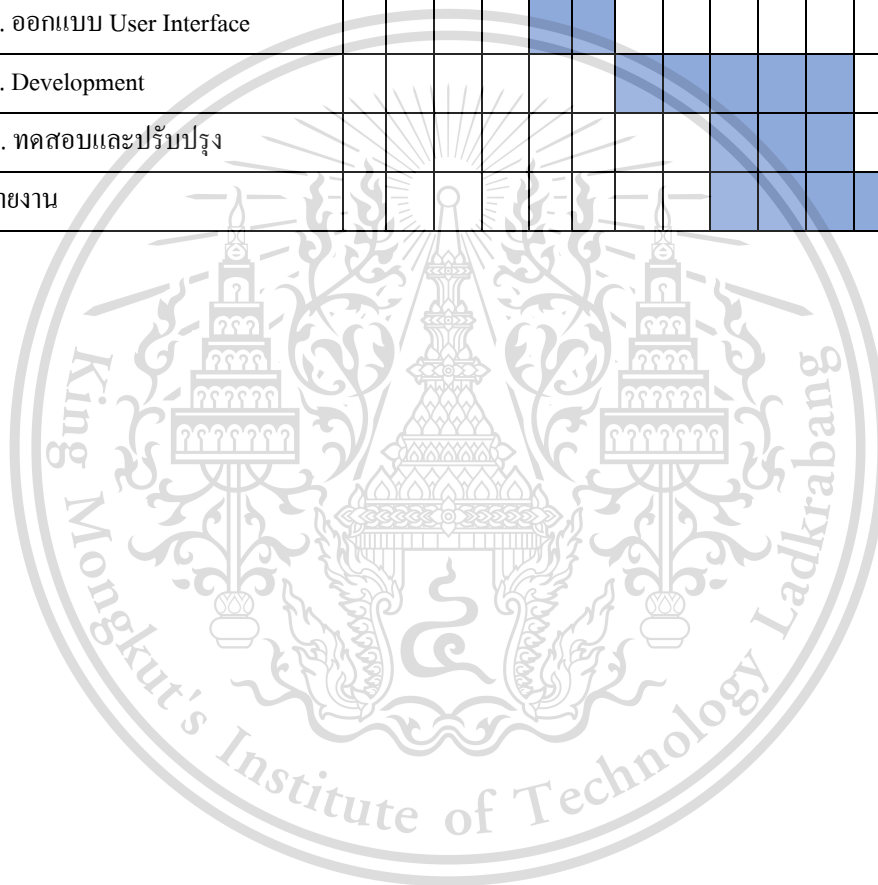
ตาราง 1.1 แผนการดำเนินงานโครงการในภาคเรียนที่ 1

หัวข้องาน	ส.ค.				ก.ย.				ต.ค.				พ.ย.			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1. สืบค้นข้อมูล	■	■			■	■	■	■								
1.1 งานวิจัยที่เกี่ยวข้อง	■	■														
1.2 Data Set			■	■												
1.3 Deep Learning					■	■	■	■								
1.4 Image Processing					■	■	■	■								
1.5 Python					■	■	■	■								
1.6 CIRA core					■	■	■	■								
1.7 อาคารเสี้ยวของ Solar cell					■	■	■	■								
1.8 Object Detection					■	■	■	■								
2. เตรียมข้อมูล																
2.1. Labeling																
2.2. Annotation																
3. Training									■	■	■	■	■	■	■	
4. ทดสอบและแก้ไข model									■	■	■	■	■	■	■	
5. ทำรายงาน									■	■	■	■	■	■	■	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตาราง 1.2 แผนการดำเนินงานโครงการในภาคเรียนที่ 2

หัวข้องาน	ม.ค.				ก.พ.				มี.ค.				เม.ย.			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1. สืบค้นข้อมูล	■	■	■	■												
1.1 ReactJS	■	■														
1.2 FastAPI framework			■	■												
2. ออกแบบและพัฒนาเว็บไซต์					■	■	■	■	■	■	■	■				
2.1. ออกแบบ User Interface					■	■										
2.2. Development							■	■	■	■	■	■				
2.3. ทดสอบและปรับปรุง									■	■	■	■				
3. ทำรายงาน									■	■	■	■				



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 Solar cell

ฟาร์มเซลล์สุริยะโดยส่วนมากจะถูกใช้งานมานานแล้ว ซึ่งอายุที่เพิ่มขึ้นทำให้โอกาสเกิดปัญหาเพิ่มขึ้นตามการเสื่อมสภาพตามอายุการใช้งาน ทำให้จำเป็นต้องมีการตรวจสอบและบำรุงรักษาอย่างสม่ำเสมอ โดยเมื่อพิจารณาถึงจำนวนของแผงเซลล์สุริยะภายในแต่ละฟาร์ม การใช้ภาพมุมมองของภาพ infrared และภาพถ่ายจากเซลล์สุริยะจึงเป็นหนึ่งทางเลือกที่เป็นที่นิยม มีความเชื่อกันว่าเซลล์สุริยะนั้นดูแลรักษาง่ายหรือไม่ต้องดูแลเลย ซึ่งคำกล่าวนั้นเป็นจริงในบางกรณี ซึ่งทำให้เกิดการเข้าใจผิด เพราะการลงทุนทำฟาร์มเซลล์สุริยะนั้นจะทำต่อเนื่องไป 20-25 ปี ในการคำนวณผลตอบแทนที่แม่นยำ จำเป็นจะต้องนึกถึงค่าดำเนินการและค่าดูแลรักษา รวมทั้งเข้าใจวิธีการจัดการจัดการที่คุ้มค่าและคุ้มค่าที่สุด เมื่อปัญหาถูกพบบนเซลล์สุริยะในบางปัญหาขนาดเล็กสามารถแก้ไขได้ก่อนจะทำให้เกิดปัญหาที่ทำให้เกิดความเสียหายขนาดใหญ่ที่ต้องเสียค่าใช้จ่ายในการแก้ไข

ปัญหาของเซลล์สุริยะจะถูกแบ่งได้เป็น ปัญหาบนตัวแผง ปัญหาของสายไฟ ปัญหาของกล่องพักสายไฟ กล่องแปลงไฟ วัชพืชข้างเคียง โดยการเช็คปัญหาอย่างละเอียดจะเกิดขึ้นในสถานที่นั้นๆ ซึ่งจะต้องปลดแผงนั้นออกมาทำการทดสอบประสิทธิภาพซึ่งมีค่าใช้จ่ายและใช้เวลา หลายปัญหาสามารถตรวจพบได้โดยใช้งานภาพ infrared โดยจะเห็นเป็น จุดความร้อนที่อุณหภูมิแตกต่างจากบริเวณโดยรอบอย่างชัดเจน

นอกจากนั้นภาพถ่ายปกติของเซลล์สุริยะยังสามารถใช้ตรวจสอบความเสียหายของเซลล์สุริยะบางรูปแบบได้อีกด้วยเช่น รอยรอยแตก ความสกปรก รอยแตก ฟองอากาศในแผง การสึกหรอของกรอบ ซึ่งสามารถตรวจสอบได้ชัดเจนกว่าการใช้ภาพ infrared


การถ่ายภาพ infrared นั้นสามารถทำได้ระหว่างที่ตัวเซลล์สุริยะกำลังทำงานอยู่จึงไม่จำเป็นต้องปิดเซลล์สุริยะลง หากใช้อย่างเหมาะสมภาพ infrared จะสามารถแสดงความแตกต่างได้อย่างแม่นยำทำให้สามารถแก้ไขปัญหาได้ในระยะตั้งต้นที่ปัญหายังไม่รุนแรง

การใช้งาน drone (อากาศยานไร้คนขับ) จะทำให้สามารถควบคุมกระบวนการบันทึกภาพได้อย่างแม่นยำทำให้ลดค่าใช้จ่ายทำให้การถ่ายภาพ infrared นั้นง่ายต่อการจัดตำแหน่ง, ระยะห่างและเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

มุมมองที่ต้องการ จากการสำรวจ drone สามารถตรวจสอบเซลล์สุริยะได้ถึง 4000 แผงใน 5 นาที ในขณะที่
ที่ใช้คนในการตรวจสอบจะใช้เวลาถึง 8 วันด้วยอัตราที่ 1 แผงต่อ 1 นาที

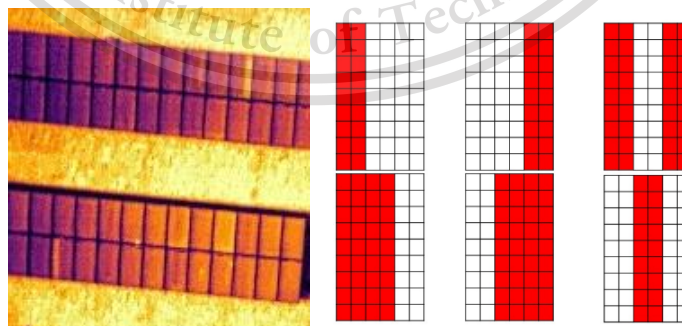
2.1.1.1. ประเภทปัญหาของแผงเซลล์สุริยะ

1. Hotspots ส่วนใหญ่เกิดจากเซลล์ที่มีข้อบกพร่องภายใน PV โมดูล ตัวอย่างเช่น microcrack การผลิตที่ผิดพลาดและอื่นๆ และยังสามารถเกิดจากการบดบังของเงาที่ทำให้กระแสไฟฟ้าไหลจากศักย์สูงไปต่ำทำให้เกิดจุดความร้อน



รูป 2.1 ตัวอย่าง Hotspots


2. Bypass Diode เกิดจากเซลล์ที่มีข้อบกพร่องทำให้แรงดันไฟฟ้าตกลง ไดโอดจึงถูกกระตุ้นเพื่อป้องกันการสูญเสียพลังงานของทั้งแผงเซลล์สุริยะ ซึ่งหมายความว่าอย่างน้อยที่สุดหนึ่งในสามของพลังงานที่ผลิตจะลดลง



รูป 2.2 ตัวอย่าง Bypass Diode

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. Vegetation เป็นประเภทที่บ่งบอกว่า PV โมดูลมีการบดบังของวัชพืช vegetation
ควรที่จะกำจัดให้เร็วที่สุดเท่าที่เป็นไปได้ก่อนที่จะเป็นสาเหตุให้เกิด hotspots




รูป 2.3 ตัวอย่าง Vegetation

4. String Reverse Polarity เกิดมาจากการเชื่อมต่อของขั้วตรงข้ามในแผงเซลล์สุริยะ
ซึ่งเกิดจากข้อผิดพลาดของผู้ติดตั้งแผงเซลล์สุริยะที่แผง DC



รูป 2.4 ตัวอย่าง String Reverse Polarity


5. String Short Circuit เกิดมาจากสายไฟของแผงเซลล์สุริยะทั้งแถวที่อาจลัดวงจร
สายไฟหลวมหรือ ground fault



รูป 2.5 ตัวอย่าง String Short Circuit


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

6. Module Hot เกิดจากเมื่อทั้ง โมดูลทำงานผิดปกติทั้งจากการผลิตหรือปัญหาที่เกิดจากการติดตั้งแผงเซลล์สุริยะ



รูป 2.6 ตัวอย่าง Module Hot

7. PID เกิดจากลักษณะอาการของไฟฟ้าในแผงเกิดข้อผิดพลาดกรณีนี้ค้นพบบ่อยในแผงเซลล์สุริยะที่ใช้เทคโนโลยีเก่า ปัจจุบันแผงเซลล์สุริยะมีตัวป้องกันการเกิด PID ในแผงอยู่แล้ว



รูป 2.7 ตัวอย่าง PID


2.1.2 Object Detection

คือการหาวัตถุและตำแหน่งที่เราสนใจในภาพหนึ่ง ซึ่งจะมีอัลกอริทึมที่นิยมใช้คือ CNN

2.1.2.1 CNN (Convolutional Neural Network)


เป็นหนึ่งในอัลกอริทึมของ Deep learning ใช้วิเคราะห์รูปภาพ โดยแยกคุณลักษณะของพื้นที่รูปภาพเช่น ลายเส้น และการตัดกันของสี ซึ่งมีขั้นตอนการทำงาน 4 ขั้นตอน เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. Convolution คือ การใช้ filter หรือ kernel ในการหา feature map โดยจะทำการนำรูปคุณเมทริกและเลื่อน kernel ทำการคูณเมทริกซ้ำจนครบทั้งรูป ได้เป็น convolution layer และทำการปรับค่าด้วย activation function ต่างๆเช่น ReLU หรือ Sigmoid



รูป 2.8 Convolution


2. Max Pooling คือการย่อรูปโดยดึงลักษณะเด่นที่ทำ CNN โดยการหาค่าสูงสุดในบริเวณที่ทำ Pooling เพื่อใช้ในการคำนวณในขั้นตอนต่อไป



รูป 2.9 Max Pooling

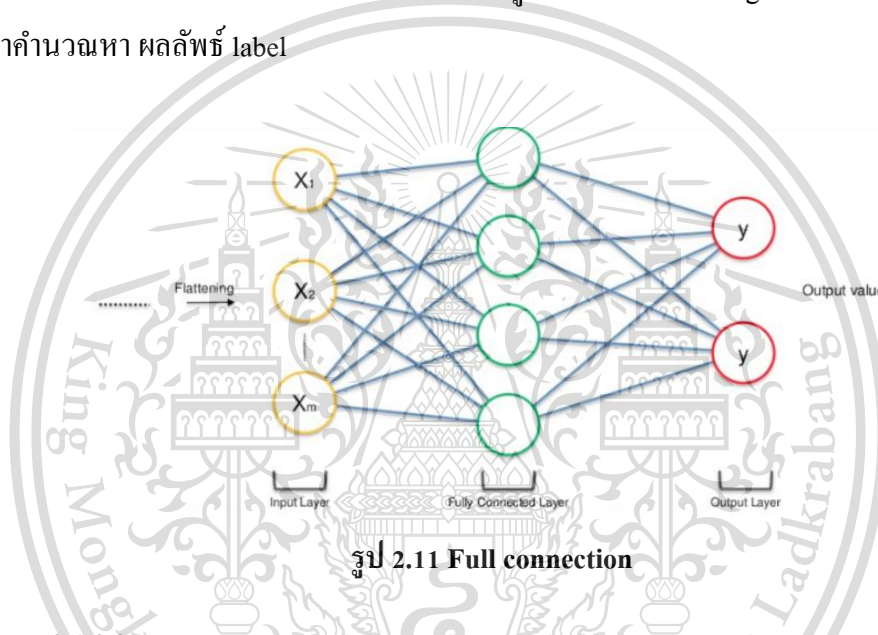
3. Flattening คือการแปลงข้อมูลให้อยู่ในรูป อาร์เรย์ 1 มิติ เพื่อใช้ในการคำนวณในขั้นตอนสุดท้าย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.10 Flattening

4. Full Connection คือการนำข้อมูลที่ได้จาก Flattening มาทำการ classification ได้ score มากำหนดหา ผลลัพธ์ label



รูป 2.11 Full connection

2.1.2.2 YOLO

YOLO เป็น Object detection model ที่ถูกคิดค้นขึ้นในปี 2016 โดยมีวิธีการ classifier ที่แตกต่างจาก Object detection model ตัวอื่น คือการตีกรอบวัตถุเหมือนกับการ regression เพื่อแบ่ง bounding box และ ความน่าจะเป็นในแต่ละ class นอกจากนี้ Neural network สามารถที่จะทำนาย bounding box และ ความน่าจะเป็นในแต่ละ class ในรูปภาพได้ในการประมวลผลเพียงครั้งเดียว ต่อมาสถาปัตยกรรมของ YOLO มีความรวดเร็วในการประมวลผลสูง ซึ่งสามารถประมวลผลภาพแบบ real-time ได้ 45 เฟรมใน 1 วินาที รวมทั้งได้ ค่า mAP(mean average precision) ดีกว่าเกือบ 2 เท่าเมื่อเทียบกับ Object detection model อื่น ถึงอย่างนั้น YOLO ก็ยังมีข้อเสียในการเกิด localize error มากกว่า


YOLO ใช้ detection system ที่เข้าใจง่ายตามรูปข้างล่าง ขั้นตอนแรกทำการลดขนาด

รูปภาพต้นฉบับให้เหลือแค่ 448*448 ต่อมาทำการใช้งาน Convolutional network ในแต่ละรูปภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

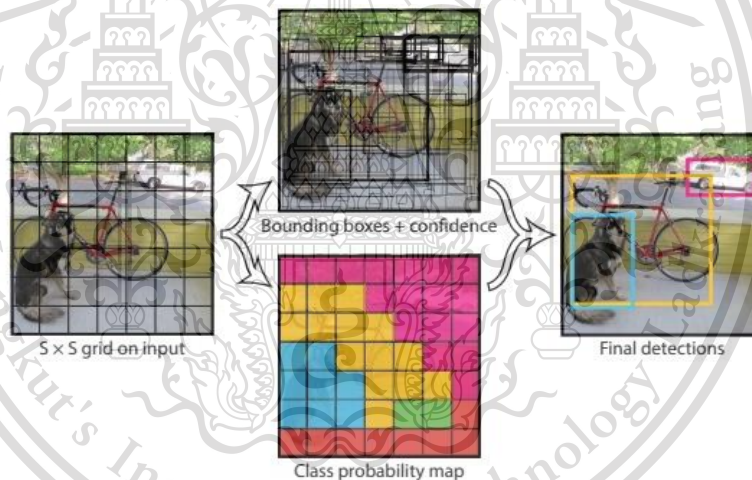
สุดท้ายแสดงผลลัพธ์การตรวจสอบ ด้วยค่า confidence ของ model นี้

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.12 Detection System


YOLO สามารถที่จะ train ในภาพขนาดใหญ่ได้ และปรับการประมวลผลของการตรวจสอบได้โดยตรงได้อีกด้วย นอกจากนี้ YOLO ยังมีข้อดีอีกมากมายตัวอย่างเช่น 1. YOLO เร็วมาก ตั้งแต่ขั้นตอนการตีกรอบ ซึ่งไม่ต้องการขั้นตอนที่ซับซ้อน 2. YOLO มีความแม่นยำสูงเมื่อเทียบกับ Object Detection model อื่น 3. YOLO สามารถเรียนรู้การจำลอง object ได้ดี ถึงแม้ว่าจะนำภาพที่แตกต่างจากภาพที่ใช้ train มาก YOLO ก็สามารรถที่จะทำนายได้แม่นยำมากกว่า Object Detection Model อื่น



รูป 2.13 Detection model

ในส่วนของการสถาปัตยกรรมใน YOLO จะประกอบไปด้วย convolutional layer 24 ชั้น ตามด้วย fully connected layer 2 ชั้น การสลับ 1*1 convolutional layer จะช่วยลดพื้นที่ของ feature ใน preceding layer ลง นอกจากนี้ยังเชื่อมโยง convolutional layer ในการจำแนกรูปภาพที่ความละเอียดลดลงครั้งหนึ่งและเพิ่มความละเอียดในการตรวจสอบเป็นเท่าตัว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.14 YOLO architecture

2.1.2.3 YOLOV2

YOLOV2 ทำการปรับปรุง YOLOV1 เพื่อให้ได้ประสิทธิภาพที่เพิ่มขึ้นดังนี้

- 1) เพื่อ Batch Normalization ใน convolutional layer ทั้งหมด ได้ประสิทธิภาพเพิ่มขึ้น 2% ของค่า mAP
- 2) Classifier ภาพความละเอียดสูงขึ้น ด้วยการใส่ภาพขนาด 448X448 สำหรับปรับแต่ง classification network สำหรับ 10 epochs บน ImageNet ได้ประสิทธิภาพเพิ่มขึ้น 4% ของค่า mAP
- 3) Convolutions กับ Anchor Boxes ใน YOLOV2 ทำการลบ fully connected layers ออกทั้งหมดและใช้ Anchor Boxes สำหรับการทำนาย bounding boxes แทน และลบ pooling layer ออกจำนวน 1 layer เพื่อเพิ่มความละเอียดของ output และใช้ภาพขนาด 416X416 สำหรับการ training ใน detection network และผลลัพธ์ที่ได้คือ feature ขนาด 13X13 ด้วยการเพิ่ม anchor boxes ใน YOLOV2 ทำให้ค่า mAP ลดลงเล็กน้อยแต่ได้ค่า recall ที่เพิ่มขึ้นอย่างมาก
- 4) Dimension Clusters ขนาดของ anchor boxes เป็นการกำหนดเบื้องต้น โดยไม่มี prior information ใดๆ เหมือนกันกับ Faster-RCNN, YOLOV2 ใช้ k-means clustering ทำให้ได้ค่า IOU ที่เพิ่มขึ้น

$$d(\text{box}, \text{centroid}) = 1 - \text{IOU}(\text{box}, \text{centroid})$$


รูป 2.15 สมการ k-means clustering

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อใช้ในการศึกษาเท่านั้น มิใช่เพื่อเผยแพร่สู่สาธารณะ
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

	Box Generation	#	Avg IOU
Euclidean Distance based	Cluster SSE	5	58.7
IOU based	Cluster IOU	5	61.0
Faster R-CNN	Anchor Boxes [15]	9	60.9
IOU based	Cluster IOU	9	67.2

รูป 2.16 การเปรียบเทียบ cluster IOU กับ Anchor box

5) Direct Location Prediction ใน YOLOV1 ไม่มีข้อจำกัดในการทำ location prediction ทำให้โมเดลไม่เสถียรในช่วงแรก bounding box ที่ทำนายจะอยู่ไกลจากตำแหน่งเดิมของ object สำหรับ YOLOV2 จำกัดขอบเขตตำแหน่งด้วยการใช้ logistic activation σ ซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 ทำให้ประสิทธิภาพเพิ่มขึ้น 5% ของค่า mAP



รูป 2.17 ข้อจำกัด Bounding box prediction

6) Fine Grained Feature ผลลัพธ์ที่ได้ มี feature ขนาด 13X13 ซึ่งเพียงพอสำหรับการทำ detect object ขนาดใหญ่ ทำให้ค่าประสิทธิภาพเพิ่มขึ้น 1% ของค่า mAP

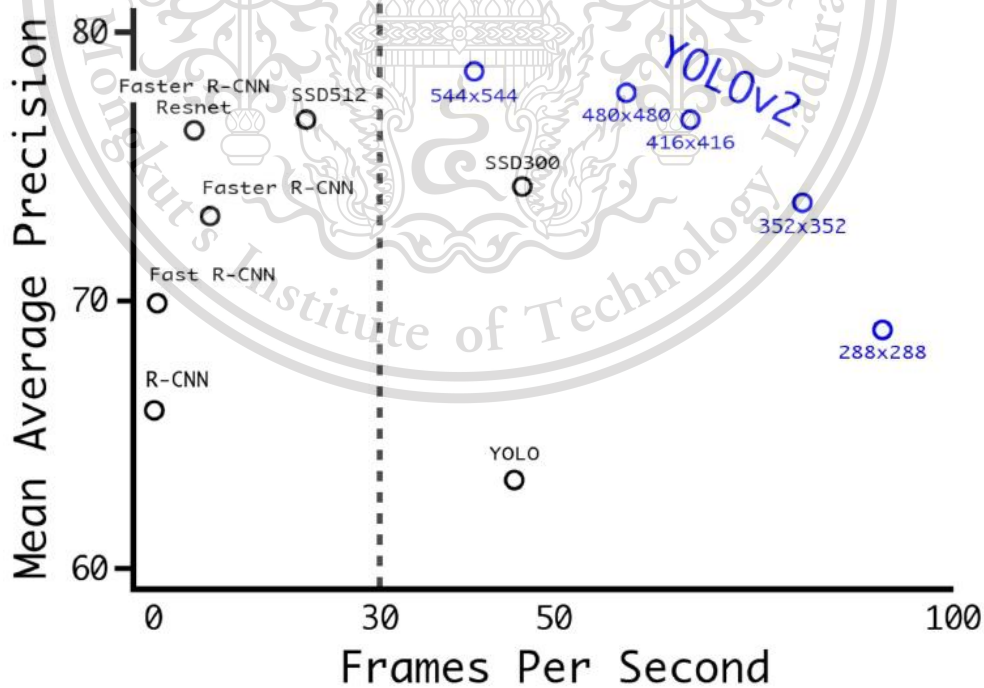
7) Multi Scale Training สำหรับทุกๆ 10 batches มิติของภาพใหม่จะถูกสุ่มจาก {320, 352, ..., 608} และทำการปรับขนาดของภาพและทำการ training ต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

	YOLO								YOLOv2
batch norm?		✓	✓	✓	✓	✓	✓	✓	✓
hi-res classifier?			✓	✓	✓	✓	✓	✓	✓
convolutional?				✓	✓	✓	✓	✓	✓
anchor boxes?				✓	✓				✓
new network?					✓	✓	✓	✓	✓
dimension priors?						✓	✓	✓	✓
location prediction?						✓	✓	✓	✓
passthrough?							✓	✓	✓
multi-scale?								✓	✓
hi-res detector?									✓
VOC2007 mAP	63.4	65.8	69.5	69.2	69.6	74.4	75.4	76.8	78.6

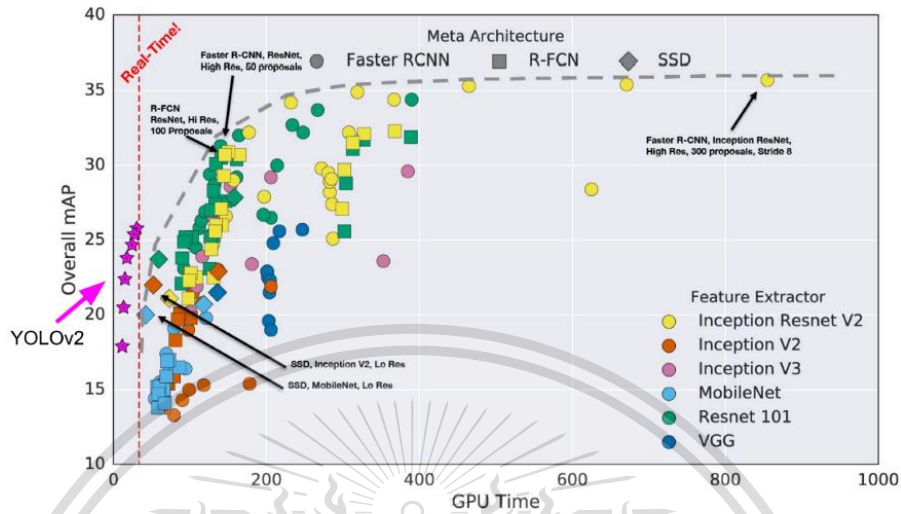
รูป 2.18 ตารางแสดงส่วนที่เพิ่มขึ้นของ YOLOv2 เมื่อเทียบกับ YOLO

สรุป สำหรับ YOLOV2 ประมวลผลได้รวดเร็วสำหรับภาพขนาดเล็ก ในภาพที่มีความละเอียดต่ำ ที่ 90 FPS มีค่า mAP เทียบเท่ากับ Fast R-CNN โดย Fast R-CNN เหมาะสำหรับ GPU ขนาดเล็ก แต่ในภาพที่มีความละเอียดสูงได้ค่า 76.8% mAP สำหรับการ detection แบบ real time speed



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการนำข้อมูล PASCAL VOC 2007 ไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับชุดข้อมูล MS COCO มีเพียง YOLOV2 ที่มี performance แบบ real time ได้ตามกราฟด้านล่าง



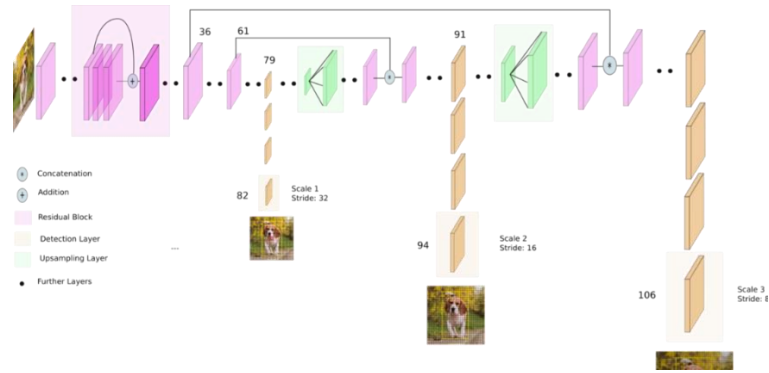
รูป 2.20 ชุดข้อมูล Microsoft COCO

2.1.2.4 YOLOV3

YOLOV3 มีรูปแบบโครงสร้างที่แบ่งออกเป็น 2 ส่วนหลักคือ 1.Feature Extractor เป็นตัวรับภาพเข้ามา ซึ่งในปัจจุบัน YOLO V3 ใช้ตัว Darknet-53 ซึ่งเป็น Network ที่มีทั้งหมด 53 layer หลังจากที่ผ่านมากระบวนการ Darknet-53 แล้ว จะได้รูปภาพอยู่ในรูปแบบ Grid 3 ขนาด คือ 13*13, 26*26, 52*52 เพื่อส่งต่อไปให้ Detector ต่อไป

2.Detector เป็นตัวตรวจจับหาวัตถุต่าง ๆ ในภาพ โดยในขั้นตอนแรกจะทำการหาแต่ละ cell ใน grid feature map ขนาด 13*13 ก่อน ซึ่งแต่ละ cell จะได้ประกอบไปด้วย 3 anchor ซึ่งแต่ละ anchor จะประกอบไปด้วย Box Co-ordinates , Objectness Score, Class Scores ทั้งนี้การใช้ anchor ก็เพื่อตรวจสอบว่าในรูปมีวัตถุที่เราสนใจหรือไม่ ด้วยการดูค่า object score และ สามารถตรวจสอบชนิดของ class ในรูปได้อีกด้วย หลังจากนั้นก็จะไปหา cell ใน grid feature map ขนาด 26*26 และ 52*52 ต่อไปเรื่อยๆ ซึ่ง grid feature map แต่ละ layer ก็จะใช้หาวัตถุที่มีขนาดแตกต่างกัน เช่น 13*13 วัตถุแบบหยาบ 26*26 วัตถุแบบกลาง และ 52*52 วัตถุแบบละเอียด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูป 2.21 YOLO V3 Architecture

Type	Filters	Size	Output
Convolutional	32	3 × 3	256 × 256
Convolutional	64	3 × 3 / 2	128 × 128
Convolutional	32	1 × 1	
1x Convolutional	64	3 × 3	
Residual			128 × 128
Convolutional	128	3 × 3 / 2	64 × 64
Convolutional	64	1 × 1	
2x Convolutional	128	3 × 3	
Residual			64 × 64
Convolutional	256	3 × 3 / 2	32 × 32
Convolutional	128	1 × 1	
8x Convolutional	256	3 × 3	
Residual			32 × 32
Convolutional	512	3 × 3 / 2	16 × 16
Convolutional	256	1 × 1	
8x Convolutional	512	3 × 3	
Residual			16 × 16
Convolutional	1024	3 × 3 / 2	8 × 8
Convolutional	512	1 × 1	
4x Convolutional	1024	3 × 3	
Residual			8 × 8
Avgpool		Global	
Connected		1000	
Softmax			


รูป 2.22 Darknet-53 Architecture

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


Image Grid. The Red Grid is responsible for detecting the dog



Prediction Feature Map



Attributes of a bounding box



รูป 2.23 Anchor box


2.1.2.5 YOLOV4

การตรวจสอบหาวัตถุจากรูปภาพยังคงเป็นกระแสและน่าสนใจมากขึ้นเมื่อ yoloV4 ถูกปล่อยงานวิจัยออกมาที่แสดงให้เห็นถึงการเน้นย้ำของความเร็วในการประมวลผลที่รวดเร็วกว่า โปรแกรมตรวจสอบวัตถุจากภาพอื่น ๆ อย่างเห็นได้ชัดในงานบทความนี้จะวิเคราะห์ลึกลงไปในงานวิจัยของผู้สร้าง YoloV4 และนำมาเปรียบเทียบกับตรวจสอบหาวัตถุที่มีมาก่อนแล้ว โดยย่อ

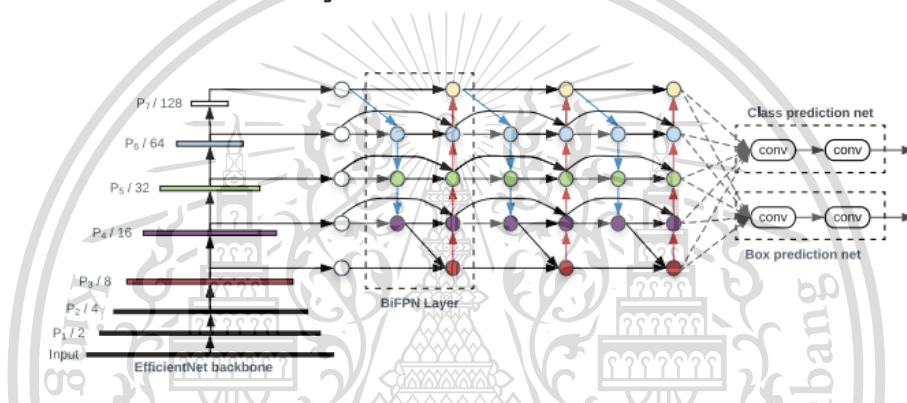
YOLOV4 คือส่วนขยายของเทคนิคการทำ computer vision ที่มีอยู่ที่ผ่านการปรับปรุงด้วยเทคนิคใหม่ลงไป ที่จะมาเสริมกับส่วนที่มีอยู่แล้วทำให้เพิ่มประสิทธิภาพได้อย่างชัดเจน นอกจากนี้ยังเป็น โมเดลในการตรวจสอบวัตถุที่ถูกสอน โดยการดูรูปภาพและค้นหาสมาชิกของวัตถุที่กำหนดไว้ เมื่อตรวจพบจะถูกตีกรอบและถูกระบบว่าเป็นวัตถุอะไร โดยทั่วไปโมเดลการตรวจสอบวัตถุ จะถูกทดสอบโดยเรียนรู้จากชุดข้อมูล COCO ที่ประกอบไปด้วยวัตถุ 80 ประเภท ทำให้รู้ว่าโมเดลนั้นสามารถตรวจสอบได้อย่างกว้างขวางและพร้อมสำหรับประเภทวัตถุใหม่ ทำให้การประมวลผลแบบ realtime มีความสำคัญมากสำหรับการประมวลผลบนวิดีโอ เช่น ยานยนต์อัตโนมัติอีกข้อดีคือโมเดลมีขนาดเล็กและง่ายต่อการใช้งาน โดยผู้พัฒนาโปรแกรม ซึ่งYOLOV4 ถูกออกแบบมาเพื่อนำมาเน้นการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตรวจสอบวัตถุในวิดีโอเป็นหลักโดยผู้สร้างสอนโมเดลโดยใช้ GPU เพียงตัวเดียวโดยมีจุดประสงค์การสร้างและพัฒนาโมเดลนี้ขึ้นเพื่อให้ง่ายต่อผู้ใช้ในการใช้งาน โมเดลในวัตถุที่กำหนดของตนเอง



รูป 2.24 YOLO V4 Anatomy



รูป 2.25 YOLOV4 Anatomy

ทุกโมเดลตรวจสอบวัตถุจะรับรูปภาพเป็น input และ บีบอัดเอาแค่ feature ผ่านไป ใน CNN backbone ซึ่งในการทำ image classification นั้น backbone จะเป็นส่วนสุดท้ายของ network แล้วต่อจากนั้นคือการระบุประเภทเลย แต่ในโมเดลตรวจสอบวัตถุจะต้องมีการตีกรอบรอบวัตถุบนรูป ในทุกวัตถุรวมถึงระบบประเภทวัตถุด้วย ทำให้ feature layer ของ backbone จะต้องผ่านอีก convolution ที่ the neck

1) YOLOv4 backbone network-Feature Formation ใน object detector จะถูก pretrain บนข้อมูลของ ImageNet หมายความว่า network weight ได้ปรับให้ระบุ feature ที่สัมพันธ์กับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

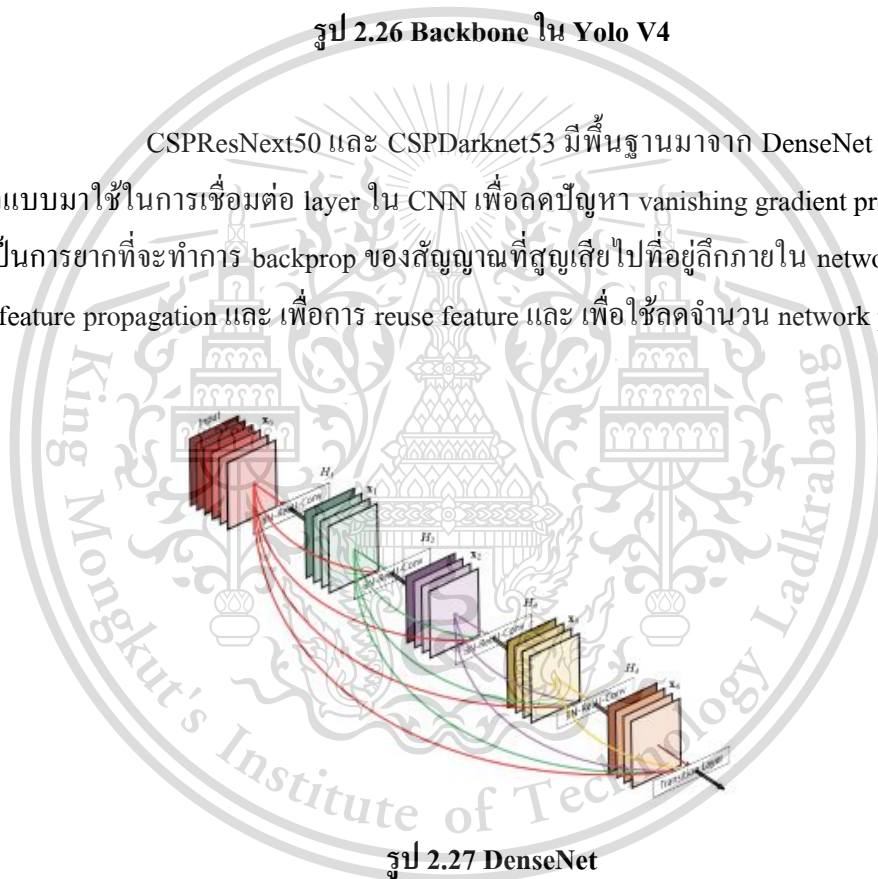
รูป แม้ว่า weight นั้นจะต้องถูกปรับให้เข้ากับวัตถุที่มันจะทำการตรวจสอบใหม่อีกครั้ง ซึ่งประกอบไปด้วย CSPResNext50, CSPDarknet53 และ EfficientNet-B3

Table 1: Parameters of neural networks for image classification.

Backbone model	Input network resolution	Receptive field size	Parameters	Average size of layer output (WxHxC)	BFLOPs (512x512 network resolution)	FPS (GPU RTX 2070)
CSPResNext50	512x512	425x425	20.6 M	1058 K	31 (15.5 FMA)	62
CSPDarknet53	512x512	725x725	27.6 M	950 K	52 (26.0 FMA)	66
EfficientNet-B3 (ours)	512x512	1311x1311	12.0 M	668 K	11 (5.5 FMA)	26


รูป 2.26 Backbone ใน Yolo V4

CSPResNext50 และ CSPDarknet53 มีพื้นฐานมาจาก DenseNet โดยที่ DenseNet ถูกออกแบบมาใช้ในการเชื่อมต่อ layer ใน CNN เพื่อลดปัญหา vanishing gradient problem (เนื่องจากมันจะเป็นการยากที่จะทำการ backprop ของสัญญาณที่สูญหายไปที่อยู่ลึกภายใน network), เพื่อส่งเสริมการทำ feature propagation และ เพื่อการ reuse feature และ เพื่อใช้ลดจำนวน network parameters




รูป 2.27 DenseNet

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.28 DenseNet

ใน CSPResNext50 และ CSPDarknet53 มี DenseNet ที่ถูกแก้ไขเพื่อแยก feature map ของแต่ละ base layer โดยการคัดลอกและส่งผ่าน dense block กับ ส่งผ่านไป next stage เลย เพื่อลดปัญหา computational bottlenecks ที่เกิดขึ้นใน DenseNet และเพิ่มประสิทธิภาพการ learning โดยส่ง feature map ที่ยังไม่ถูกแก้ไขไปด้วย

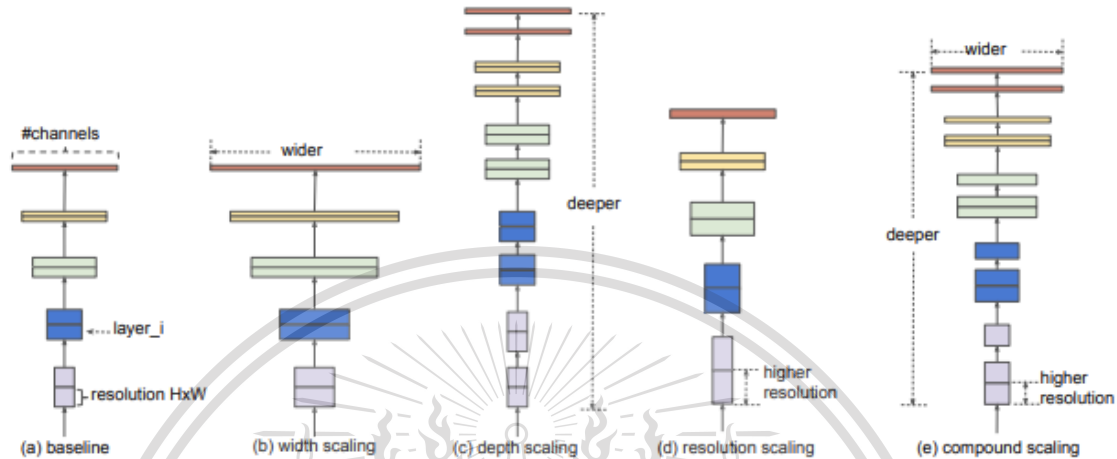


รูป 2.29 Cross Stage Partial DenseNet

EfficientNet ถูกออกแบบโดย Google Brain เพื่อศึกษาปัญหาการทำ scaling ของ CNN เพราะว่าการ scaling up ของ ConvNet สามารถแก้ไขค่า parameter ได้หลายอย่างทั้ง input size

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

, width scaling , depth scaling หรือแม้แต่เพิ่มทุกอย่างที่กล่าวมา ในงานวิจัยของ EfficientNet ระบุว่าว่า ในแต่ละค่าจะมีค่าที่เหมาะสมของการตั้งค่าทุกค่าอยู่

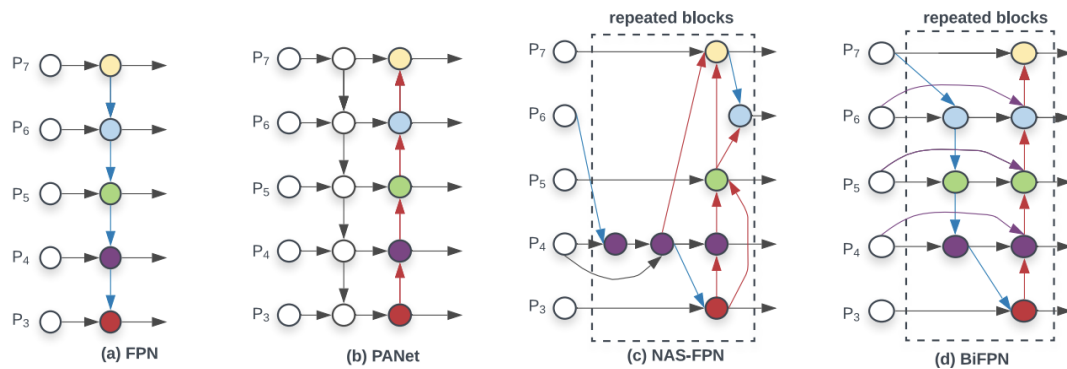


รูป 2.30 การปรับลดขนาดของ CNN

EfficientNet แสดงผลลัพธ์ที่ดีกว่า network อื่นที่มี size ที่เท่ากันในการทำการ image classification ผู้สร้าง yoloV4 ระบุว่าอย่างไรก็ตามใน network อื่นอาจจะทำงานได้ดีกว่าในการ ทำ object detection และตัดสินใจที่จะทดลองว่าจริงหรือไม่ จากการทดลองอย่างจริงจังผู้สร้างได้ เลือกลงใช้งาน CSPDarknet53 ใช้งานใน backbone network

2) YOLOV4 Neck-Feature Aggregation ทำหน้าที่ในเป็น Feature Aggregation ใน ส่วนถัดไปในการตรวจสอบวัตถุคือการ mix, combine feature ที่มาจาก ConvNet backbone เพื่อเตรียม ในขั้นตอนการทำ detection YOLOV4 ประกอบไปด้วย FPN, PAN, NAS-FPN, BiFPN, ASFF, SFAM โดยส่วนประกอบของ neck โดยทั่วไปจะไหลไปกลับใน layer และเชื่อมต่อแก่ layer จำนวนน้อย บริเวณท้ายของ convolutional network

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูป 2.31 ส่วนประกอบของ Neck


จากรูปภาพประกอบด้านบน จากตัวที่มาก่อนหน้า YOLOV4 หรือคือ EfficientDet ที่ถูกพัฒนาขึ้นโดย Google Brain โดยใช้ neural architecture search เพื่อค้นหารูปแบบที่ดีที่สุดของส่วน neck ใน network จนมาพบกับ NAS-FPN ที่เลือกที่ผู้พัฒนาเลือกจะนำมาปรับปรุงเล็กน้อย นอกจากนี้ YOLOV4 เลือก PANet ในการทำ feature aggregation ภายใน network โดยที่ผู้พัฒนาไม่ได้อธิบายเหตุผลไว้ และ NAS-FPN กับ BiFPN ยังคงถูกเขียนควบคู่กันไปจึงยังไม่นำมาพิจารณาในปัจจุบันและ yoloV4 ได้ทำการเพิ่ม SPP block หลังจาก CSPDarknet53 เพื่อเพิ่มความการรับรู้อื่นและแยกส่วน feature ที่สำคัญออกจาก backbone

3) YOLOV4 Head-The Detection Step ปรับใช้ YOLO head ตัวเดียวกันกับใน YOLOV3 ในส่วนการทำ detection ด้วยการใช้อันchor based detection ที่แบ่งเป็น 3 ระดับ detection granularity

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



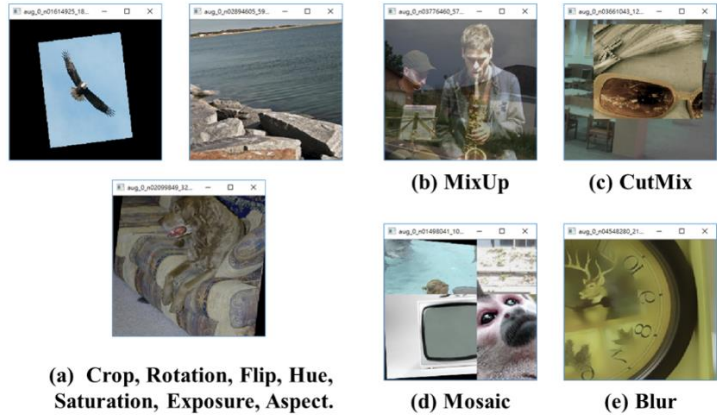
รูป 2.32 Bounding box



รูป 2.33 Dene Prediction

4) YOLOV4-Bag of Freebies มีการใช้งาน “bag of freebies” ที่ผู้พัฒนาสรุปว่า สามารถเพิ่มประสิทธิภาพโดยไม่เพิ่มเวลาในการทำงานประมวลผลโดยส่วนใหญ่จะเป็นการทำ data augmentation โดยผู้พัฒนา YOLOV4 ได้ใช้การทำ data augmentation เพื่อเพิ่มขนาด training set และทำให้ model ได้เจอกับรูปที่ทำลายต่อ model

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.34 Data Augmentation

วิธีการเหล่านี้เป็นที่แพร่หลายในวงการ computer vision และตัว model yoloV4 เป็นเครื่องยืนยันประสิทธิภาพและยังมีผลงานวิจัยใหม่ระบุว่าการทำงาน mosaic data augmentation เป็น 4 ช่องและนำรูปมารวมกันในการตรวจสอบหาวัตถุขนาดเล็กและลดการสนใจรอบข้างที่ไม่ได้อยู่ใกล้กับวัตถุ

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 Review on Infrared and Electroluminescence Imaging for PV Field Applications

ในงานวิจัยนี้จะมีเนื้อหาเกี่ยวกับการเปรียบเทียบการใช้งานภาพ IR (infrared) และ ภาพ EL (Electroluminescence) ในการตรวจสอบความผิดปกติของ แผงเซลล์สุริยะ ในการใช้งานกล้อง Infrared สามารถมองเห็นปัญหาของแผงเซลล์สุริยะหลายกรณี เช่น

1) แผงเซลล์สุริยะได้รับความเสียหายในส่วนของกระจกบนแผงซึ่งมีสาเหตุมาจากการกระทบกันของวัตถุหนักกับกระจกบนแผงเช่น ลูกเห็บ จะเห็นจากกล้อง IR ได้ว่า cell ที่เสียหาย มีอุณหภูมิสูงกว่า cell รอบข้าง

2) Hotspot ที่มีสาเหตุจากภายใน ซึ่งเกิดจากการทำจัดเรียงแผงเซลล์สุริยะที่ไม่ถูกต้อง, ไฟลัดวงจร หรือ วงจรภายในเสียหาย ทำให้แผงเซลล์สุริยะมีความร้อนมากเกินไป ซึ่งปัญหา Hotspot มักจะเกิดภายใน เซลล์สุริยะมากกว่า จะเห็นจากกล้อง IR ได้ว่าเซลล์สุริยะที่เกิด hotspot มีอุณหภูมิสูงกว่าเซลล์สุริยะรอบข้าง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) Hotspot ที่มีสาเหตุจากภายนอก ซึ่งเกิดจากบดบังของวัตถุภายนอกเช่น ชี้นก ต้นไม้ สิ่งก่อสร้าง ทำให้ cell มีในแผงมีอุณหภูมิที่แตกต่างกันมากกว่า จะเห็นจากกล้อง IR ได้ว่าเซลล์สุริยะที่เกิดเงาบังจะมีอุณหภูมิสูงกว่าเซลล์สุริยะรอบข้าง

4) Bypass Diode ซึ่งเกิดจากความผิดพลาดในการติดตั้ง Diode ใน junction box (กล่องไฟ) ทำให้ตัว Diode มีอุณหภูมิสูงกว่าตัวแผงเซลล์สุริยะจะเห็นจากกล้อง IR ได้ว่า Diode ที่อยู่ใน Junction box จะมีอุณหภูมิสูงกว่าแผงเซลล์สุริยะ


5) สายรวมไฟ DC box ร้อนเกินไปซึ่งมีสาเหตุมาจากการต่อสายไฟที่ไม่ถูกต้องหรือหลวมเกินไปจะเห็นจากกล้อง IR ได้ว่า สายไฟที่ต่อ DC box มีอุณหภูมิสูงกว่าส่วนอื่น



รูป 2.35 DC Combiner box overheated

6) PID(Potential induced degradation) เกิดจากการที่ตัวเซลล์สุริยะอยู่ใกล้กับกรอบตัวแผงทำให้เกิดความต่างศักย์ระหว่างเซลล์สุริยะ , กระจก และ กรอบตัวแผงแล้วทำให้เกิดการเคลื่อนไหวของประจุได้ ส่งผลให้เซลล์เสียหายในที่สุด และทำให้ประสิทธิภาพของทั้งแผงเซลล์สุริยะต่ำลง จะเห็นจากกล้อง IR ได้ว่าแผงเซลล์สุริยะที่เกิด PID จะมีอุณหภูมิสูงกว่าแผงเซลล์สุริยะรอบข้าง


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.36 PID from IR camera

ส่วนในการใช้งานกล้อง EL สามารถแสดงผลปัญหาเซลล์สุริยะ เช่น

- 1) Crack (รอยแตก)และ Micro-crack (รอยแตกขนาดเล็ก) เกิดจากการที่เซลล์สุริยะได้รับความเสียหาย ทั้งจากการติดตั้งที่ผิดพลาด หรือ การชนของลูกเห็บหรือสิ่งอื่น อาจส่งผลให้เซลล์สุริยะรอบข้างเกิดการ crack ตามไปด้วย และนำไปสู่ปัญหา PID ได้ จะเห็นจากกล้อง EL ได้ว่า ตัว cell มี รอยแตกร้าว
- 2) PID มีสาเหตุเหมือนกับที่เกิดกับกล้อง IR จะเห็นจากกล้อง EL ได้ว่า ตัวแผงเซลล์สุริยะที่เกิด PID มี สีที่แตกต่างจาก cell รอบๆ




รูป 2.37 PID from EL camera

- 3) Busbar corroded เกิดจากตัวนำไฟฟ้าที่ทำมาจาก ทองแดง ทองเหลือง และอะลูมิเนียม ถูกกัดกร่อน ซึ่งมีสาเหตุมาจาก ความชื้น เช่น ฝน, ละอองน้ำ จะเห็นจากกล้อง EL ได้ว่า ตัว cell มีคราบติดอยู่เป็น

แนวยาว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.38 Busbar Corroded

4) Dirty เกิดจากฝุ่น ละออง ไข่ม้วน ค้างอยู่ที่แผ่นเซลล์สุริยะจะเห็นจากกล้อง EL ได้ว่าตัวเซลล์สุริยะมีคราบติดอยู่เป็นละอองบนตัวแผง

จากผลสรุปของงานวิจัย จะทำให้เราเห็นข้อดีและข้อเสียของ การใช้กล้องแต่ละแบบ โดยจะสรุปเป็นตารางดังนี้

ตาราง 2.1 เปรียบเทียบข้อดีข้อเสียของการใช้งาน EL และ การใช้งาน IR

กล้อง Electroluminescence		กล้อง Infrared	
ข้อดี	ข้อเสีย	ข้อดี	ข้อเสีย
1. ภาพมีความละเอียดสูง	1. ไม่สามารถบอกต้นกำเนิดของปัญหาที่เกิดขึ้นได้	1. ไม่ต้องการเชื่อมต่อทางไฟฟ้ากับแผงเซลล์สุริยะ	1. บางปัญหาไม่ได้ส่งผลให้อุณหภูมิเพิ่มขึ้น
2. สามารถระบุปัญหาได้ชัดเจน	2. ยากที่จะระบุผลกระทบจากปัญหาที่มีผลต่อการทำงานของตัวเซลล์สุริยะหรือ module	2. สามารถระบุปัญหาได้ชัดเจน	2. พื้นที่ที่มีอุณหภูมิสูงไม่จำเป็นต้องเป็นจุดกำเนิดของปัญหาเสมอไป
a. รอยขีดข่วนที่เกิดจาก laser	3. ตัวกล้องต้องมีการเชื่อมต่อทางไฟฟ้ากับตัวแผงเซลล์สุริยะ	a. เห็น Thermal behavior ที่แตกต่างกันไปหลายรูปแบบ	3. ไม่สามารถระบุตำแหน่งที่เกิดปัญหาได้ชัดเจนหรือจุดความร้อนจำนวนมาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้ใช้ในเชิงพาณิชย์


ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

b. ไฟฟ้าลัดวงจร bypass diodes, Disconnected cell region, Shunts, Short circuited cells, cell cracks, layer defects และ อื่นๆ	4.ภาพ EL อาจจะใช้ ภาพ IR แทนได้ใน หลากหลายกรณี	b. Shunts, hotspots, Moisture, Shading, Mismatches, Installation Failure และ อื่นๆ	4. ไม่สามารถระบุเซลล์ สุริยะระหว่าง Low shunt และ High series resistance
--	--	--	---

2.2.2 Aerial Inspection Report

การเสื่อมสภาพของเซลล์สุริยะที่มีสาเหตุมาจากปัญหาทางอุณหภูมิจะนำไปสู่การสูญเสียพลังงาน ส่วนใหญ่การเสื่อมสภาพมักจะเกิดจากปัญหา Bypass Diode ซึ่งเราไม่สามารถที่จะตรวจสอบได้จาก I-V curves หรือ การวัดแรงดันไฟฟ้าจากวงจร ในส่วนของงานวิจัยจะพูดถึงการทดลองหาความน่าจะเป็นที่แผงเซลล์สุริยะจะเกิดปัญหาต่างๆที่นำไปสู่การเสื่อมสภาพ ในฟาร์มหนึ่ง ด้วยการถ่ายภาพ Infrared มุมสูง ที่จะทำให้เห็นความแตกต่างของความร้อนในแต่ละเซลล์สุริยะ ซึ่งทางงานวิจัยก็ได้อธิบายถึงลักษณะสาเหตุ ปัญหาต่างๆ ที่เกิดขึ้น รวมทั้งการแก้ไขอีกด้วย โดยจะแบ่งออกเป็น 5 ปัญหา คือ

1. Reverse Polarity มีสาเหตุมาจากการติดตั้ง MC4 Connector ที่ผิดพลาด สามารถตรวจสอบได้ที่ขั้วของ Module connector รวมทั้ง แรงดันไฟฟ้าและทิศทางของกระแสไฟฟ้า โดยรูปที่ปรากฏจะเห็นว่า cell ที่มีปัญหาจะมีอุณหภูมิสูงกว่า cell รอบๆ
2. Bypass Diode Active มีสาเหตุมาจากแถวของแผงเซลล์สุริยะที่อยู่ติดกับ diode ไม่ได้กักเก็บกระแสไฟฟ้าที่จำเป็น ซึ่งอาจทำให้เกิด Spot ที่ module ได้ วิธีแก้ไขให้ตรวจสอบ Diode ที่เสีย ใน MC4 connector และเปลี่ยน Diode ที่เสียนั้น โดยรูปที่ปรากฏจะเห็นว่า cell ที่มีปัญหาจะมีอุณหภูมิสูงกว่า cell รอบๆ โดยมีรูปแบบเป็นแนวตั้งยาว



รูป 2.39 Bypass Diode Active

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. Vegetation มีสาเหตุมาจากการเติบโตของต้นหญ้า หรืออบคั้งของกิ่งต้นไม้ ซึ่งเราสามารถแก้ไข ปัญหาได้ด้วยการตัดกิ่งไม้ ,ทำลายต้นหญ้าที่กำลังขึ้น หรือ ย้ายแผงเซลล์สุริยะ โดยรูปที่ปรากฏจะเห็น ได้ว่า cell มีอุณหภูมิที่แตกต่างกันไป โดยมีรูปแบบที่ไม่แน่นอน ตามกิ่งไม้ที่อบคั้งหรือ หญ้าที่ขึ้น



รูป 2.40 Vegetation

4. Hotspot ที่ไม่ร้ายแรง เกิดจาก การขึ้นของต้นหญ้า ,ดิน ,ขึ้นรก สามารถแก้ไขได้ด้วยการทำความสะอาด แผงเซลล์สุริยะ โดยรูปที่ปรากฏจะเห็นได้ว่า cell ที่ถูกอบคั้งจะมีอุณหภูมิที่สูงกว่ารอบๆ เป็นจุดๆ

5. Hotspot ที่ร้ายแรง เกิดจาก การแตกหักของ cell , รอยรอยแตก และ PID สามารถแก้ไขได้ด้วยการ เปลี่ยนแปลงเซลล์สุริยะ โดยรูปที่ปรากฏจะเห็นได้ว่า cell ที่เกิดปัญหาจะมีอุณหภูมิสูงกว่ารอบๆ เป็นจุดๆ

จากผลสรุปของงานวิจัย จะได้ค่าความน่าจะเป็นตามตารางดังนี้

ตาราง 2.2 แสดงความน่าจะเป็นของการเกิด Hotspot ในแผงเซลล์สุริยะ

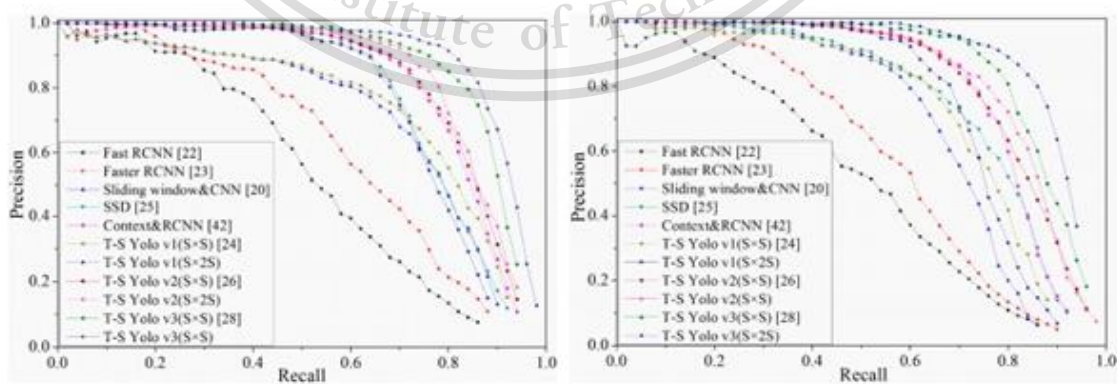
แผงเซลล์สุริยะที่ได้รับการเปรียบเทียบตามการดูแล	โอกาสในการเกิด Hotspot ในแผงเซลล์สุริยะ	คะแนน
แผงเซลล์สุริยะที่ได้รับการตรวจสอบที่ดี และมีแนวทางในการดูแล รักษา และป้องกันที่ถูกต้อง	0.0 % จนถึง 0.6%	ดี
แผงเซลล์สุริยะที่มีการตรวจสอบรายปี และมีแนวทางการบำรุงรักษาที่ถูกต้อง	0.6% ขึ้นไปจนถึง 1.0%	ปานกลาง
แผงเซลล์สุริยะที่มีการตรวจสอบเท่าที่จำเป็นและมีการดูแลรักษา ที่ผิดพลาด	มากกว่า 1.0%	แย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2.3 A Fast-Learning Method for Accurate and Robust Lane Detection Using Two-Stage Feature Extraction with YOLO v3

ในงานวิจัยนี้ทำเพื่อปรับปรุงค่าความแม่นยำของการค้นหาเลนถนนในสถานการณ์ที่ซับซ้อน โดยใช้ algorithm ในการเรียนรู้ feature เลนถนนโดยอัตโนมัติด้วย two-stage learning network พื้นฐานใน YOLOV3 โครงสร้างพารามิเตอร์ของ YOLOV3 มีการแก้ไข algorithms ทำให้เหมาะสมที่สุดกับการค้นหาเลนถนน เพื่อปรับปรุงประสิทธิภาพในการเทรน วิธีการสำหรับสร้าง Label ของเลนถนนแบบอัตโนมัติจากภาพที่ไม่ซับซ้อน โดยการนำภาพไปทำ Label สำหรับการเทรนใน first-stage network Algorithm ในการหาขอบถนนเป็นพื้นฐานใน Canny operator ซึ่งใช้เพื่อย้ายเลนถนนที่ค้นพบด้วย first-stage model นอกจากนี้เลนถนนที่ไม่ได้ทำการ Label จะไม่ไปรบกวนการเทรน โมเดลครั้งต่อไป ในขณะที่ภาพที่ทำ Label มาแล้วจะถูกใช้สำหรับการเทรนใน second-stage model การทดลองทำในชุดข้อมูล KITTI และ Caltech ผลลัพธ์จากการทดลองจะแสดงค่าความแม่นยำในการค้นหาเลนถนนและความเร็วในการค้นหาใน second stage model

ในงานนี้ใช้การประเมินด้วยค่า Mean Average Precision (mAP) และความเร็วในการค้นหาเลนถนน โดยเปรียบเทียบจาก Object detection หลายตัวประกอบด้วย Faster RCNN, SSD, YOLOV1 YOLOV2 และ YOLOV3 เป็น Keras framework พื้นฐานบน Tensorflow และ algorithm ในการเทรนของโมเดล lane detection ที่แตกต่างกันเทรนด้วยการใช้ชุดข้อมูล KITTI และ Caltech รูป 2.25 แสดงผลลัพธ์ของ Precision-recall (PR) บน Ground truth ของชุดข้อมูล KITTI และ Caltech แนวโน้มของ PR บนชุดข้อมูล 2 ชุดที่เหมือนกัน จะเห็นได้ว่า YOLO ได้ผลลัพธ์ที่ดีที่สุดในการการค้นหาเลนถนน และโมเดล S X 2S โครงสร้างพื้นฐานบน YOLOV3 ดีที่สุดในทั้ง 2 ชุดข้อมูล



รูป 2.41 แสดงผลลัพธ์ของ Precision-recall (PR) บน KITTI และ Caltech

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับกรใช้งานเพื่อการรศกษาเท่านั้น เมื่ออนุญาตเห็นไปเซบระโยชนด้านกรคำ
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่า mAP และเวลาในการค้นหาของ algorithm ทั้งหมดแสดงใน Table ด้านล่าง

Algorithm	KITTI		Caltech	
	mAP (%)	Speed (ms)	mAP (%)	Speed (ms)
Fast RCNN [25]	49.87	2271	53.13	2140
Faster RCNN [26]	58.78	122	61.73	149
Sliding window & CNN [23]	68.98	79,000	71.26	42,000
SSD [28]	75.73	29.3	77.39	25.6
Context & RCNN [45]	79.26	197	81.75	136
Yolo v1 ($S \times S$) [27]	72.21	44.7	73.92	45.2
T-S Yolo v1 ($S \times 2S$)	74.67	45.1	75.69	45.4
Yolo v2 ($S \times S$) [29]	81.64	59.1	82.81	58.5
T-S Yolo v2 ($S \times 2S$)	83.16	59.6	84.07	59.2
Yolo v3 ($S \times S$) [31]	87.42	24.8	88.44	24.3
T-S Yolo v3 ($S \times 2S$)	88.39	25.2	89.32	24.7

รูป 2.42 ตารางเปรียบเทียบ Object detection model

จากตารางจะเห็นได้ว่า Sliding window & CNN และ Context & RCNN ไม่ได้ resize ภาพเพื่อที่จะให้ภาพมีขนาดที่เท่ากันทุกภาพ ดังนั้นภาพที่มีขนาดใหญ่จะใช้เวลาในการค้นหานานกว่า algorithms ของโมเดลตัวอื่นที่ทำการ resize ขนาดภาพ Sliding window & CNN ใช้วิธีการ window sliding ในการค้นหาภาพทั้งหมดเพื่อให้ได้ตำแหน่งเลนถนนในภาพ ถึงแม้ว่าค่าความแม่นยำของ Sliding window & CNN จะสูงบน 2 ชุดข้อมูล KITTI และ Caltech แต่ใช้เวลาในการ detect นาน ในทางตรงกันข้าม Fast-RCNN ได้รับ feature map ด้วยการยัดภาพทั้งหมดไปที่ CNN สิ่งนี้ทำให้เวลาในการ detect ลดลง แต่ก็ยังช้าอยู่เนื่องจากขั้นตอนการ Selective Search ใช้สร้าง Candidate boxes เวลาในการ detect ทั้ง 2 ชุดข้อมูล KITTI และ Caltech ต้องใช้เวลาอย่างน้อย 2 วินาที Faster-RCNN มี RPN สำหรับรับ Candidate boxes ทั้งค่าความแม่นยำและเวลาที่ใช้ในการ detect ดีขึ้นอย่างมาก อย่างไรก็ตามความต้องการสำหรับการค้นหาแบบ Realtime ยังไม่เหมาะและค่าความแม่นยำยังมีค่าที่สูงไม่พอสำหรับการใช้งาน feature ที่สำคัญ ตัวอย่างเช่น Context information ของเลนถนนถูกใช้เพื่อสร้างโมเดลที่ชื่อว่า Context & RCNN ด้วยการสร้าง Network พื้นฐานบน RCNN ค่าความแม่นยำบนชุดข้อมูล KITTI และ Caltech ดีขึ้นไปถึง 79.26% และ 81.75% อย่างไรก็ตามก็ยังไม่เหมาะกับข้อมูลที่มีขนาดใหญ่

Object classification และการระบุตำแหน่งด้วย YOLO ถูกแสดงภายในหนึ่งสแตปและมีค่าความแม่นยำที่สูงในการประมวลผลแบบ Realtime

SSD มีโอเคียมาจาก End-to-End ใน YOLO และ Mechanism ของ anchor boxes ใน Faster-RCNN ดังนั้นค่าความแม่นยำและความเร็วในการค้นหาเลนถนนจะเพิ่มขึ้นอย่างมาก ค่าเฉลี่ยของเวลาที่

เอกสารนี้เป็นเอกสารสิทธิ์สงวนลิขสิทธิ์ไว้เพื่อใช้ในการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

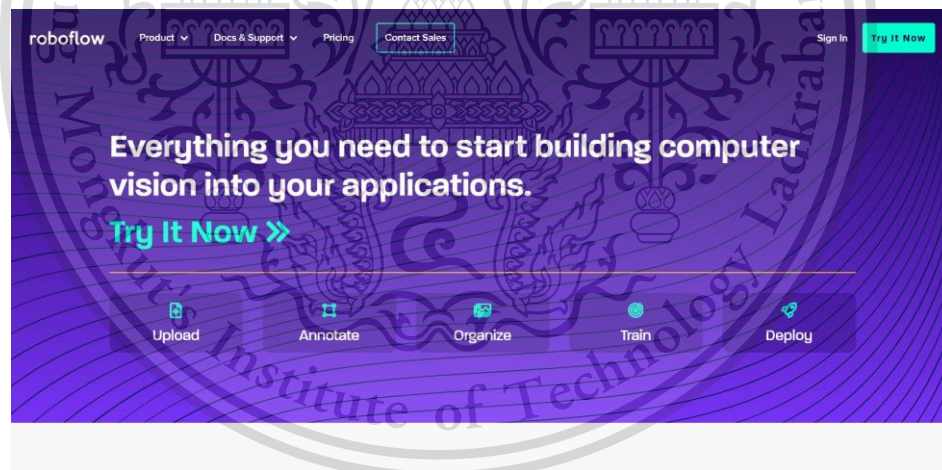
ใช้ในการประมวลผลภาพบนชุดข้อมูล KITTI และ Caltech เป็น 29.3 และ 25.6 มิลลิวินาที นอกจากนี้ YOLOV2 เพิ่ม anchor boxes เป็นพื้นฐานของ YOLO และค้นหาอัตราโนมิติสำหรับมิติที่ดีที่สุดด้วยการใช้ K-means clustering ดังนั้นค่าความแม่นยำจึงถูกปรับให้ดีขึ้น YOLOV3 ใช้ Darknet 53 เป็นพื้นฐานของ Darknet 19 ดังนั้นความสามารถในการหา feature จึงเพิ่มขึ้นด้วยการปรับแก้ function ที่ไม่จำเป็นและเพิ่มจำนวน anchor boxes ความสามารถของ YOLOV3 จึงดีขึ้น

จะเห็นได้ว่าค่า mAP ของ YOLOV3 ทั้ง 2 ชุดข้อมูล KITTI และ Caltech เท่ากับ 88.39% , 89.32% และใช้เวลาเพียง 25.2 และ 24.7 มิลลิวินาทีแสดงให้เห็นว่าการเปรียบเทียบโมเดลที่ใช้ในการเทรนแต่ละตัวในงานวิจัยชิ้นนี้ง่ายในการประมวลผลและมีผลลัพธ์ที่น่าเชื่อถือ

2.3 เครื่องมือที่ใช้ในการทดลอง

2.3.1 Roboflow website

สำหรับจัดการ, เตรียมการและปรับปรุงรูปภาพของเราและทำ Annotation training data สร้าง computer vision model คุณภาพสูงของชุดข้อมูลได้อย่างรวดเร็ว และสนับสนุนการทำ Object detection และ Classification




รูป 2.43 Roboflow website

2.3.2 Figma

Figma เป็นเครื่องมือแก้ไขกราฟิกแบบและเครื่องมือสร้างต้นแบบซึ่งส่วนใหญ่ทำงานบนเว็บพร้อมคุณสมบัติออฟไลน์เพิ่มเติมที่เปิดตัวใช้งาน โดยแอปพลิเคชันเดสก์ท็อปสำหรับ macOS และ

Windows แอปคู่หู Figma Mirror สำหรับ Android และ iOS อนุญาตให้คุณต้นแบบ Figma บนอุปกรณ์มือถือ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่บนสื่อออนไลน์ ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ถือ Feature ของ Figma มุ่งเน้นไปที่การใช้งานในส่วนติดต่อกับผู้ใช้งานและ User experience โดยเน้นการทำงานร่วมกันแบบเรียลไทม์



รูป 2.44 Figma

2.3.3 Bootstrap

Bootstrap เป็นเฟรมเวิร์ก CSS แบบ โอเพนซอร์สที่ให้บริการฟรีซึ่งมุ่งเน้นไปที่การพัฒนาเว็บส่วนหน้าแบบตอบสนองสำหรับอุปกรณ์เคลื่อนที่เป็นอันดับแรก ประกอบด้วยเทมเพลตการออกแบบที่ใช้ CSS และ JavaScript สำหรับการพิมพ์ฟอร์มปุ่มการนำทางและส่วนประกอบอินเทอร์เฟซอื่นๆ



รูป 2.45 Bootstrap

2.3.4 MongoDB


MongoDB เป็นโปรแกรมฐานข้อมูลที่มุ่งเน้นเอกสารข้ามแพลตฟอร์ม MongoDB จัดอยู่ในประเภทโปรแกรมฐานข้อมูล NoSQL โดยใช้เอกสารที่มีลักษณะคล้าย JSON พร้อมด้วยแบบแผนช่วยเสริม MongoDB พัฒนาโดย MongoDB Inc. และได้รับอนุญาตภายใต้ Server Side Public License เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 2.46 MongoDB

2.3.5 ReactJS

React เป็น User Interface (UI) library ของ JavaScript ใช้เป็นเครื่องมือสำหรับสร้าง UI components ที่กำลังได้รับความนิยม บางทีก็เรียกว่า React.js หรือ ReactJS React เป็น Open-source library ที่สร้างโดย Jordan Walke วิศวกรของ Facebook ในปี 2011 เขาได้สร้าง FaxJS ซึ่งเป็น prototype แรกของ React ต่อมาในปี 2012 Facebook Ads เริ่มจัดการยากขึ้น ดังนั้น Facebook จึงต้องการหาวิธีแก้ปัญหาที่ดี Jordan Walke จึงพัฒนาตัว prototype ต่อจนกลายเป็น React ในที่สุด และได้เปิดเป็น Open-source ในปี 2013 จากนั้น React ก็ได้รับการพัฒนาเรื่อยมาจนถึงปัจจุบัน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อรูป 2.47 React JS ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.6 FastAPI

เป็น Framework สำหรับการสร้าง API เขียนด้วยภาษา Python โดยมี uvicorn เป็นตัวจัดการ run server และด้วยความที่ใช้ uvicorn ที่เป็น ASGI(Asynchronous Server Gateway Interface) ทำให้รองรับการทำงานแบบ Asynchronous โดย FastAPI มีคุณสมบัติที่น่าสนใจดังนี้

- 1.เป็น MIT License
- 2.รองรับการสร้าง API หลากหลายรูปแบบ แคมรองรับ OAuth2 ด้วย
- 3.มีระบบสร้างเอกสาร API แบบอัตโนมัติ ที่สามารถทดลอง API ได้ผ่านหน้าเว็บเอกสาร
- 4.API เข้ากันได้กับ OpenAPI และ JSON Schema

2.3.7 Uvicorn

Uvicorn คือ lightning-fast ASGI server implementation โดยใช้ uvloop และ httptools.Until ในการทำงาน เมื่อไม่นานมานี้ ภาษา Python ยังไม่มี server ระดับต่ำขนาดเล็ก และ ส่วนติดต่อกับ application ใน asynchronous frameworks ซึ่ง The ASGI จะมาแก้ปัญหาในจุดนี้ นั่นหมายความว่า เราสามารถสร้างเครื่องมือที่ใช้ใน asynchronous frameworks ได้แล้ว นอกจากนี้ ASGI ทำให้ระบบการจัดการใน Python web frameworks มีประสิทธิภาพเทียบเท่า Node และ Go รวมทั้งมันยังสนับสนุนทั้ง HTTP/2 และ WebSockets ปัจจุบัน WSGI.Uvicorn สนับสนุน HTTP/1.1 และ WebSockets ซึ่งในอนาคตจะสนับสนุน HTTP/2

2.3.8 Multipart

Multipart ต้องการรวม data หลายตัวเข้าด้วยกันใน single body โดยแบ่งด้วยขอบเขต ซึ่งคุณสามารถใช้ request นี้ในการอัปโหลดไฟล์ และ ขนส่ง data หลายประเภทในแต่ละ request ยกตัวอย่างเช่น file ที่ประกอบไปด้วย JSON

2.3.9 React-to-print

React-to-print เป็น Library ที่ใช้ใน platform Reactjs เพื่อ แสดงเนื้อหาใน website ออกมาในรูปแบบ PDF ซึ่งสามารถที่จะแก้ไขการแสดงผลได้หลากหลายโดยใช้ component ใน library นี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.10 Axios

Axios คือ open-source JavaScript library สำหรับ http request เรียบง่ายๆ ก็คือ ตัวที่ใช้สำหรับเชื่อมต่อกับ API Service เพื่อการรับส่งข้อมูลแบบ RESTful API โดยที่เจ้า axios จะทำหน้าที่เป็นตัวกลางในการจัดการทั้ง method, data, headers, security และอื่นๆ ที่เกี่ยวข้องกับการรับส่งข้อมูล ความเจ๋งของ axios ก็คือรองรับ Promises async/await ได้ และยังรองรับ TypeScript อีกด้วย



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 8) ระบบต้องแสดง ชื่อไฟล์ ขนาดไฟล์ ในหน้าที่ทำการเลือกรูปภาพ
- 9) ระบบต้องมีคำแนะนำการเลือกรูปภาพสำหรับผู้ใช้
- 10) ระบบต้องมีการแจ้งเตือนผู้ใช้เมื่อผู้ใช้นำเข้ารูปภาพที่ไม่ตรงกับคำแนะนำ
- 11) ผู้ใช้สามารถนำเข้ารูปภาพที่มีนามสกุล JPEG, PNG, TIF เท่านั้น
- 12) ผู้ใช้ต้องสามารถเลือกที่จะแสดงชนิดปัญหาของเซลล์สุริยะและแผงเซลล์สุริยะได้ตามใจชอบ
- 13) ผู้ใช้ต้องสามารถดูรายละเอียดรูปแบบของปัญหาเซลล์สุริยะได้
- 14) ผู้ใช้ต้องสามารถนำเข้ารูปภาพพร้อมกันหลายรูปได้
- 15) ผู้ใช้ต้องสามารถตรวจสอบรูปภาพก่อนการประมวลผลได้
- 16) ผู้ใช้ต้องสามารถลบรูปภาพที่เลือกไว้ก่อนได้
- 17) ผู้ใช้ต้องสามารถกลับไปหน้าเลือกรูปภาพเพื่อเพิ่มและลบรูปภาพในการประมวลผลได้
- 18) ผู้ใช้ต้องสามารถตรวจสอบ report ก่อนที่จะ download ได้
- 19) ผู้ใช้สามารถเปลี่ยนรูปภาพที่จะแสดงผลในหน้าแสดงผลปัญหาเซลล์สุริยะ

3.2.2 Non-Functional Requirement

- 1) ระบบต้องสามารถประมวลผลเสร็จสิ้นภายในเวลาไม่เกิน 30 วินาทีในแต่ละรูป
- 2) ระบบต้องสามารถแสดงผลได้อย่างเข้าใจง่าย
- 3) ระบบต้องสามารถ นำเข้ารูปภาพ 100 รูป โดยประสิทธิภาพการทำงานของระบบคงที่

3.3 User Story ของระบบ

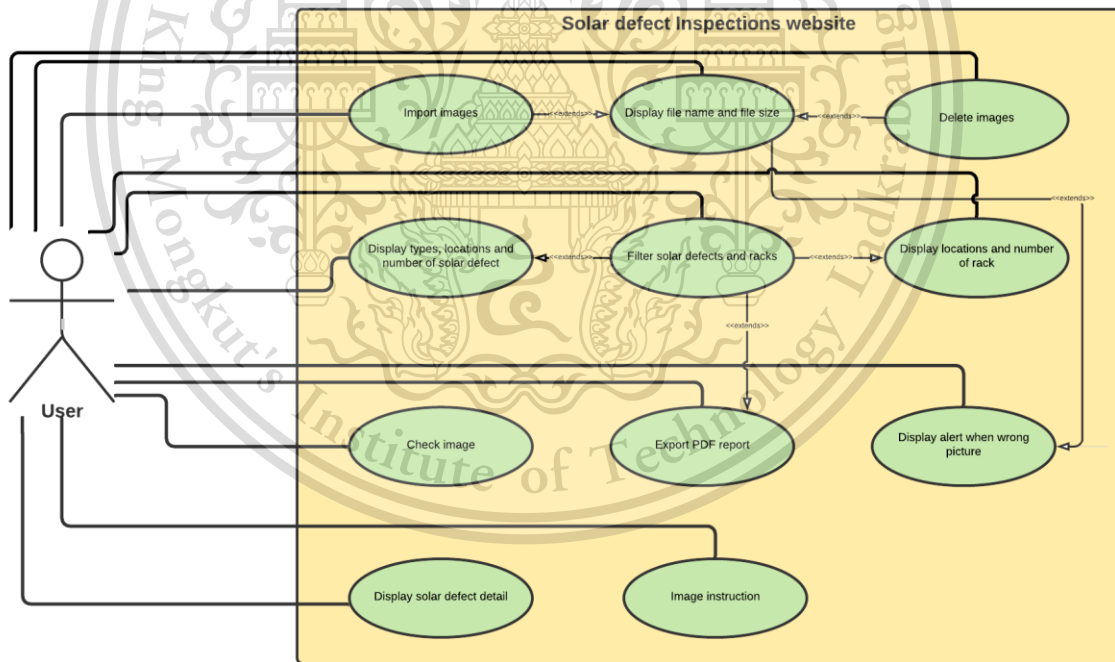
- 1) ในฐานะผู้ใช้ ฉันต้องการตรวจจับเซลล์สุริยะที่มีปัญหา เพื่อที่จะสามารถดูแลและซ่อมบำรุงได้อย่างทันทั่วทั้งที่
- 2) ในฐานะผู้ใช้ ฉันต้องการรู้ประเภทชนิดปัญหาของเซลล์สุริยะ เพื่อที่จะเตรียมอุปกรณ์ซ่อมบำรุงได้อย่างถูกต้อง
- 3) ในฐานะผู้ใช้ ฉันต้องการรู้ตำแหน่งของเซลล์สุริยะที่มีปัญหาและแผงเซลล์สุริยะ เพื่อที่จะประหยัดเวลาในการค้นหาเซลล์สุริยะที่มีปัญหาและแผงเซลล์สุริยะ
- 4) ในฐานะผู้ใช้ ฉันต้องการให้รูปภาพที่เคยประมวลผลแล้วไม่ต้องประมวลผลซ้ำ เพื่อที่จะประหยัดเวลาในประมวลผล
- 5) ในฐานะผู้ใช้ ฉันต้องการตรวจสอบรูปภาพก่อนการประมวล เพื่อที่จะป้องกันการเลือกรูปภาพ

ผิด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 6) ในฐานะผู้ใช้ ฉันต้องการลบรูปภาพที่ไม่ใช้ก่อนการประมวลผล หรือหลังจากประมวลผล เพื่อที่จะลดระยะเวลาในการประมวลผล หรือนำรูปที่ไม่ต้องการออก
- 7) ในฐานะผู้ใช้ ฉันต้องการที่จะ export report ออกมาเป็นไฟล์ PDF เพื่อที่จะสามารถตรวจสอบปัญหาเซลล์สุริยะย้อนหลังได้แบบ offline
- 8) ในฐานะผู้ใช้ ฉันต้องการทราบรายละเอียดและรูปแบบของปัญหาเซลล์สุริยะ เพื่อที่จะเห็นตัวอย่างของปัญหาเซลล์สุริยะก่อน
- 9) ในฐานะของผู้ใช้ ฉันต้องการทราบคำแนะนำรูปภาพ เพื่อที่จะเห็นตัวอย่างรูปภาพที่ใช้ในการนำเข้า
- 10) ในฐานะผู้ใช้ ฉันต้องการนำเข้ารูปภาพพร้อมกันหลายรูป เพื่อที่จะลดระยะเวลาในการตรวจสอบปัญหาเซลล์สุริยะ

3.4 Use Case Diagram



รูป 3.2 Use Case diagram ของระบบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูป Use Case diagram สามารถแสดงรายละเอียดได้ดังนี้

ตาราง 3.1 Use Case ที่ 1 (Display types, locations and numbers of solar defect)

Use Case no.	1
Use Case Name	Display types, locations, and numbers of solar defect
Actors	ผู้ใช้งาน
Pre-Condition	ผู้ใช้เข้ามาที่หน้าแสดงผลปัญหาเซลล์สุริยะ
Post-Condition	-
Brief Description	ส่วนของการแสดงผลประเภท ตำแหน่งและจำนวนปัญหาเซลล์สุริยะที่ต้องการ

ตาราง 3.2 Use Case ที่ 2 (Filter solar defect and racks)

Use Case no.	2
Use Case Name	Filter solar defect and racks
Actors	ผู้ใช้งาน
Pre-Condition	ระบบแสดงผลหน้าปัญหาเซลล์สุริยะ
Post-Condition	ระบบแสดงผลปัญหาเซลล์สุริยะและแผงเซลล์สุริยะที่เปลี่ยนไป
Brief Description	ส่วนของผู้ใช้งานที่ต้องการปรับการแสดงผลปัญหาเซลล์สุริยะและแผงเซลล์สุริยะ

ตาราง 3.3 Use Case ที่ 3 (Display locations and numbers of rack)

Use Case no.	3
Use Case Name	Display locations and numbers of rack
Actors	ผู้ใช้งาน
Pre-Condition	ผู้ใช้เข้ามาที่หน้าแสดงผลปัญหาเซลล์สุริยะ

Post-Condition	-
Brief Description	ส่วนของการแสดงผลตำแหน่งและจำนวนแผงเซลล์สุริยะที่ต้องการ

ตาราง 3.4 Use Case ที่ 4 (Check image)

Use Case no.	4
Use Case Name	Check image
Actors	ผู้ใช้งาน
Pre-Condition	ผู้คลิกที่ card
Post-Condition	-
Brief Description	ส่วนของการแสดงรูปภาพที่เลือกไว้

ตาราง 3.5 Use Case ที่ 5 (Import images)

Use Case no.	5
Use Case Name	Import images
Actors	ผู้ใช้งาน
Pre-Condition	ผู้ใช้ คลิก/ลาก/วางรูปภาพ
Post-Condition	ระบบแสดง card รูปภาพขึ้นมา
Brief Description	ส่วนของผู้ใช้งานที่ต้องการนำรูปภาพเข้าสู่ระบบ

ตาราง 3.6 Use Case ที่ 6 (Display file name and file size)

Use Case no.	6
Use Case Name	Display file name and file size
Actors	ผู้ใช้งาน
Pre-Condition	ผู้ใช้นำรูปภาพเข้าสู่ระบบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Post-Condition	-
Brief Description	ส่วนของผู้ใช้งานที่ต้องการรู้ชื่อไฟล์และขนาดไฟล์

ตาราง 3.7 Use Case ที่ 7 (Delete images)

Use Case no.	7
Use Case Name	Delete images
Actors	ผู้ใช้งาน
Pre-Condition	ระบบแสดงรายชื่อรูปภาพ ขนาดไฟล์ และนามสกุล
Post-Condition	ระบบแสดงรายชื่อรูปภาพ ที่เหลืออยู่
Brief Description	ส่วนของผู้ใช้งานที่ต้องการลบไฟล์รูปภาพที่อยู่ในระบบ

ตาราง 3.8 Use Case ที่ 8 (Export PDF report)

Use Case no.	8
Use Case Name	Export PDF report
Actors	ผู้ใช้งาน
Pre-Condition	ระบบแสดงผลปัญหาเซลล์สุริยะและแผงเซลล์สุริยะ
Post-Condition	แสดงตัวอย่างไฟล์รายงานพร้อมปุ่มดาวน์โหลด
Brief Description	ส่วนของผู้ใช้งานที่ต้องการไฟล์รายงานผลการวิเคราะห์

ตาราง 3.9 Use Case ที่ 9 (Display solar defect detail)

Use Case no.	9
Use Case Name	Display solar defect detail
Actors	ผู้ใช้งาน
Pre-Condition	ระบบแสดงผลปัญหาเซลล์สุริยะและแผงเซลล์สุริยะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Post-Condition	แสดงตัวอย่างรายละเอียดและรูปแบบของปัญหาเซลล์สุริยะ
Brief Description	ส่วนของผู้ใช้งานที่ต้องการตัวอย่างปัญหาเซลล์สุริยะ

ตาราง 3.10 Use Case ที่ 10 (Display alert when wrong picture)

Use Case no.	10
Use Case Name	Display alert when wrong picture
Actors	ผู้ใช้งาน
Pre-Condition	ระบบประมวลผลรูปภาพ
Post-Condition	ระบบแสดงหน้าแสดงปัญหาเซลล์สุริยะ
Brief Description	ส่วนของระบบที่ไม่ต้องการให้ผู้ใช้งานภาพที่ไม่เกี่ยวข้องเข้ามา

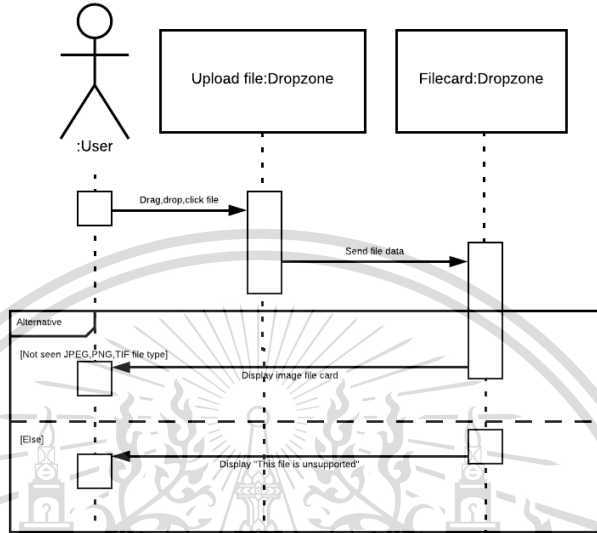
ตาราง 3.11 Use Case ที่ 11 (Image instruction)

Use Case no.	11
Use Case Name	Image instruction
Actors	ผู้ใช้งาน
Pre-Condition	ระบบแสดงหน้านำเข้ารูปภาพ
Post-Condition	-
Brief Description	ส่วนของระบบที่ต้องการให้ผู้ใช้งานภาพที่ตรงตามความต้องการของระบบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

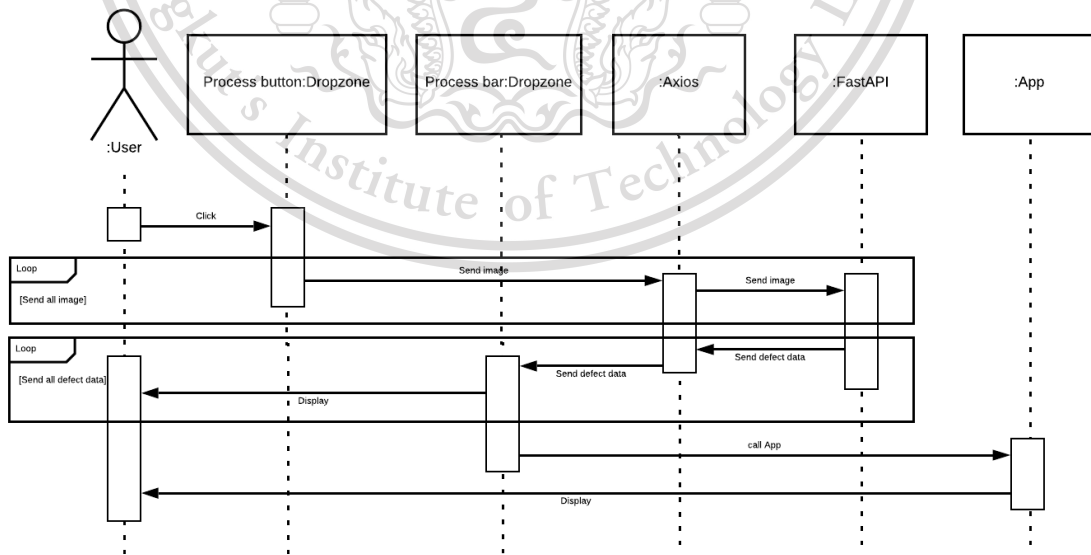
3.5 Sequence Diagram

3.5.1. ผู้ใช้นำเข้ารูปภาพ



รูป 3.3 Sequence Diagram ผู้ใช้นำเข้ารูปภาพ

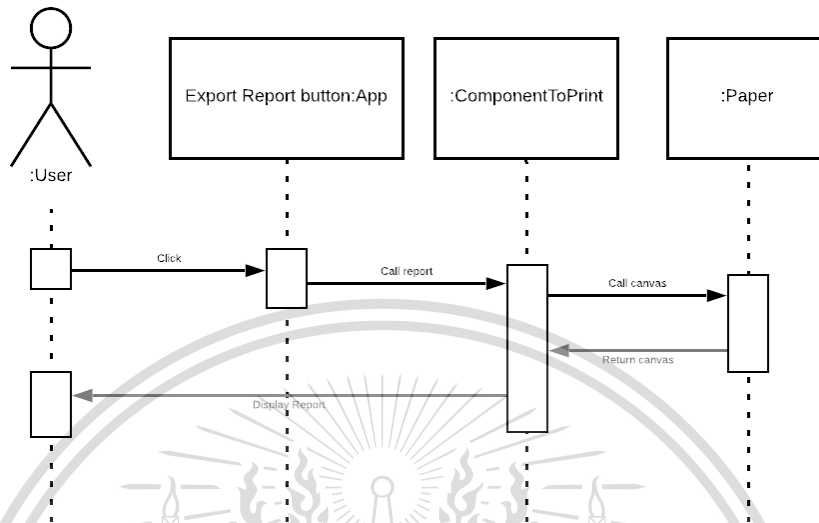
3.5.2. ผู้ใช้ทำการประมวลผลรูปภาพที่เลือกไว้



รูป 3.4 Sequence Diagram ผู้ใช้ทำการประมวลผลรูปภาพที่เลือกไว้

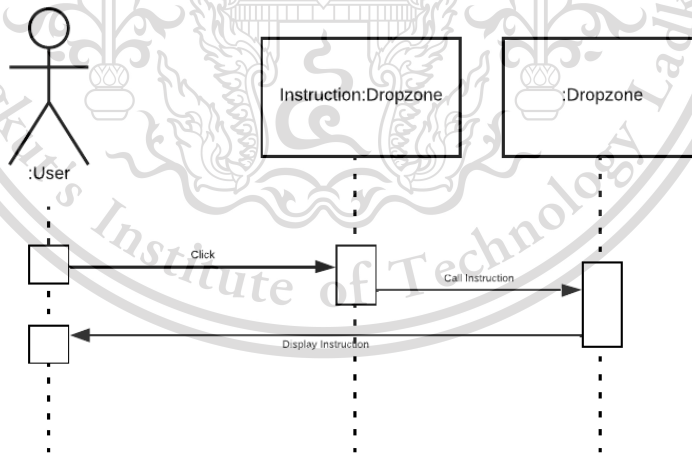
เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ ห้ามมิให้ผู้อื่นนำเอกสารนี้ไปเผยแพร่โดยไม่ได้รับอนุญาตจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5.3. ผู้ใช้ทำการ export รายงาน



รูป 3.5 Sequence Diagram ผู้ใช้ทำการ download รายงาน

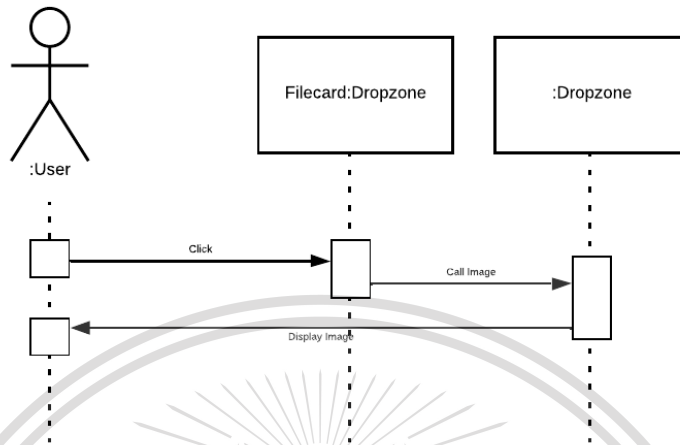
3.5.4. ผู้ใช้ทำการใช้คำแนะนำรูปภาพ



รูป 3.6 Sequence Diagram ผู้ใช้ทำการใช้คำแนะนำรูปภาพ

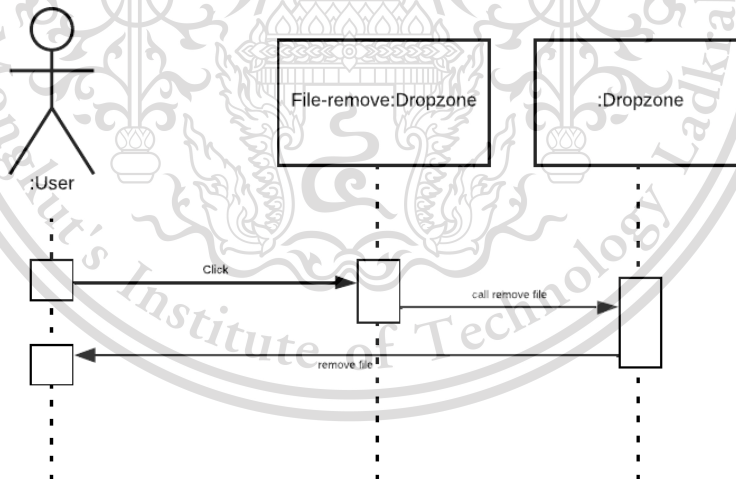
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5.5. ผู้ใช้ทำการตรวจสอบรูปภาพก่อนการประมวลผล



รูป 3.7 Sequence Diagram ผู้ใช้ทำการตรวจสอบรูปภาพก่อนการประมวลผล


3.5.6. ผู้ใช้ทำการลบรูปภาพที่เลือกไว้



รูป 3.8 Sequence Diagram ผู้ใช้ทำการลบรูปภาพที่เลือกไว้

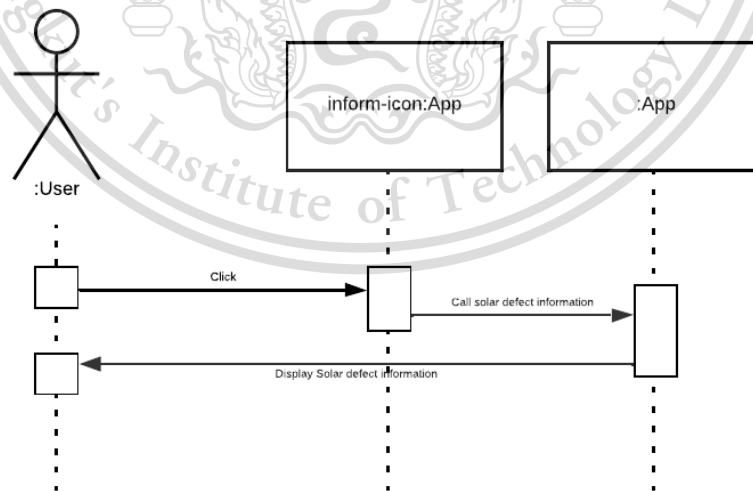
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5.7. ผู้ใช้ทำการเปิด/ปิด Solar defect/Rack filter button



รูป 3.9 Sequence Diagram ผู้ใช้ทำการลบรูปภาพที่เลือกไว้

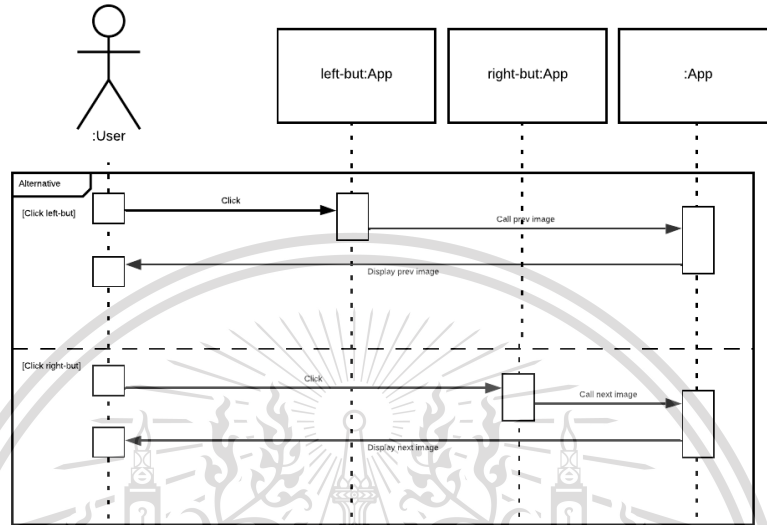
3.5.8. ผู้ใช้ทำการตรวจสอบรายละเอียดรูปแบบปัญหาเซลล์สุริยะ



รูป 3.10 Sequence Diagram ผู้ใช้ทำการตรวจสอบรายละเอียดรูปแบบปัญหาเซลล์สุริยะ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5.9. ผู้ใช้ทำการเปลี่ยนรูปภาพที่แสดงผลในหน้าแสดงผลปัญหาเซลล์สุริยะ



รูป 3.11 Sequence Diagram ผู้ใช้ทำการตรวจสอบรายละเอียดรูปแบบปัญหาเซลล์สุริยะ

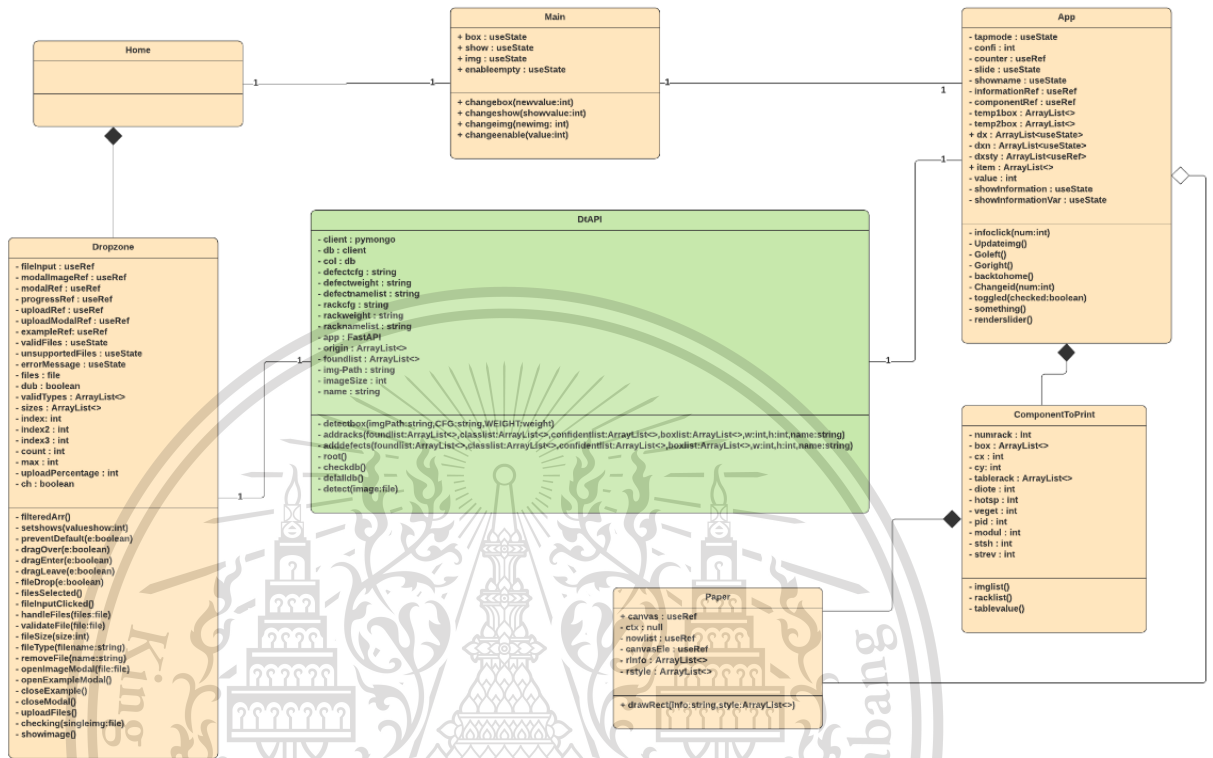
3.5.10. ผู้ใช้ทำการย้อนกลับจากหน้าแสดงผลปัญหาเซลล์สุริยะไปหน้านำเข้าสู่รูปภาพ



รูป 3.12 Sequence Diagram ผู้ใช้ทำการย้อนกลับจากหน้าแสดงผลปัญหาเซลล์สุริยะไปหน้านำเข้าสู่รูปภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

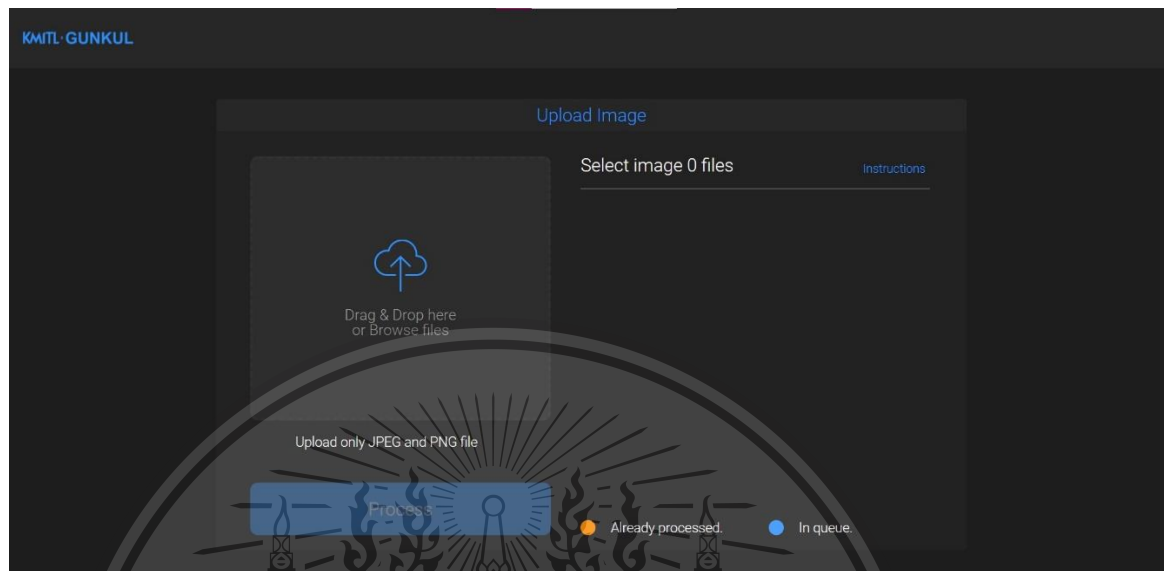
3.6 Class Diagram



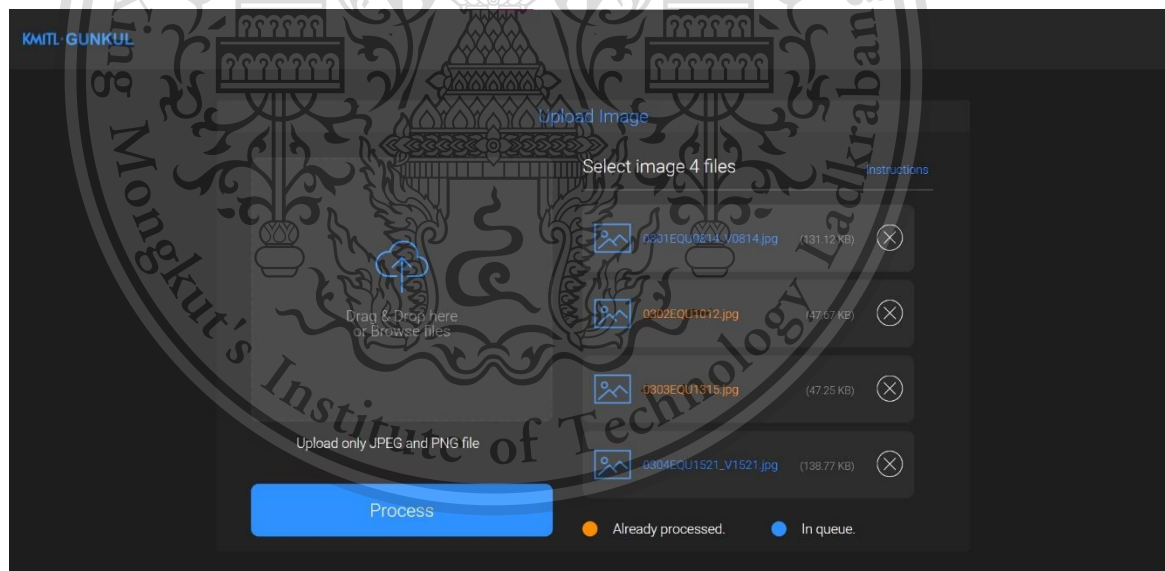
รูป 3.13 Class Diagram ของระบบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.7 User Interface Design

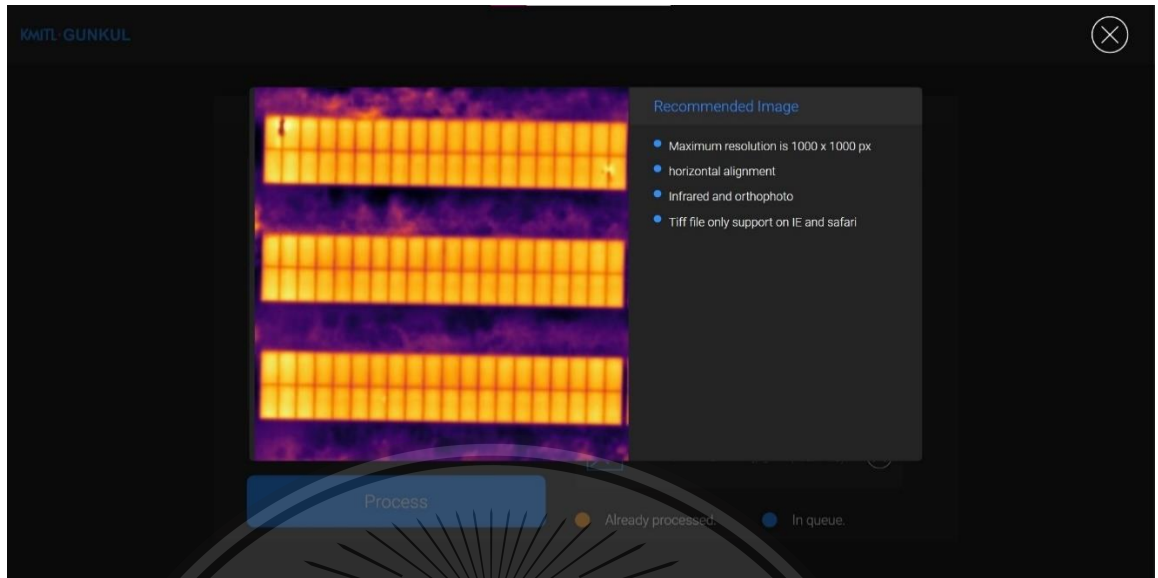


รูป 3.14 การออกแบบหน้านำเข้ารูปภาพ

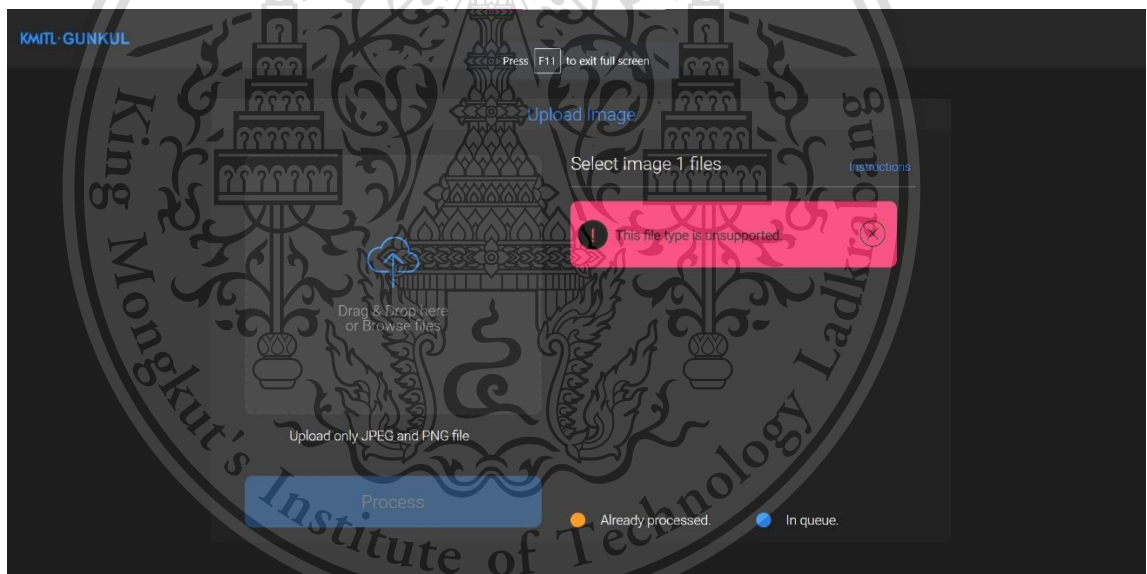


รูป 3.15 การออกแบบ หลังจากผู้ใช้นำเข้ารูปภาพพร้อมกันหลายรูป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

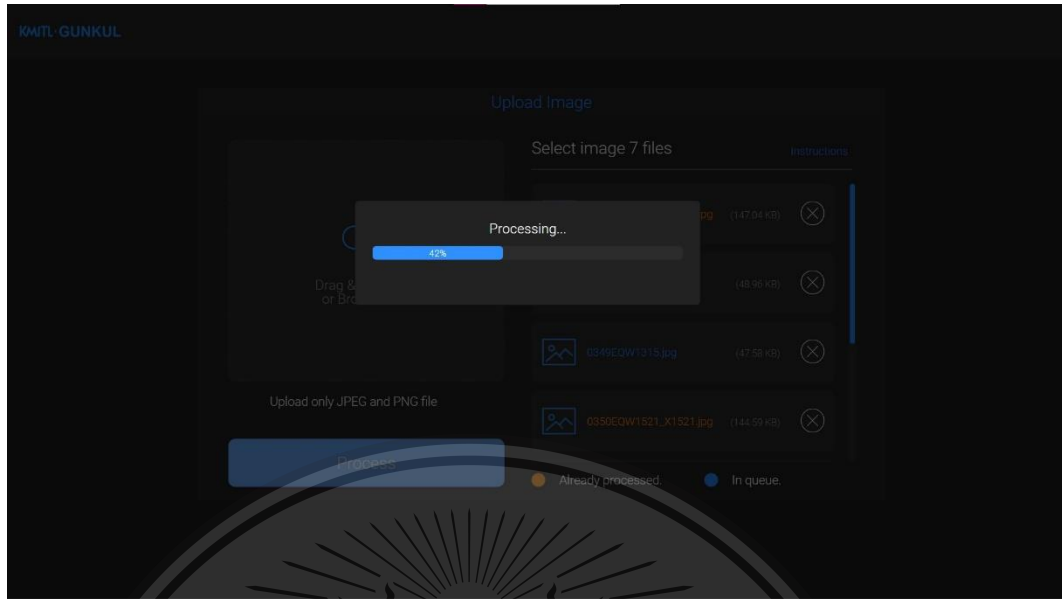


รูป 3.16 การออกแบบหน้าแสดงคำแนะนำการเลือกรูปภาพสำหรับผู้ใช้

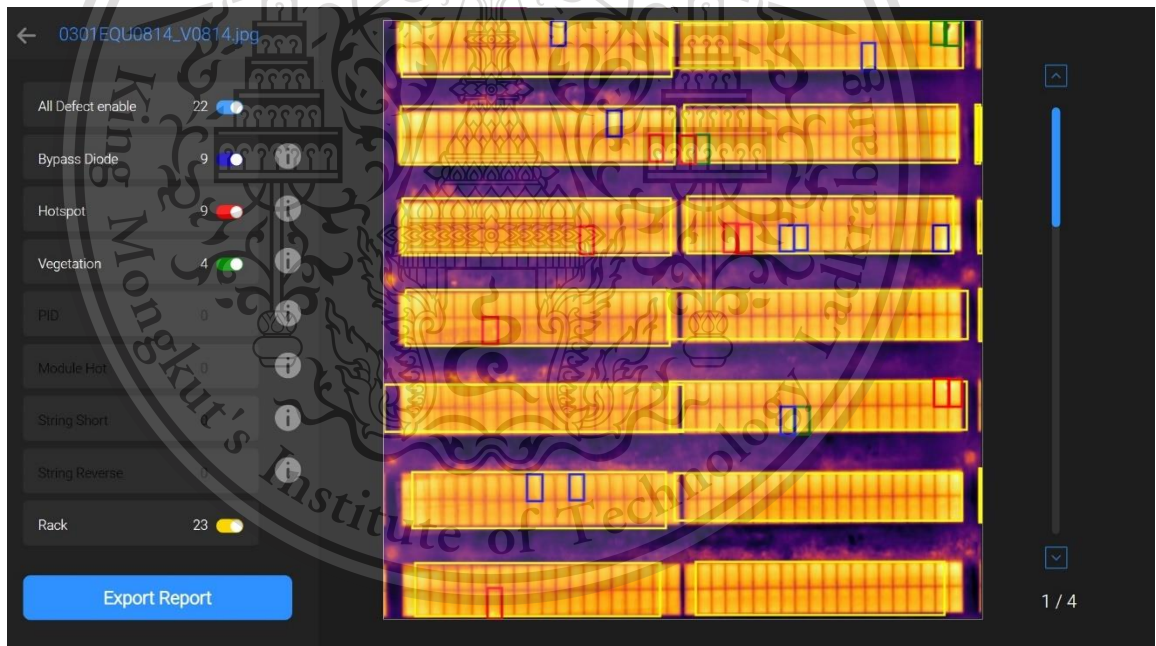


รูป 3.17 การออกแบบ หลังจากผู้ใช้นำเข้าไฟล์ที่ไม่ได้มีนามสกุล JPEG, PNG, TIF

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

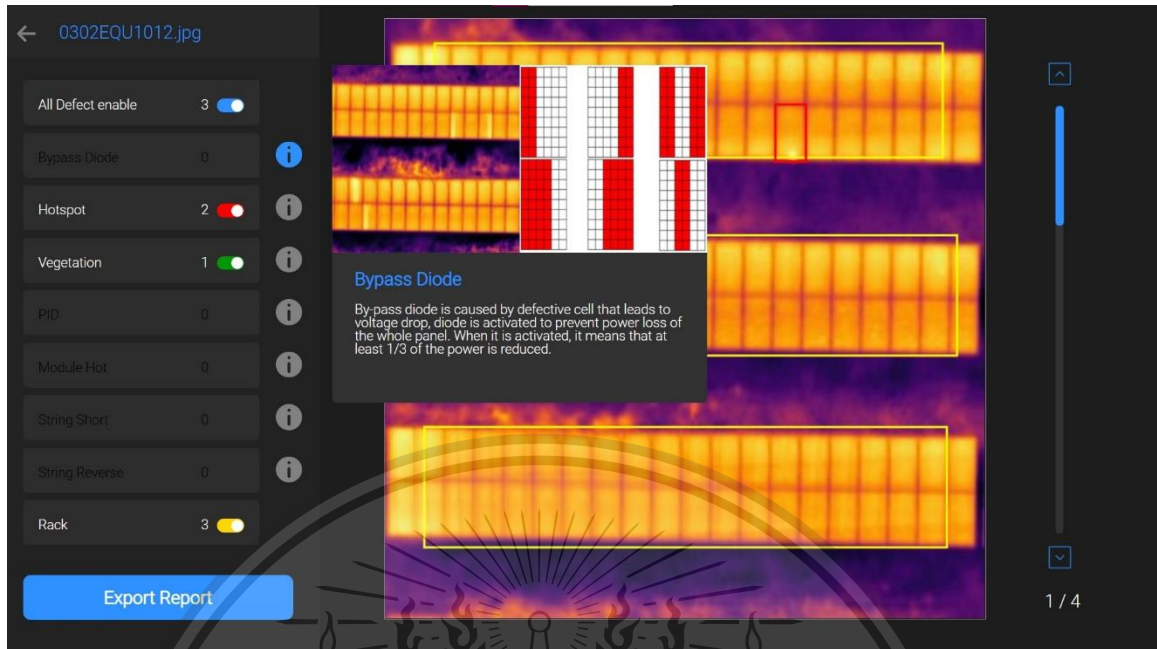


รูป 3.18 การออกแบบ progress bar ในช่วงการประมวลผล

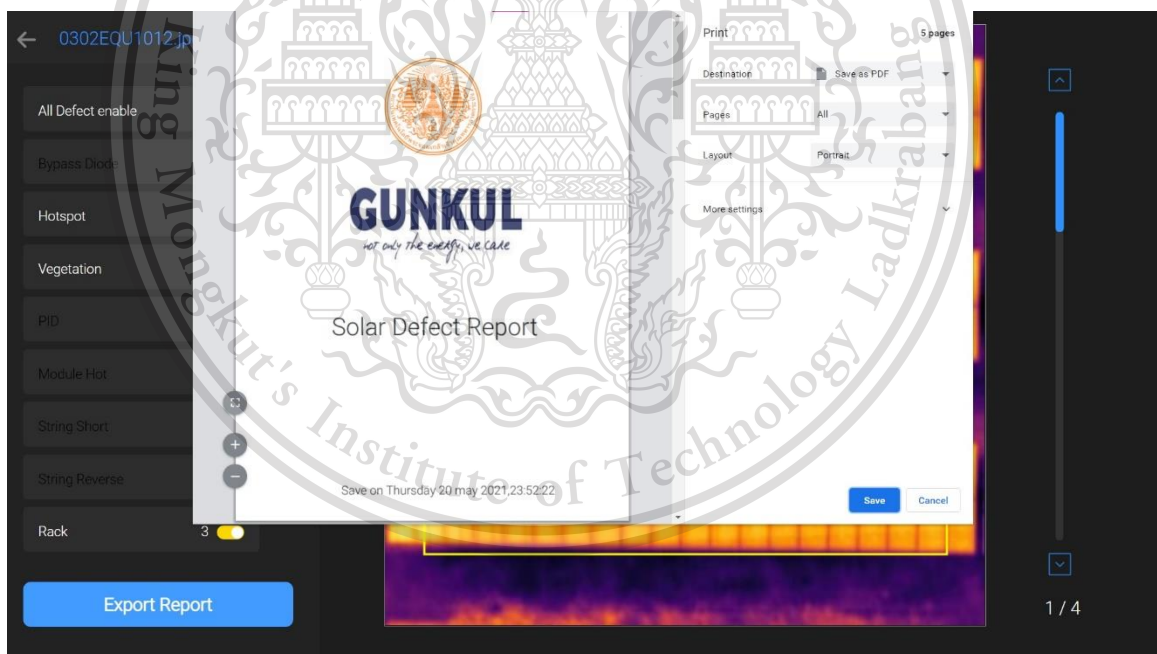


รูป 3.19 การออกแบบหน้าแสดงผล ตำแหน่งและประเภทปัญหาของเซลล์สุริยะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 3.20 การออกแบบ หน้าแสดงผลรายละเอียดรูปแบบปัญหาเซลล์สุริยะ



รูป 3.21 การออกแบบ หน้าแสดงตัวอย่าง report ก่อน download

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.8 ขั้นตอนและวิธีการจัดเตรียมชุดข้อมูล

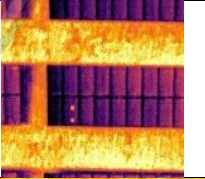
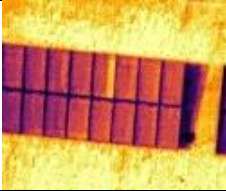

- 1) ได้ภาพ infrared ฟาร์มเซลล์สุริยะที่ผ่านกระบวนการ Orthomosaic มาจากบริษัท
- 2) เลือกฟาร์มเซลล์สุริยะ 4 ฟาร์ม จากทั้งหมด 13 ฟาร์ม เพราะทั้ง 4 ฟาร์มนี้รวมกันมีปริมาณปัญหาครอบคลุมเมื่อเทียบกับฟาร์มทั้งหมด
- 3) แบ่งย่อภาพแต่ละฟาร์มเป็นสี่เหลี่ยมจัตุรัสขนาดเล็กเพื่อใช้ในการ Training ใน Google colab website โดยแบ่งจำนวนรูปภาพในการ train : test เป็น 80 : 20

ตาราง 3.12 การแบ่ง dataset ออกเป็นส่วน train และ test


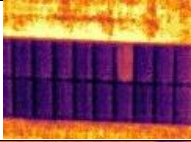
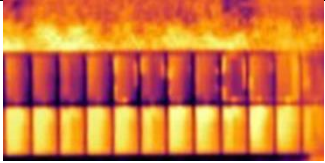
ฟาร์มที่	จำนวนรูปภาพที่ใช้ในการ train	จำนวนรูปที่ใช้ในการ test	รวม
1	191	56	247
2	47	15	62
3	79	23	102
4	81	22	103


3.9 การแยกประเภทปัญหาเซลล์สุริยะ

ตาราง 3.13 การแยกปัญหาเซลล์สุริยะ

ชื่อปัญหาเซลล์สุริยะ	ลักษณะ	ตัวอย่าง
Hotspot	มีจุดที่มีอุณหภูมิสูงกว่าบริเวณรอบข้างไม่มากกว่า 5 จุด	
Bypass Diode	มีเซลล์สุริยะเสียในแนวตั้งทั้งแนว 1 แนวขึ้นไป	
Vegetation	มีจุดที่อุณหภูมิต่ำกว่าอุณหภูมิรอบข้างมากกว่า 1 จุด	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

PID	บริเวณขอบของแผงเซลล์สุริยะมีอุณหภูมิสูงกว่ารอบข้าง	
Module Hot	แผงเซลล์สุริยะมีอุณหภูมิสูงเมื่อเทียบกับแผงรอบข้าง	
String Short Circuit	แผงเซลล์สุริยะหลายแผงติดกันมีอุณหภูมิสูงทั้งแผงเมื่อเทียบกับแผงรอบข้าง	
String Reverse Polarity	แผงเซลล์สุริยะหลายแผงติดกันมีจุดความร้อนหลายจุดหรือมีเซลล์สุริยะเสียในแนวขนานล่างสุด 1 แนว	



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

การทดลองและผลการทดลอง

4.1 การทดลองเปรียบเทียบการกระจายของสีต่อประสิทธิภาพของ YOLOV4

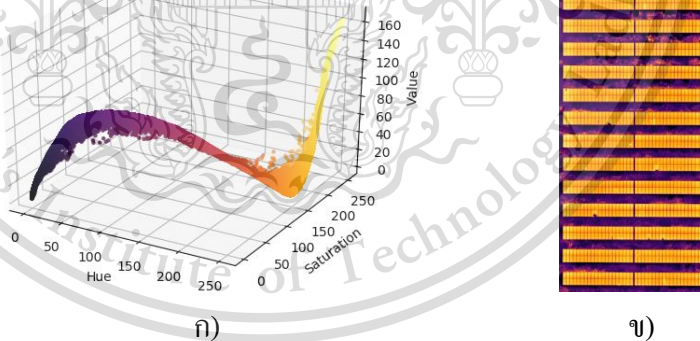
4.1.1 วัตถุประสงค์

ต้องการเปรียบเทียบการกระจายของสีแต่ละฟาร์มเพื่อหาเหตุผลที่ทำให้ค่าความแม่นยำของฟาร์มที่ 1 มีค่าที่สูงที่สุดในทั้ง 4 ฟาร์ม

4.1.2 วิธีการทดลอง

- 1) เขียนโค้ดสำหรับนำภาพถ่ายฟาร์มเซลล์สุริยะด้วยกล้อง IR หลังผ่านกระบวนการ Orthophoto map มาแล้วทั้ง 4 ฟาร์ม แสดงผลทางกราฟ HSV (Hue , Saturation, Value หรือ ความสว่างของสี) เพื่อดูการกระจายของสี
- 2) นำภาพถ่ายฟาร์มเซลล์สุริยะทั้ง 4 ฟาร์มเข้า Model และประมวลผล

4.1.3 ผลการทดลอง



รูป 4.1 Color distribution ของฟาร์มที่ 1


ก) กราฟ Color distribution ของฟาร์มที่ 1

ข) ภาพตัวอย่างที่ใช้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.



ก)




ข)


รูป 4.2 Color distribution ของฟาร์มที่ 2

ก) กราฟ Color distribution ของฟาร์มที่ 2

ข) ภาพตัวอย่างที่ใช้



ก)





ข)

รูป 4.3 Color distribution ของฟาร์มที่ 3

ก) กราฟ Color distribution ของฟาร์มที่ 3

ข) ภาพตัวอย่างที่ใช้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ก)

ข)

รูป 4.4 Color distribution ของฟาร์มที่ 4

ก) กราฟ Color distribution ของฟาร์มที่ 3

ข) ภาพตัวอย่างที่ใช้

4.1.4 วิเคราะห์ผลการทดลอง

จากค่า Recall แต่ละฟาร์มมีค่าเท่ากับ 0.93, 0.71, 0.83, 0.84 เรียงจากฟาร์มที่ 1 ไปฟาร์มที่ 4 จะเห็นได้ว่าจากผลลัพธ์ที่กราฟแสดง ในฟาร์มที่มีค่า recall น้อยที่สุดจะมีการกระจายตัวของสีค่อนข้างมากกว่าฟาร์มอื่นๆ ในขณะที่ฟาร์มที่เหลือมีการกระจายตัวของสีที่น้อยกว่า

4.1.5 สรุปผลการทดลอง

จากผลการทดลองจะเห็นได้ว่าภาพถ่ายจากฟาร์มที่ 1 มีการกระจายของตัวของสีที่น้อยที่สุด จากทั้ง 4 ฟาร์ม แสดงให้เห็นว่าลักษณะการกระจายตัวของสีมีผลต่อประสิทธิภาพในการระบุปัญหาของแพลงก์ตอนใน YOLOV4

4.2 การทดลองการเปรียบเทียบประสิทธิภาพของโมเดล Faster-RCNN, SSD, YOLOV4


4.2.1 วัตถุประสงค์ในการทดลอง

ต้องการเปรียบเทียบประสิทธิภาพค่า mAP สำหรับการ training Object detection model ทั้ง 3 โมเดล ได้แก่ Faster-RCNN, SSD, YOLOV4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.2 วิธีการทดลอง

- 1) เตรียมชุดข้อมูลฟาร์มที่ 1 เป็นภาพถ่ายจากโดรนด้วยกล้อง IR ที่ผ่านการทำ orthophoto map มาแล้ว ตัดภาพให้เป็นรูปสี่เหลี่ยมจัตุรัสจำนวน 20 รูป เพื่อที่จะใช้สำหรับการทดสอบโมเดลทั้ง 3 โมเดล



รูป 4.5 ภาพฟาร์มเซลล์สุริยะที่ผ่านการตัดให้เป็นรูปสี่เหลี่ยมจัตุรัส

- 2) นำรูปภาพที่ได้มาทำ Label จำแนกประเภทข้อบกพร่องของเซลล์สุริยะ 2 ประเภทได้แก่ Hotspots และ Bypass Diode ด้วยโปรแกรม LabelImg

ตาราง 4.1 จำนวน ground truth ของแต่ละประเภทปัญหา

	Hotspot	Bypass Diode
ฟาร์มที่ 1	28	55

- 3) นำไฟล์ Ground truth ที่ได้ไปเทรนในโมเดลทั้ง 3 โมเดล
- 4) กำหนดค่า Num_Step เท่ากับ 10,000 ทั้ง 3 โมเดลเพื่อกำหนดจำนวนรอบที่ใช้ในการเทรนให้เท่ากันทั้ง 3 โมเดล
- 5) เตรียมรูปภาพเซลล์สุริยะที่จะใช้สำหรับทดสอบประสิทธิภาพทั้ง 3 โมเดลจำนวน 10 รูป
- 6) รันโมเดลทั้ง 3 โมเดล
- 7) ทำการเปรียบเทียบกับการ predict ของ object detection model จาก weight ที่ได้จากการ training


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
8) เปรียบเทียบค่า Precision ทั้ง 2 classes
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\text{Precision} = \frac{\text{true positive}}{\text{true positive} + \text{false positive}}$$

4.2.3 ผลการทดลอง

ตาราง 4.2 เปรียบเทียบค่า Precision ของแต่ละ model


Model	Precision of Hotspots	Precision of Bypass Diode
Faster-RCNN	0	0.086957
SSD object detection	0.142857	0.695652
YOLO version 4	0.666667	0.85



รูป 4.6 ผลลัพธ์จาก Model Faster-RCNN


ผลลัพธ์ที่ได้จาก Model Faster-RCNN Precision จากรูปภาพข้างต้นไม่มีแผงเซลล์สุริยะที่เสียเป็นประเภท hotspots เลย แต่โมเดลทำนายว่ามีแผงที่เสียเป็นประเภท hotspots และตัวโมเดลไม่เจอแผงที่เสียเป็นประเภท bypass diode เลย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 4.7 ผลลัพธ์จาก Model SSD Object Detection

ผลลัพธ์ที่ได้จาก Model SSD Object จากรูปภาพข้างต้นระบุตำแหน่งประเภท bypass diode ได้แม่นยำกว่า Model Faster-RCNN



รูป 4.8 ผลลัพธ์จาก Model YOLOV4

ผลลัพธ์ที่ได้จาก Model YOLOV4 จากรูปภาพข้างต้นระบุตำแหน่งประเภท bypass diode ได้แม่นยำกว่า Model Faster-RCNN, SSD

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.4 วิเคราะห์ผลการทดลอง

จากผลการทดลองพบว่าค่า mAP ของคลาส Hotspots และ Bypass Diode ของใน YOLO V4 มีค่าที่สูงที่สุดใน 3 โมเดล

4.2.5 สรุปผลการทดลอง

จากผลการทดลองเปรียบเทียบประสิทธิภาพในการหาข้อบกพร่องของแผงเซลล์สุริยะ 2 ประเภท Hotspots, Bypass Diode ทั้ง 3 โมเดล(Faster-RCNN, SSD, YOLOV4) พบว่าค่า mAP ทั้ง 2 คลาสในโมเดล YOLOV4 มีค่ามากที่สุด โดยมากกว่าโมเดล Faster-RCNN อยู่ 71.5 % และโมเดล SSD อยู่ 34 % สรุปได้ว่าในระยะเวลาที่เท่ากัน โมเดล YOLOV4 เหมาะสมที่สุดสำหรับโครงการนี้

4.3 การทดลองทดสอบประสิทธิภาพของ YOLOV4

4.3.1 วัตถุประสงค์ในการทดลอง

ต้องการเปรียบเทียบความแม่นยำของการ predict ของ YOLOV4 model จากฟาร์มเซลล์สุริยะ ทั้ง 4 ฟาร์ม


4.3.2 วิธีการทดลอง

- 1) นำ dataset ที่ได้เตรียมเอาไว้ทั้ง 4 ฟาร์ม แบ่งเป็นรูปเล็กแล้วใช้รูป 80 % ของทุกฟาร์ม แบ่งมาทำการ Train



รูป 4.9 ตัวอย่างรูปถ่าย infrared ฟาร์มเซลล์สุริยะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูป 4.10 ตัวอย่างรูปถ่าย infrared ฟาร์มเซลล์สุริยะ ที่ผ่านการครอบตัดแล้ว

- 2) ทำ ground truth ของ dataset ที่จะนำมา Train

ตาราง 4.3 จำนวน ground truth ในแต่ละ class ทั้ง 4 ฟาร์ม ของ dataset ที่จะนำมา train

	Hotspot	Bypass Diode	Vegetation	Module Hot	PID	String Short	String Reverse
ฟาร์มที่ 1	221	275	120	9	2	1	0
ฟาร์มที่ 2	500	287	0	98	246	14	0
ฟาร์มที่ 3	1542	579	0	28	52	46	7
ฟาร์มที่ 4	1013	488	6	61	4	0	0
Total	3276	1629	126	196	304	61	7

- 3) ทำ data augmentation ใน Roboflow website ซึ่งประกอบไปด้วย Flip horizontal และ Flip vertical
- 4) ตั้งค่า parameter ในตัว model สำหรับ train ให้ batch size = 64 , subdivision = 24, learning rate = 0.001, channel = 3, momentum = 0.949, decay = 0.0005, angle = 0, saturation = 1.5, exposure = 1.5, hue = 0.1, max batch = 6000
- 5) ทำการ Training ใน Google colab โดยเลือกใช้ YOLOV4 model เป็นจำนวน 7700 iteration จนได้ weight ที่มีค่า average loss ต่ำกว่า 2.00
- 6) ทำ Ground truth ของ ไฟล์ Test ที่แบ่งไว้ 20 % จาก dataset ทั้งหมด
- 7) ทำการเปรียบเทียบกับ การ predict ของ YOLOv4 model จาก weight ที่ได้จากการ training

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 8) เปรียบเทียบค่า Precision เพื่อการหาความแม่นยำในการ predict ปัญหาเซลล์สุริยะในแต่ละ class และค่า Recall ในการหาความถูกต้องในการ predict ปัญหาเซลล์สุริยะ โดยมีค่า IOU Threshold เท่ากับ 0.5

$$\text{Precision} = \frac{\text{true positive}}{\text{true positive} + \text{false positive}}$$

$$\text{Recall} = \frac{\text{true positive}}{\text{true positive} + \text{false negative}}$$

4.3.3 ผลการทดลอง



รูป 4.11 ตัวอย่างผลการทดลอง

ตาราง 4.4 ค่า Average precision ในแต่ละ Class ในการ train 7700 iterations

	Hotspot	Bypass Diode	Vegetation	Module Hot	PID	String Short	String Reverse
Average precision	0.9971	0.9985	0.9998	0.99999	0.9975	0.9992	0.9971

ผลลัพธ์ในการ train ทำให้ได้ค่า Recall = 0.99

หลังจากนั้นหาค่า mAP(mean average precision) เพื่อหาค่าความแม่นยำเฉลี่ยของการ train นี้

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ได้ค่า mAP = 0.998414

ตาราง 4.5 ค่า Precision ในแต่ละ class ทั้ง 4 ฟาร์ม ผลลัพธ์ในการ test

	Hotspot	Bypass Diode	Vegetation	Module Hot	PID	String Short	String Reverse
Farm 1	0.871429	0.966667	0.94	1.00	-	-	-
Farm 2	0.695652	0.906977	-	0.686275	0.909091	1.00	1.00
Farm 3	0.885827	0.956835	-	0.863636	0.618182	0.882353	1.00
Farm 4	0.990476	1.00	-	0.923077	1.00	-	-

ตาราง 4.6 ค่า Recall ในแต่ละฟาร์ม ผลลัพธ์ในการ test

	Recall
Farm 1	0.933333
Farm 2	0.714286
Farm 3	0.834297
Farm 4	0.84375

4.3.4 วิเคราะห์ผลการทดลอง

จากผลการทดลองในตารางที่ 4.5 จะเห็นได้ว่าค่า Precision แต่ละคลาสขึ้นกับความชัดเจนของลักษณะปัญหาของแผงเซลล์สุริยะ ส่วนคลาสที่มีค่า Precision เท่ากับ 0 เกิดจากฟาร์มนั้นไม่มีลักษณะปัญหาของแผงเซลล์สุริยะในคลาสนั้นเลย และ recall ได้ผลลัพธ์เป็นไปตามผลการทดลองที่ 4.1

4.3.5 สรุปการทดลอง

จากผลการทดลอง จะสรุปได้ว่า YOLOV4 มีประสิทธิภาพเหมาะสมกับโครงการนี้ โดยถ้าแบ่งตามคลาสที่มีค่า Precision สูงที่สุดคือ String Reverse ส่วนคลาสที่มีค่า Precision น้อยที่สุดคือ Module Hot และถ้าแบ่งตามฟาร์ม ฟาร์มที่มีค่า Recall สูงที่สุดคือ Farm 1 และ ฟาร์มที่มีค่า Recall น้อยที่สุดคือ Farm 2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

บทสรุปผลและข้อเสนอแนะ

5.1 สรุปผล

จากประสิทธิภาพความแม่นยำในการทำนายของ yoloV4 ที่ได้จากการทดลองแสดงให้เห็นว่าสามารถใช้งานได้จริงที่บางรูปแบบการกระจายของสีและจากผลการทดลองเรื่องการกระจายตัวของสี ทำให้เห็นแนวทางว่าควรตั้งค่ากล้อง infrared ที่จะใช้งานในอนาคตอย่างไรเพื่อให้ได้ประสิทธิภาพที่สุดจากการใช้งาน yoloV4

5.2 ปัญหาและแนวทางแก้ไข

- 1) การติดตั้ง library ในการทำงานให้ทำงานได้เต็มประสิทธิภาพนั้นทำได้ค่อนข้างยาก จึงแก้ปัญหาโดยการใช้งาน google colab แทน
- 2) ปัญหาในการจัดการและแสดงผลใน reactJS แก้ปัญหาโดยการอ่าน Official Document
- 3) ส่งรูปผ่านทาง HTTP request ได้ยาก แก้ปัญหาโดยการส่งผ่านตัว axios ด้วย multipart
- 4) Print report จาก backend python แล้วส่งมาให้ react ได้ยาก แก้ปัญหาโดย print ใน reactJS แทน
- 5) yoloV3 ที่ใช้งานในภาคการศึกษาที่ 1 มีประสิทธิภาพที่ไม่น่าพอใจ แก้ไขโดยเปลี่ยนไปใช้ yoloV4 แทน

5.3 แนวทางและการพัฒนาต่อ

- 1) ปรับปรุง weight ของตัวปัญหาหรือตัวแมงให้มีประสิทธิภาพที่ดีขึ้น
- 2) เพิ่มระบบผู้ใช้งาน, ระบบจัดการผู้ใช้
- 3) พัฒนา backend โดยเปลี่ยนไปใช้ object detection model ที่ใหม่กว่าหรือมีประสิทธิภาพที่ดีกว่าใน fastAPI framework ภาษา python
- 4) เพิ่มระบบระบุตำแหน่งในแผนที่โลก
- 5) พัฒนาระบบจัดการลำดับการซ่อมบำรุงเซลล์สุริยะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

This material is reserved for educational use only, not allowed for commercial use.

Forbidden to modify the content, and cite the document when use.

บรรณานุกรม

PradyaSin. 2019. **Convolution Neural Network คืออะไร**. [Online].

Available : <https://medium.com/@pradyasin/what-is-convolution-neural-network-bf2e525089f5>.

Mr.P L. 2019. **Deep Learning แบบฉบับคนสามัญชน EP 1 : Neural Network History**. [Online].

Available : <https://medium.com/mmp-li/deep-learning-แบบฉบับคนสามัญชน-ep-1-neural-network-history-f7789236a9a3>.

Natthawat Phongchit. 2018. **Convolutional Neural Network (CNN) คืออะไร**. [Online].

Available : <https://medium.com/@natthawatphongchit/มาลองดูวิธีการคิดของ-cnn-กัน-e3f5d73eebaa>.

David Friml. 2017. **How to prepare images for a training dataset?**. [Online].

Available : <https://medium.com/@davidfriml/how-to-prepare-images-for-a-training-dataset-f6889433249b>.

Joe Hoeller. 2020. **Object Detection on Thermal Images**. [Online].

Available : <https://medium.com/@joehoeller/object-detection-on-thermal-images-f9526237686a>

Ayoosh Kathuria. 2018. **What's new in YOLO v3?**. [Online].

Available : <https://towardsdatascience.com/yolo-v3-object-detection-53fb7d3bfe6b>

Jonathan Hui. 2018. **Real-time Object Detection with YOLO, YOLOv2 and now YOLOv3**.

[Online]. Available : <https://jonathan-hui.medium.com/real-time-object-detection-with-yolo-yolov2-28b1b93e2088>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Jonathan Hui. 2018. **mAP (mean Average Precision) for Object Detection.** [Online].

Available : <https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173>

INTERNATIONAL ENERGY AGENCY PHOTOVOLTAIC POWER SYSTEMS PROGRAMME.

2018. **Review on Infrared and Electroluminescence Imaging for PV Field Applications.**

[Online]. Available : https://iea-pvps.org/wp-content/uploads/2020/01/Review_on_IR_and_EL_Imaging_for_PV_Field_Applications_by_Task_13.pdf

Xiang Zhang., Wei Yang., Xiaolin Tang., and Jie Liu. 2018. **A Fast-Learning Method for Accurate and Robust Lane Detection Using Two-Stage Feature Extraction with YOLO v3.**

[Online]. Available : <https://www.mdpi.com/1424-8220/18/12/4308/pdf>.

W3schools.2015. **What is React?.** [Online].

Available : https://www.w3schools.com/whatis/whatis_react.asp.

Bozz Srinikom.สร้าง API ด้วย FastAPI เร็ว แรง พิ่ว !!! [Online].

Available : <https://p-srinikom.medium.com/review-สร้าง-api-ด้วย-fastapi-เร็ว-แรง-พิ่ว-๗-148b10416a70>.

Jacob Solawetz.**Breaking Down YOLOv4.** [Online].

Available : <https://blog.roboflow.com/a-thorough-breakdown-of-yolov4/>.

MongoDB.**MongoDB A complete framework.**[Online].

Available : <https://www.mongodb.com/3>.

Bootstrap.**Build fast, responsive sites with Bootstrap.**[Online].

Available : <https://getbootstrap.com/>.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Roboflow.**Everything you need to start building computer vision into your applications.**[Online].

Available : <https://roboflow.com/>.

Figma.**Where teams design together.**[Online].

Available : <https://www.figma.com/>.

Uvicorn.**The lightning-fast ASGI server.**[Online].

Available : <https://www.uvicorn.org/>.

Gowthami Wudaru.**Sending multipart request in Node.js(files upload+ json).**[Online].

Available : <https://medium.com/@wgowthami98/sending-multipart-request-in-node-js-bef5a4192b7d>.

Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi.**You Only Look Once: Unified, Real-Time Object Detection.**[Online].

Available : <https://arxiv.org/pdf/1506.02640.pdf>.

Sik-HO tsang.**Review: YOLOv2 & YOLO9000 — You Only Look Once (Object Detection).**[Online].

Available : <https://towardsdatascience.com/review-yolov2-yolo9000-you-only-look-once-object-detection-7883d2b02a65>.

MatthewHerbst.**ReactToPrint - Print React components in the browser.**[Online].

Available : <https://github.com/gregnb/react-to-print>.

Anawat Wannapila.**ทำความรู้จักกับ Axios — Promise based HTTP client แบบหมดเปลือก.**[Online].

Available : <https://blog.nextzy.me/axios-based-http-promise-de13980aec55>.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้