

การตรวจจับข้อบกพร่องและการวินิจฉัยการหยุดทำงานของเครื่องจักรใน
กระบวนการติดตั้งหัวอ่านเขียนโดยใช้เทคนิคการเรียนรู้ของเครื่องจักร



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมเมคคาทรอนิกส์
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2562

**FAULT DETECTION AND DIAGNOSIS OF MACHINE
DOWNTIME IN SLIDER ATTACHMENT PROCESS
USING MACHINE LEARNING TECHNIQUE**



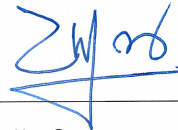
Thanaporn Thamcharoen

**A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Mechatronics Engineering
Suranaree University of Technology
Academic Year 2019**

การตรวจจับข้อบกพร่องและการวินิจฉัยการหยุดทำงานของเครื่องจักรใน
กระบวนการติดตั้งหัวอ่านเขียนโดยใช้เทคนิคการเรียนรู้ของเครื่องจักร

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(รศ. ดร.บัณฑิต กฤตาคม)

ประธานกรรมการ



(รศ. ดร.จิระพล ศรีเสริฐผล)

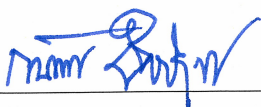
กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(อ. ดร.ธีทัต คลวิชัย)

กรรมการ

มหาวิทยาลัยเทคโนโลยีสุรนารี



(รศ. ร.อ. ดร.กนต์ธร ชำนิประศาสน์)

รองอธิการบดีฝ่ายวิชาการและพัฒนาความเป็นสากล



(รศ. ดร.พรศิริ จงกล)

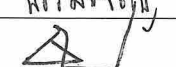
คณบดีสำนักวิชาวิศวกรรมศาสตร์

ชนาภรณ์ ธรรมเจริญ : การตรวจจับข้อบกพร่องและการวินิจฉัยการหยุดทำงานของ
เครื่องจักรในกระบวนการติดตั้งหัวอ่านเขียน โดยใช้เทคนิคการเรียนรู้ของเครื่องจักร
เครื่องจักร (FAULT DETECTION AND DIAGNOSIS OF MACHINE DOWNTIME IN
SLIDER ATTACHMENT PROCESS USING MACHINE LEARNING TECHNIQUE)
อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร.จิระพล ศรีเสริฐผล, 111 หน้า.

ปัจจุบันอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ได้ประยุกต์ใช้เครื่องจักรอัตโนมัติในกระบวนการ
ผลิตเป็นกำลังสำคัญ เนื่องจากมีความรวดเร็วและแม่นยำสูง ซึ่งในกระบวนการติดตั้งหัวอ่านเขียน
ของฮาร์ดดิสก์ไดรฟ์จะมี Mount head เป็นส่วนที่ทำหน้าที่ติดตั้งหัวอ่านเขียนลงบนแขนจับหัวอ่าน
เขียน โดยใช้แรงดันสุญญากาศ (Vacuum pressure) เพื่อยึดหัวอ่านขึ้นและเคลื่อนที่ไปติดตั้งลง
บนแขนจับหัวอ่านเขียนในตำแหน่งที่ถูกต้อง โดยทั้งสองส่วนนี้ต้องทำงานร่วมกันเพื่อให้สามารถ
อ่านเขียนข้อมูลได้อย่างมีประสิทธิภาพ เมื่อมีอัตราการผลิตที่สูง Mount Head อาจเกิดความ
เสียหายหรือเสื่อมอายุได้ ส่งผลให้เกิดการรั่วของแรงดันสุญญากาศ ทำให้หัวอ่านเขียนหล่นหาย
ระหว่างการเคลื่อนที่ไปติดตั้ง Slider Loss Defect (SLD) ส่งผลให้เครื่องจักรเกิดการ Alarm 71 อยู่
2% ในกระบวนการผลิตและเครื่องจักรหยุดทำงาน (Machine downtime) ในที่สุด

ดังนั้นในงานวิจัยนี้จึงออกแบบระบบตรวจจับและวินิจฉัยความบกพร่องด้วยรูปภาพของ
Mount Head เพื่อเป็นตัวตัดสินใจในการทำงานของกระบวนการติดตั้งหัวอ่านเขียน เพื่อจำแนก
ข้อบกพร่องที่เกิดขึ้น อีกทั้งยังสามารถแสดงสถานะแจ้งเตือนไปยังเครื่องจักรเมื่อเกิดความเสียหาย
เกินเกณฑ์ที่กำหนด เพื่อให้ผู้ปฏิบัติงานสามารถเปลี่ยน Mount head ได้ทันก่อนที่จะเกิดความ
เสียหาย โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องจักร (Machine learning) มาช่วยในการจำแนก
ข้อบกพร่องทั้ง 4 ระดับ คือ Good, Fault I, Fault II และ Fault III เพื่อแก้ปัญหา SLD และ Alarm
71 โดยใช้โครงข่ายประสาทเทียมนิวรอลเน็ตเวิร์กเปรียบเทียบค่าความถูกต้องระหว่างสองอินพุต
และสามอินพุต และโครงข่ายประสาทเทียมคอนโวลูชัน พบว่าโมเดลนิวรอลเน็ตเวิร์กแบบสอง
อินพุตมีความถูกต้องสูงสุด คือ 95.8% สามารถลด Alarm71 ได้ 1.919% และแบบสามอินพุตมี
ความถูกต้อง 94.3% สามารถลด Alarm71 ได้ 1.886% และ โมเดลคอนโวลูชันมีความถูกต้อง
87.6% สามารถลด Alarm71 ได้ 1.756%

สาขาวิชา วิศวกรรมเมคคาทรอนิกส์
ปีการศึกษา 2562

ลายมือชื่อนักศึกษา ชนาภรณ์ ธรรมเจริญ
ลายมือชื่ออาจารย์ที่ปรึกษา 

THANAPORN THAMCHAROEN : FAULT DETECTION AND
DIAGNOSIS OF MACHINE DOWNTIME IN SLIDER ATTACHMENT
PROCESS USING MACHINE LEARNING TECHNIQUE. THESIS
ADVISOR : ASSOC. PROF. JIRAPHON SRISERTPOL, Ph.D., 111 PP.

FAULT DETECTION AND DIAGNOSIS, FAULT CLASSIFICATION,
MACHINE LEARNING, ARTIFICIAL NEURAL NETWORK (ANN),
CONVOLUTION NEURAL NETWORK (CNN)

Hard Disk Drive (HDD) utilize automation machines for the assembly processes used in the industry to achieve higher production rates and lower costs. The Head Gimbal Assembly (HGA) production process has two main parts: glue dispensing and slider attaching by an Auto Core Adhesion mounting Machine (ACAM). The slider attaching process produces a mounted head to the suspension utilizing vacuum pressure to hold and position a slider. The errors from a vacuum leak effect to slider loss defective (SLD) resulting alarm71 and machine downtime. The proposed Fault Detection and Diagnosis (FDD) to detect and classify fault level of the mount head. Applied the Artificial Neural Network (ANN) and Convolution Neural Network (CNN) for detection and classification to investigated fault different class: Good, Fault I, Fault II and Fault III, comparison to classifier between ANN with 2 inputs and 3 input and CNN. that result, a fault detection and classification has achieved accuracy are 95.8%, 94.3%, 87.6% and ability reduce alarm71 are 1.919%, 1.886% and 1.756 respectively.

School of Mechatronics Engineering Student's Signature Thanaporn Thamcharoen
Academic Year 2019 Advisor's Signature Srisertpol

กิตติกรรมประกาศ

ผู้วิจัยขอกราบขอบพระคุณบุคคล และกลุ่มคนต่อไปนี้ ที่ได้กรุณาให้คำปรึกษา แนะนำ และช่วยเหลืออย่างดียิ่ง ทั้งในด้านวิชาการและการดำเนินงานวิจัย จนวิทยานิพนธ์นี้สำเร็จลุล่วงตาม วัตถุประสงค์ทุกประการ

รองศาสตราจารย์ ดร.จิระพล ศรีเสริฐผล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้ประสิทธิ์ ประสาทวิชาความรู้ ทั้งในด้านทฤษฎี ด้านการดำเนินงานวิจัย และด้านกระบวนการความคิดในการ ดำรงชีวิต อีกทั้งยังคอยชี้แนะในการทำงานวิจัย คอยช่วยเหลือ ให้กำลังใจ ให้รู้จักพักเพียร และ อดทน ตลอดจนให้คำแนะนำในการเขียน และตรวจแก้ไขวิทยานิพนธ์จนเสร็จสมบูรณ์ ซึ่งผู้วิจัย ขอขอบคุณท่านเป็นอย่างสูง และจะนำเอาวิชาความรู้และการดำรงชีวิตไปประยุกต์ใช้กับการทำงาน ในภายภาคหน้าต่อไป

รองศาสตราจารย์ เรืออากาศเอก ดร.กนต์ธร ชำนิประศาสน์ พร้อมด้วยผู้ช่วยศาสตราจารย์ ดร.อุเทน ลีตติ ที่ให้ความรู้ในด้านวิชาการที่เป็นประโยชน์ในการดำเนินงานวิจัย ซึ่งผู้วิจัยนำมา ประยุกต์ใช้จนทำให้งานวิจัยนี้สำเร็จได้

ขอขอบคุณบุคคลดังต่อไปนี้ที่ให้ความช่วยเหลือในด้านต่างๆ ในระหว่างทำงานวิจัย ซึ่ง ผู้วิจัยรู้สึกทราบบ้างอย่างยิ่ง และขอจดจำไว้ตลอดไป

บริษัท เวสเทิร์น ดิจิตอล (ประเทศไทย) จำกัด ที่ได้มอบทุนการศึกษาระดับบัณฑิตศึกษาแก่ ผู้วิจัย รวมทั้งค่าใช้จ่ายในการดำรงชีวิต และขอขอบพระคุณที่ได้ให้การสนับสนุนในการใช้อุปกรณ์ และเครื่องมือต่าง ๆ ในการทำงานวิจัยนี้

คุณประธาน ชมเมืองปัก, คุณจักรวรรดิ ดิยัง และ คุณสันติ พุ่มกระจ่าง รวมไปถึงบุคลากร ในแผนก HGA Assembly and Automation Development ที่ให้ความช่วยเหลือ และคำปรึกษาใน ระหว่างการทำงาน ทำให้ผู้วิจัยมีความรู้และประสบการณ์มากขึ้น

เจ้าหน้าที่ประจำสำนักวิชาวิศวกรรมศาสตร์ทุก ๆ ท่าน ที่อำนวยความสะดวกในด้านงาน เอกสารต่าง ๆ ตลอดจนให้คำปรึกษาแก่ผู้วิจัยด้วยดีเสมอมา

ท้ายนี้ ผู้วิจัยขอกราบขอบพระคุณบิดา มารดา และสมาชิกครอบครัวธรรมเจริญ ที่ให้การอุปการะ เลี้ยงดูด้วยความรักความอบอุ่น อบรมสั่งสอนให้เป็นคนดี กตัญญูรู้คุณ ตลอดจนส่งเสริม การศึกษาและให้กำลังใจเป็นอย่างดีเสมอมาจนกระทั่งวิทยานิพนธ์ฉบับนี้สำเร็จ

ธนาภรณ์ ธรรมเจริญ

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย)	ก
บทคัดย่อ (ภาษาอังกฤษ)	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ฉ
สารบัญรูป	ญ
บทที่	
1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	6
1.3 ขอบเขตของการวิจัย	6
1.4 ระเบียบวิธีวิจัย	7
1.5 สถานที่ทำงานวิจัย	7
1.6 เครื่องมือที่ใช้ในการทำวิจัย	7
1.7 ประโยชน์ที่คาดว่าจะได้รับ.....	8
1.8 การจัดทำรูปเล่มวิทยานิพนธ์	8
2 งานวิจัยที่เกี่ยวข้องและปริทัศน์วรรณกรรม	9
2.1 บทนำ.....	9
2.2 ความสำคัญของฮาร์ดดิสก์ไดรฟ์	9
2.2.1 ส่วนประกอบของฮาร์ดดิสก์ไดรฟ์.....	10
2.2.1.1 จานแม่เหล็ก.....	10
2.2.1.2 มอเตอร์หมุนจานแม่เหล็ก	11
2.2.1.3 หัวอ่านเขียน	11
2.2.1.4 แขนจับหัวอ่านเขียน.....	12
2.2.1.5 เคส.....	12

สารบัญ (ต่อ)

หน้า

2.3	เครื่องจักรและระบบอัตโนมัติ	13
2.4	ระบบสุญญากาศ.....	13
2.4.1	เทคโนโลยีสุญญากาศ	14
2.5	การประมวลผลภาพ.....	14
2.5.1	ความหมายพิกเซล.....	14
2.5.2	การแปลงภาพสีเป็นภาพระดับเทา	15
2.5.3	ภาพไบนารี.....	17
2.5.4	การแยกสีภาพ	18
2.6	การคงทนต่อความเสียหาย.....	18
2.7	ระบบตรวจจับและวินิจฉัยความผิดปกติ.....	19
2.8	ระบบตรวจจับและระบุตำแหน่งความผิดปกติ.....	19
2.9	ปัญญาประดิษฐ์.....	20
2.10	การเรียนรู้ของเครื่องจักร	21
2.10.1	เรียนรู้แบบมีผู้สอน.....	22
2.10.2	เรียนรู้แบบไม่มีผู้สอน	23
2.10.3	การเรียนรู้แบบเสริมกำลัง	24
2.11	แบบจำลองโครงข่ายประสาทเทียมนิเวศเน็ตเวิร์ก.....	25
2.11.1	ส่วนประกอบของนิเวศเน็ตเวิร์ก.....	26
2.11.2	องค์ประกอบของโครงข่ายประสาทเทียม	27
2.11.3	หลักการทำงานของโครงข่ายประสาทเทียม.....	27
	2.11.3.1 เครื่องข่ายการส่งข้อมูลไปข้างหน้า	27
	2.11.3.1 เครื่องข่ายการส่งข้อมูลไปข้างหน้า	27
	2.11.3.2 เครื่องข่ายการส่งข้อมูลย้อนกลับ	29
	2.11.3.3 การเรียนรู้สำหรับโครงข่ายประสาทเทียม	30
2.12	การเรียนรู้เชิงลึก	30
2.13	แบบจำลองโครงข่ายประสาทเทียมคอนโวลูชัน	31

สารบัญ (ต่อ)

หน้า

2.13.1	หลักการทํางาน	31
2.14	ปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	36
2.14.1	งานวิจัยเกี่ยวกับระบบสุญญากาศ.....	36
2.14.2	งานวิจัยเกี่ยวกับระบบตรวจจับความผิดพลาด	37
2.14.3	งานวิจัยเกี่ยวกับโครงข่ายประสาทเทียม	38
2.15	สรุป	40
3	วิธีการดำเนินงานวิจัย	41
3.1	บทนำ.....	41
3.2	วิเคราะห์ปัจจัยในกระบวนการติดตั้งหัวอ่านเขียน	41
3.2.1	ลักษณะความเสียหาย	41
3.2.1.1	สภาพ Good.....	42
3.2.1.2	สภาพ Fault I.....	43
3.2.1.3	สภาพ Fault II.....	44
3.2.1.4	สภาพ Fault III	45
3.2.1.5	สรุปปัจจัยที่มีผล	46
3.3	วิธีการทดลอง	51
3.3.1	การเก็บข้อมูล	52
3.3.2	เทคนิคการประมวลผลภาพ.....	52
3.3.2.1	การปรับความสว่างภาพ	52
3.3.2.2	การตัดส่วนภาพที่สำคัญ.....	53
3.4	กำหนดเงื่อนไขของระดับข้อบกพร่อง.....	54
3.5	การจำแนกข้อบกพร่องของ Mount head	55
3.5.1	จัดกลุ่มข้อมูลตามระดับข้อบกพร่อง	55
3.5.2	การเพิ่มจำนวนข้อมูล	55
3.5.3	การเตรียมข้อมูลเพื่อสร้างโมเดล	55
3.6	แบบจำลองโครงข่ายประสาทเทียมนิรอลเน็ตเวิร์ก.....	56

สารบัญ (ต่อ)

หน้า

3.6.1	เตรียมข้อมูลสำหรับโครงข่ายประสาทเทียมแบบ ANN.....	56
3.6.2	โครงข่ายประสาทเทียมนิเวรอลเน็ตเวิร์ก	57
3.6.2.1	กรณีที่ 1 สองอินพุต	57
3.6.2.2	วิธีการทดสอบ.....	57
3.6.2.3	กรณีที่ 2 สามอินพุต	59
3.6.2.4	วิธีการทดสอบ.....	59
3.7	แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน	61
3.7.1	เตรียมข้อมูลสำหรับโครงข่ายประสาทเทียมแบบ CNN.....	61
3.7.2	โครงสร้างของโมเดล	62
3.8	สรุป	64
4	ผลการศึกษา และการวิเคราะห์ผล.....	67
4.1	บทนำ.....	67
4.2	ผลการตรวจจับข้อบกพร่องของโครงข่ายประสาทเทียมนิเวรอลเน็ตเวิร์ก	67
4.2.1	การจำแนกข้อบกพร่องแบบสองอินพุต	67
4.2.1.1	กระบวนการเรียนรู้แบบสองอินพุต	67
4.2.1.2	การประเมินผลการจำแนกด้วยคอนฟิวชันเมตริกซ์	69
4.2.1.3	การประเมินผลประสิทธิภาพของโมเดล	70
4.2.2	การจำแนกข้อบกพร่องแบบสามอินพุต	71
4.2.2.1	กระบวนการเรียนรู้แบบสามอินพุต	71
4.2.2.2	การประเมินผลการจำแนกด้วยคอนฟิวชันเมตริกซ์	73
4.2.2.3	การประเมินผลประสิทธิภาพของโมเดล	73
4.3	การตรวจจับข้อบกพร่องของโครงข่ายประสาทเทียมแบบคอนโวลูชัน.....	74
4.3.1	ผลการทดสอบการจำแนกข้อบกพร่อง.....	74
4.3.2	การทดสอบการทำนายประสิทธิภาพในการจำแนก.....	76
4.3.2.1	การทดสอบการทำนายข้อบกพร่องแบบ Good.....	76
4.3.2.2	การทดสอบการทำนายข้อบกพร่องแบบ Fault I	76

สารบัญ (ต่อ)

หน้า

4.3.2.3 การทดสอบการทำนายข้อบกพร่องแบบ Fault II.....	77
4.3.2.4 การทดสอบการทำนายข้อบกพร่องแบบ Fault III.....	78
4.4 วิเคราะห์ผลการตรวจจับและจำแนกข้อบกพร่อง	79
4.4.1 โครงข่ายประสาทเทียมนิวรอลเน็ตเวิร์ก	79
4.4.1.1 กรณีสองอินพุต	79
4.4.1.2 กรณีสามอินพุต	79
4.4.2 โครงข่ายประสาทเทียมคอนโวลูชัน.....	79
4.5 ศึกษาอายุการใช้งานของ Mount head.....	81
4.5.1 อายุการใช้งานแบบปกติ.....	81
4.5.2 อายุการใช้งานแบบผิดปกติ.....	85
4.6 สรุป	89
5 สรุปและข้อเสนอแนะ	90
5.1 สรุป	90
5.3 ข้อเสนอแนะ.....	91
รายการอ้างอิง	92
ภาคผนวก	
ภาคผนวก ก.....	94
ภาคผนวก ข.....	98
ภาคผนวก ค.....	101
ภาคผนวก ง.....	108
ประวัติผู้เขียน	111

สารบัญตาราง

ตารางที่		หน้า
3.1	เงื่อนไขของพื้นที่พิกเซลตามระดับข้อบกพร่อง.....	54
3.2	รายละเอียดกระบวนการของโครงข่ายประสาทเทียมคอนโวลูชัน.....	64
4.1	ผลการเปรียบเทียบค่าความถูกต้องของโมเดลโครงข่ายประสาทเทียม	80
4.2	อายุการใช้งานของ Mount head แบบปกติ	82
4.3	อายุการใช้งานของ Mount head แบบผิดปกติ.....	86



สารบัญรูป

รูปที่		หน้า
1.1	เครื่องจักรอัตโนมัติในกระบวนการผลิตหัวอ่านเขียน	2
1.2	หัวอ่านเขียนข้อมูล	3
1.3	เครื่องหยอดกาวและติดหัวอ่านเขียนอัตโนมัติ.....	3
1.4	กระบวนการติดตั้งหัวอ่านเขียน	4
1.5	การติดตั้งหัวอ่านเขียนลงบนแขนจับหัวอ่านเขียน	4
1.6	แสดงขั้นตอนการทำงานและการเกิด Alarm ของกระบวนการติดตั้งหัวอ่านเขียน	5
1.7	เปอร์เซ็นต์การหยุดทำงานของเครื่องจักรในกระบวนการผลิต	5
2.1	ส่วนประกอบของฮาร์ดดิสก์ไดรฟ์ Hard Disk Drive (HDD).....	10
2.2	แผ่นจานแม่เหล็ก (Platters).....	10
2.3	มอเตอร์หมุนแผ่นแม่เหล็ก (Spindle Motor)	11
2.4	หัวอ่านเขียนบันทึกข้อมูล (Slider)	12
2.5	แขนจับหัวอ่านเขียน (Suspension).....	12
2.6	เคส (Case)	13
2.7	ตำแหน่งของพิกเซล	15
2.8	องค์ประกอบของภาพสี RGB	16
2.9	ระดับภาพสีเทา	16
2.10	การแปลภาพ RGB ให้เป็นภาพระดับเทา (Grayscale)	17
2.11	การแปลงภาพระดับสีเทาให้เป็นภาพขาวดำ	18
2.12	การคงทนต่อความเสียหาย.....	19
2.13	การจำแนกประเภทของ FDI	20
2.14	องค์ประกอบของปัญญาประดิษฐ์	21
2.15	ประเภทการเรียนรู้ของเครื่องจักร	22
2.16	แสดงการเรียนรู้แบบมีผู้สอน (Supervised Learning).....	23
2.17	แสดงการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning).....	24
2.18	แสดงการเรียนรู้แบบเสริมกำลัง (Reinforcement Learning).....	24

สารบัญรูป (ต่อ)

รูปที่	หน้า
2.19	การเรียนรู้ของโครงข่ายประสาทเทียม.....25
2.20	โครงสร้างของโครงข่ายประสาทเทียม26
2.21	Activation Function.....27
2.22	แบบจำลองโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า.....28
2.23	แบบจำลองโครงข่ายประสาทเทียมแบบป้อนกลับ29
2.24	ลักษณะโครงสร้างของโครงข่ายประสาทเทียม30
2.25	โครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN).....31
2.26	ลักษณะตัวกรอง.....32
2.27	กำหนดเลื่อนตัวกรองเท่ากับ 133
2.28	กำหนดเลื่อนตัวกรองเท่ากับ 233
2.29	การทำ Padding34
2.30	การทำ Pooling.....34
2.31	การทำ Max Pooling และ Mean Pooling35
3.1	แสดงสภาพความเสียหายของ Mount head.....42
3.2	แสดงรูปภาพ Mount head สภาพ Good.....43
3.3	แสดงสัญญาณแรงดันสัญญาณอากาศสภาพ Good43
3.4	แสดงรูปภาพ Mount head ระดับข้อบกพร่อง Fault I.....44
3.5	แสดงสัญญาณแรงดันสัญญาณอากาศสภาพ Fault I.....44
3.6	แสดงรูปภาพ Mount head สภาพ Fault II.....45
3.7	แสดงสัญญาณแรงดันสัญญาณอากาศระดับข้อบกพร่อง Fault II.....45
3.8	แสดงรูปภาพ Mount head สภาพ Fault III46
3.9	สัญญาณแรงดันสัญญาณอากาศสภาพ Fault III46
3.10	แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ยของแรงดันไฟฟ้า.....47
3.11	แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ยของแรงดันสัญญาณอากาศ48

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.12 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ย ของพื้นที่พิกเซลด้านนอก	49
3.13 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ย ของพื้นที่พิกเซลด้านใน	49
3.14 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ย ของพื้นที่พิกเซลทั้งหมด	50
3.15 ขั้นตอนการดำเนินงาน	52
3.16 การปรับความสว่างของรูปภาพ Mount head	53
3.17 การครอบตัดส่วนภาพที่สำคัญ	53
3.18 แสดงการวิเคราะห์หาพื้นที่ของรูปภาพ Mount head	54
3.19 แสดงการแบ่งข้อมูลสำหรับโมเดล ANN.....	56
3.20 แสดงไดอะแกรมวิธีการทดสอบแบบสองอินพุต.....	58
3.21 แสดงโมเดลโครงข่ายประสาทเทียมแบบสองอินพุต.....	59
3.22 แสดงไดอะแกรมวิธีการทดสอบแบบสามอินพุต.....	60
3.23 แสดงโมเดลโครงข่ายประสาทเทียมแบบสามอินพุต.....	60
3.24 แสดงการแบ่งข้อมูลเพื่อใช้สร้าง โมเดล CNN	61
3.25 แสดงหลักการเรียนรู้ของโมเดล CNN	62
3.26 แสดงกระบวนการเรียนรู้ของโมเดล CNN.....	62
4.1 แสดงรายละเอียดในกระบวนการที่ถูกต้องที่สุดของสองอินพุต	68
4.2 แสดงประสิทธิภาพในการตรวจสอบของสองอินพุต	69
4.3 คอนฟิวชันเมตริกซ์ของโมเดลที่มีความถูกต้องสูงที่สุดของสองอินพุต.....	70
4.4 แสดงการเปรียบเทียบประสิทธิภาพการตรวจจับของสองอินพุต.....	71
4.5 แสดงรายละเอียดในกระบวนการที่ถูกต้องที่สุดของสามอินพุต	72
4.6 แสดงประสิทธิภาพการตรวจสอบของสามอินพุต	72
4.7 คอนฟิวชันเมตริกซ์ของโมเดลที่มีความถูกต้องสูงที่สุดของสามอินพุต.....	73
4.8 แสดงการเปรียบเทียบประสิทธิภาพการตรวจจับของสามอินพุต.....	74

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.9	แสดงความถูกต้องในการฝึกสอนและการสูญเสียจากการตรวจสอบ ของโมเดล CNN 75
4.10	แสดงความถูกต้องของโมเดล CNN..... 75
4.11	แสดงการทดสอบการทำนายข้อบกพร่องแบบ Good..... 76
4.12	แสดงการทดสอบการทำนายข้อบกพร่องแบบ Fault I..... 77
4.13	แสดงการทดสอบการทำนายข้อบกพร่องแบบ Fault II..... 78
4.14	แสดงการทดสอบการทำนายข้อบกพร่องแบบ Fault III 78
4.15	กราฟแสดงความสัมพันธ์ระหว่างพื้นที่พิกเซลด้านนอกและ อัตราการผลิตหัวอ่านเขียน 83
4.16	กราฟแสดงความสัมพันธ์ระหว่างพื้นที่พิกเซลด้านในและ อัตราการผลิตหัวอ่านเขียน 84
4.17	กราฟแสดงความสัมพันธ์ระหว่างพื้นที่พิกเซลทั้งหมดและ อัตราการผลิตหัวอ่านเขียน 84
4.18	กราฟแสดงความสัมพันธ์ระหว่างพื้นที่พิกเซลด้านนอกและ อัตราการผลิตหัวอ่านเขียน 87
4.19	กราฟแสดงความสัมพันธ์ระหว่างพื้นที่พิกเซลด้านในและ อัตราการผลิตหัวอ่านเขียน 88
4.20	กราฟแสดงความสัมพันธ์ระหว่างพื้นที่พิกเซลทั้งหมดและ อัตราการผลิตหัวอ่านเขียน 88
ก.1	โปรแกรม Visual Studio Code เพื่อปรับความสว่างภาพ 95
ก.2	โค้ดในการปรับความสว่างภาพ 95
ก.3	ขั้นตอนการนำข้อมูลเข้า..... 96
ก.4	ผลการลดความสว่างภาพ 97
ก.5	ผลการเพิ่มความสว่างภาพ 97
ข.1	โค้ดเพื่อใช้ในการครอบตัดภาพ 99
ข.2	ภาพต้นฉบับ 100

สารบัญรูป (ต่อ)

รูปที่	หน้า
ข.3 ภาพจากการลดขนาด	100
ค.1 แสดงหน้าต่างในการป้อนอินพุตและเอาต์พุต	102
ค.2 แสดงข้อมูลอินพุตแบบสองอินพุต	103
ค.3 แสดงการกำหนดคลาสเอาต์พุตของข้อมูล	103
ค.4 แสดงการแบ่งข้อมูลเพื่อใช้สร้างโมเดล	104
ค.5 แสดงโมเดลโครงข่ายประสาทเทียมกรณีสองอินพุต	104
ค.6 แสดงหน้าต่างในการป้อนอินพุตและเอาต์พุต	105
ค.7 แสดงข้อมูลอินพุตแบบสามอินพุต	106
ค.8 แสดงการแบ่งข้อมูลเพื่อใช้สร้างโมเดล	106
ค.9 แสดงโมเดลโครงข่ายประสาทเทียมสามอินพุต	107
ง.1 Import ไลบารีที่จำเป็นเพื่อสร้าง โมเดล	109
ง.2 นำข้อมูลภาพเข้าเพื่อเตรียมสร้าง โมเดล	109
ง.3 โครงสร้างของ โมเดล	110
ง.4 รายละเอียด โครงสร้างของ โมเดล	110

บทที่ 1


บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา


ปัจจุบันอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ได้มีการประยุกต์ใช้เครื่องจักรอัตโนมัติในกระบวนการผลิตเป็นกำลังสำคัญ เนื่องจากมีความรวดเร็วและความแม่นยำสูง เพื่อให้สามารถผลิตชิ้นส่วนฮาร์ดดิสก์ไดรฟ์ได้ตรงตามความต้องการต่อการส่งออกสำหรับตลาดอุปกรณ์อิเล็กทรอนิกส์แสดงดังรูปที่ 1.1 โดยส่วนที่สำคัญของการจัดเก็บข้อมูลของฮาร์ดดิสก์ไดรฟ์คือหัวอ่านเขียนบันทึกข้อมูล Head Gimbal Assembly (HGA) แสดงดังรูปที่ 1.2 ซึ่งมีส่วนประกอบสำคัญ 2 ส่วนคือ หัวอ่านเขียน (Slider) เป็นส่วนที่ใช้ในการอ่านเขียนบันทึกข้อมูล และแขนจับหัวอ่านเขียน (Suspension) โดยทั้งสองส่วนนี้ต้องทำงานร่วมกันเพื่อให้สามารถอ่านเขียนข้อมูลได้อย่างมีประสิทธิภาพ รูปที่ 1.3 แสดงเครื่องจักรอัตโนมัติในการติดตั้งหัวอ่านเขียน Auto Core Adhesive Mounter Machine (ACAM) ซึ่งกระบวนการติดตั้งหัวอ่านเขียนฮาร์ดดิสก์ไดรฟ์แบบอัตโนมัติของเครื่องจักร ACAM มี 3 ส่วนประกอบหลัก ๆ คือ Pickup head, Vacuum table และ Mount head แสดงให้เห็นดังรูปที่ 1.4 โดยกระบวนการติดตั้งหัวอ่านเขียนเริ่มจาก Pickup head จะเคลื่อนที่มายังตำแหน่งของ Slider tray ในขณะเดียวกันจะทำการเปิดแรงดันสุญญากาศเพื่อทำการหยิบหัวอ่านเขียนขึ้น จากนั้นจึงนำไปวางที่ Vacuum table แล้ว Pickup head จะปิดแรงดันสุญญากาศและเคลื่อนที่กลับไปยังตำแหน่งเดิม ขณะเดียวกัน Vacuum table ก็จะเปิดแรงดันสุญญากาศเพื่อทำการปรับตำแหน่งของหัวอ่านเขียนให้เหมาะสม จากนั้น Mount head จะเคลื่อนที่มายังตำแหน่งที่ Vacuum table โดยเปิดแรงดันสุญญากาศเพื่อทำการหยิบหัวอ่านเขียนไปยังตำแหน่งที่ตรวจสอบเพื่อทำการปรับตำแหน่งของหัวอ่านเขียนอีกครั้งก่อนที่จะเคลื่อนที่ไปยังตำแหน่งที่ติดตั้งหัวอ่านเขียนลงบนแขนจับหัวอ่านเขียน (Suspension) แสดงให้เห็นดังรูปที่ 1.5 และ รูปที่ 1.6 แสดงขั้นตอนการทำงานและการเกิด Alarm โดยการติดตั้งหัวอ่านเขียนจำเป็นจะต้องมีความเที่ยงตรงและความแม่นยำสูง เนื่องจากเป็นส่วนประกอบที่สำคัญเป็นอย่างมาก และหัวอ่านเขียนมีขนาดเล็กมากระดับไมครอน จะเห็นได้ว่ากระบวนการดังกล่าวได้มีการใช้แรงดันสุญญากาศในการหยิบหัวอ่านเขียนเพื่อเคลื่อนที่ไปยังตำแหน่งต่าง ๆ ตามกระบวนการติดตั้ง ถ้าหากเกิดการสูญเสียแรงดันสุญญากาศจะทำให้หัวอ่านเขียนหล่นหายระหว่างการเคลื่อนที่ได้ ทำให้เกิดปัญหา Slider Loss Defect (SLD) ส่งผลกระทบทำให้เครื่องจักรขัดข้องเกิดการ Alarm71 และทำ

ให้เครื่องจักรหยุดทำงาน (Machine downtime) ในที่สุด อีกทั้งยังส่งผลต่ออัตราการผลิตที่ลดลง (Yield drop) จากรูปที่ 1.7 จะเห็นได้ว่าเครื่องจักร ACAM เกิด Machine downtime สูงที่สุดในกระบวนการผลิตของหัวอ่านเขียน ซึ่งส่วนมากเกิดจาก Alarm 71 อยู่ที่ 2.85% มีสาเหตุมาจากหัวอ่านเขียนหล่นหายนั่นเอง ซึ่งเกิดจาก Mount head 2.00% และเกิดจาก Pickup head 0.85% โดยกระบวนการติดตั้งหัวอ่านเขียนจะเห็นได้ว่า Mount head มีหน้าที่ที่สำคัญที่สุดในกระบวนการติดตั้งหัวอ่านเขียน เนื่องจากทำหน้าที่ติดตั้งหัวอ่านลงบนแขนจับหัวอ่านเขียนโดยตรงและจำเป็นต้องมีความถูกต้องและแม่นยำ เพื่อให้หัวอ่านเขียนมีประสิทธิภาพที่ดีต่อการใช้งาน เพราะฉะนั้นเมื่อ Mount Head เกิดความเสียหายหรือเสื่อมอายุ จะส่งผลต่อการสูญเสียของสูญญากาศ ทำให้เกิดหัวอ่านเขียนหล่นหาย

ในงานวิจัยนี้จึงศึกษาและออกแบบระบบตรวจจับข้อบกพร่องและวินิจฉัยการหยุดทำงานของเครื่องจักรในกระบวนการติดตั้งหัวอ่านเขียน โดยแบ่งระดับข้อบกพร่องออกเป็น 4 ระดับ คือ Good, Fault I, Fault II และ Fault III โดยประยุกต์ใช้การเรียนรู้ของเครื่องจักร (Machine learning) เพื่อตรวจจับและจำแนกข้อบกพร่องของ Mount Head ซึ่งทำการเปรียบเทียบแบบจำลองโครงข่ายประสาทเทียมทั้ง 2 แบบ ระหว่าง Artificial Neural Network (ANN) และ Convolution Neural Network (CNN) เพื่อแสดงประสิทธิภาพในการตรวจจับและจำแนกประเภทของข้อบกพร่องที่เกิดขึ้น เพื่อช่วยให้ระบบสามารถรับรู้ได้ว่าเกิดความเสียหายขึ้นในระดับใด ซึ่งจะหลีกเลี่ยงการทำงานของ Mount head ในระดับ Fault III เพื่อลดปัญหาหัวอ่านเขียนหล่นหาย, เครื่องจักรขัดข้องเกิดการ Alarm 71 และเครื่องจักรหยุดทำงาน



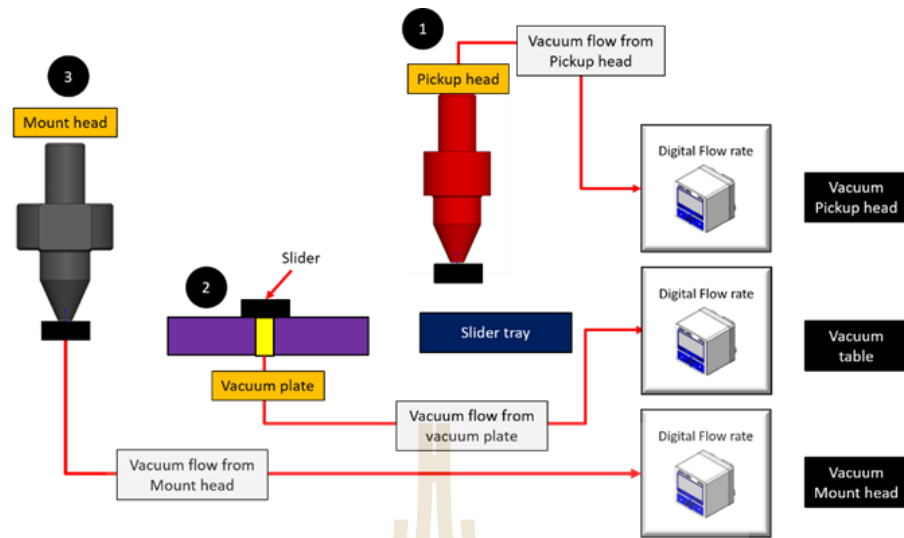
รูปที่ 1.1 เครื่องจักรอัตโนมัติในกระบวนการผลิตหัวอ่านเขียน



รูปที่ 1.2 หัวอ่านเขียนข้อมูล



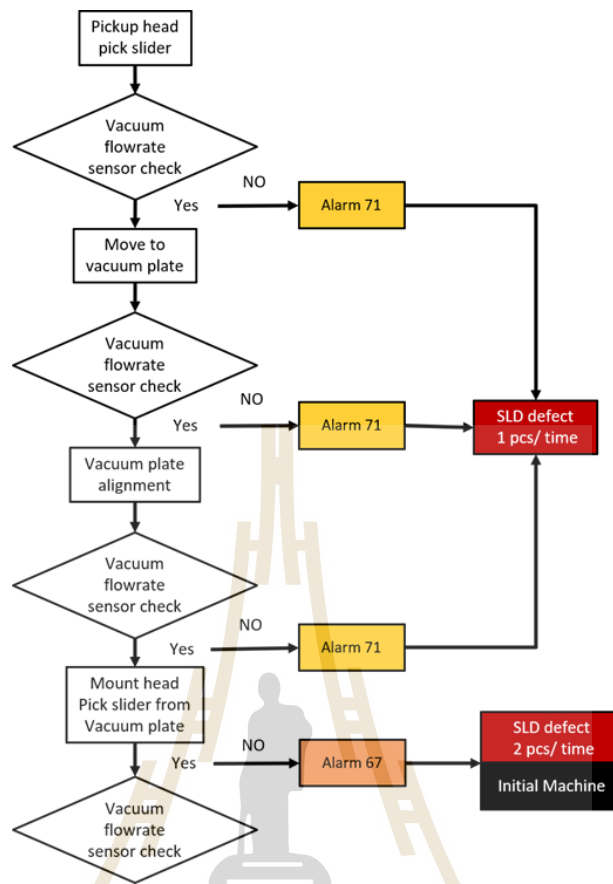
รูปที่ 1.3 เครื่องหยอดกาวและติดหัวอ่านเขียนอัตโนมัติ



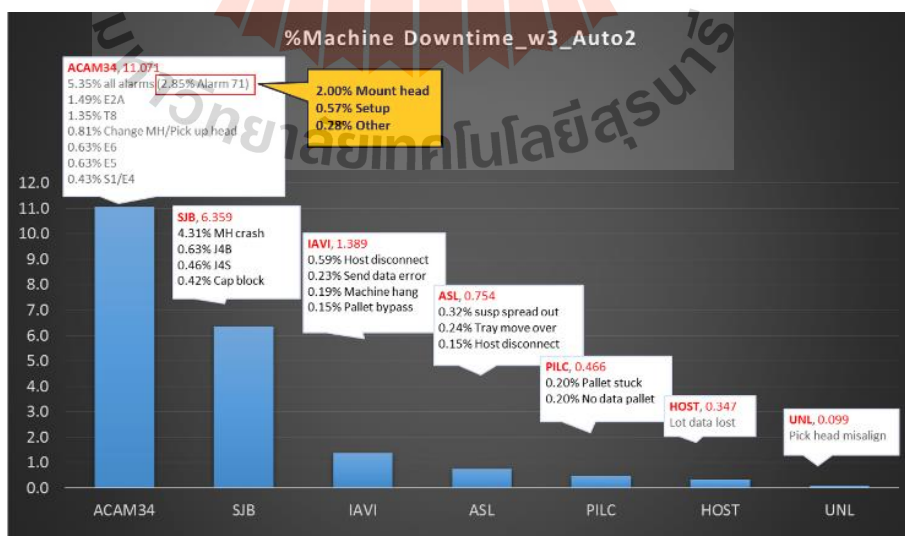
รูปที่ 1.4 กระบวนการติดตั้งหัวอ่านเขียน



รูปที่ 1.5 การติดตั้งหัวอ่านเขียนลงบนแขนจับหัวอ่านเขียน



รูปที่ 1.6 แสดงขั้นตอนการทำงานและการเกิด Alarm ของกระบวนการติดตั้งหัวอ่านเขียน



รูปที่ 1.7 แสดงเปอร์เซ็นต์การหยุดทำงานของเครื่องจักรในกระบวนการผลิต

1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อลดการหยุดทำงานของเครื่องจักร (Machine downtime) ที่มีปัญหาจาก Alarm 71 เนื่องจากสาเหตุหัวอ่านเขียนหล่นหายระหว่างการติดตั้ง (Slider Loss Defect: SLD)
2. เพื่อออกแบบและพัฒนาระบบตรวจจับข้อบกพร่องในกระบวนการติดตั้งหัวอ่านเขียนของฮาร์ดดิสก์ไครฟ์ เพื่อตรวจจับข้อบกพร่องได้ทันก่อนเกิดความเสียหาย
3. เพื่อประยุกต์ใช้ Machine learning ด้วยโครงข่ายประสาทเทียม Artificial Neural Network (ANN) และ Convolution Neural Network (CNN) เพื่อใช้ในการตรวจจับและจำแนกข้อบกพร่องที่เกิดขึ้นในกระบวนการติดตั้งหัวอ่านเขียนของฮาร์ดดิสก์ไครฟ์
4. เพื่อสามารถลดปัญหาการเกิด Alarm71 ของ Mount head จาก 2.00% ให้เหลือ 1.0%

1.3 ขอบเขตของงานวิจัย

1. ศึกษาและวิเคราะห์หาปัญหาที่ทำให้เกิดการหยุดทำงานของเครื่องจักร (Machine downtime) ที่เครื่อง ติดตั้งประกอบหัวอ่านเขียนฮาร์ดดิสก์ไครฟ์ Auto Core Adhesive Mounting machine (ACAM)
2. ศึกษากระบวนการติดตั้งหัวอ่านเขียนของฮาร์ดดิสก์ไครฟ์ (Slider Attachment Process)
3. เก็บข้อมูลจากกระบวนการผลิตหัวอ่านเขียนในไลน์การผลิตจริง
4. ประยุกต์ใช้การเรียนรู้ของเครื่องจักร (Machine learning) โดยนำอัลกอริทึมของโครงข่ายประสาทเทียม Artificial Neural Network (ANN) และ Convolution Neural Network (CNN) มาช่วยในการตรวจจับและจำแนกข้อบกพร่อง
5. ใช้โปรแกรม VisionPro และ Visual Studio Code สำหรับทำการประมวลผลภาพ (Image processing)
6. ใช้โปรแกรม MATLAB เพื่อใช้ในการทำ Artificial Neural Network (ANN)
7. ใช้ Google Colab โดยเขียนโค้ดด้วยภาษา Python เพื่อใช้ในการทำ Convolution Neural Network (CNN)
8. ประเมินประสิทธิภาพค่าความถูกต้องในการจำแนกข้อบกพร่องของโครงข่ายประสาทเทียม

1.4 ระเบียบวิธีวิจัย

1. ศึกษางานวิจัยที่เกี่ยวข้องเกี่ยวกับการตรวจจับและจำแนกข้อบกพร่อง การวิเคราะห์ด้วยรูปภาพเพื่อจำแนกลักษณะของข้อบกพร่อง การประมวลผลภาพ และการเรียนรู้ของเครื่องจักร

2. ออกแบบระบบตรวจจับข้อบกพร่องในกระบวนการติดตั้งหัวอ่านเขียนฮาร์ดดิสก์ไดรฟ์ ออกแบบการทดลอง และเก็บข้อมูลเพื่อทำการพิจารณาหาตัวแปรที่มีนัยสำคัญต่อการตรวจจับข้อบกพร่อง โดยเก็บข้อมูลทั้งสัญญาณแรงดันสัญญาณภาค, สัญญาณแรงดันไฟฟ้า และรูปภาพของ Mount head ที่มีความสัมพันธ์กัน เพื่อวิเคราะห์หาปัจจัยที่ทำให้เกิดปัญหาหัวอ่านเขียนหล่นหาย และ Alarm 71

3. ออกแบบการทดลอง และเก็บข้อมูลในกระบวนการผลิตจริง

4. เตรียมข้อมูลสำหรับการจำแนกประเภทของข้อบกพร่อง

5. ใช้การเรียนรู้ของเครื่องมาประยุกต์ใช้ในการตรวจจับและจำแนกข้อบกพร่อง

6. เตรียมข้อมูลเพื่อสร้างโมเดล ในการตรวจจับข้อบกพร่อง โดยใช้โครงข่ายประสาท

เทียม Artificial Neural Network (ANN) และ Convolution Neural Network (CNN)

7. ทำการทดสอบระบบตรวจจับข้อบกพร่อง

8. วิเคราะห์ข้อมูล และสรุปผลลัพธ์ที่ได้

9. จัดทำเอกสารและรายงานการวิจัย

1.5 สถานที่ทำงานวิจัย

บริษัทเวสเทิร์น ดิจิตอล (ประเทศไทย) จำกัด แผนก HGA Assembly and Automation Development

1.6 เครื่องมือที่ใช้ในการทำวิจัย

1. เครื่องจักรในการติดตั้งประกอบหัวอ่านเขียนฮาร์ดดิสก์ไดรฟ์ Auto Core Adhesive Mounting machine (ACAM)

2. โปรแกรม VisionPro และ Visual Studio Code สำหรับทำการประมวลผลภาพ (Image processing)

3. โปรแกรม MATLAB เพื่อใช้ในการทำ Artificial Neural Network (ANN)

4. โปรแกรม Python และ Colab เพื่อใช้ในการทำ Convolution Neural Network (CNN)

5. คอมพิวเตอร์ส่วนบุคคล

1.7 ประโยชน์ที่คาดว่าจะได้รับ

1. ลดปัญหาการเกิด Slider Loss Defect (SLD) ที่จะทำให้เครื่องจักรขัดข้องเกิด Alarm71 และลดการหยุดทำงานของเครื่องจักรได้ (Machine downtime)
2. สามารถตรวจจับและจำแนกข้อบกพร่องของ Mount head ได้
3. สามารถแจ้งเตือนไปยังเครื่องจักรเพื่อทำการซ่อมบำรุงก่อนจะเกิดความเสียหาย
4. สามารถออกแบบระบบตรวจจับข้อบกพร่องกับเครื่องจักรอัตโนมัติอื่น ๆ ได้

1.8 การจัดทำรูปเล่มวิทยานิพนธ์

บทที่ 1 เป็นบทนำซึ่งจะกล่าวถึงความสำคัญของปัญหา วัตถุประสงค์ ขอบเขตของงานวิจัย ระเบียบวิธีวิจัย ตลอดจนประโยชน์ที่คาดว่าจะได้รับจากงานวิจัยนี้

บทที่ 2 กล่าวถึงทฤษฎีพื้นฐาน และงานวิจัยที่เกี่ยวข้องกับระบบสัญญาณ, เทคนิคการตรวจจับข้อบกพร่อง โดยประยุกต์ใช้โครงข่ายประสาทเทียมของการเรียนรู้ของเครื่องจักร (Machine Learning)

บทที่ 3 บรรยายถึงวิธีการดำเนินงานวิจัย โดยใช้เทคนิค Fault Detection and Diagnosis (FDD) เพื่อพัฒนาการตรวจจับและจำแนกข้อบกพร่อง โดยประยุกต์ใช้งานร่วมกับการเรียนรู้ของเครื่องจักร (Machine Learning) ซึ่งจะเปรียบเทียบประสิทธิภาพของ 2 โมเดล คือ Artificial Neural Network (ANN) และ Convolution Neural Network (CNN) ในการตรวจจับและจำแนกประเภทของข้อบกพร่องที่เกิดขึ้น

บทที่ 4 แสดงผลการทดสอบในส่วนของการตรวจจับและจำแนกข้อบกพร่อง โดยสร้างจากแบบจำลองโครงข่ายประสาทเทียม Artificial Neural Network (ANN) และ Convolution Neural Network (CNN) รวมถึงความถูกต้องของทั้ง 2 โมเดล

บทที่ 5 เป็นบทสรุปและข้อเสนอแนะ

บทที่ 2


งานวิจัยที่เกี่ยวข้องและปริทัศน์วรรณกรรม

2.1 บทนำ

ในปัจจุบันอุตสาหกรรมการผลิตได้มีการนำเทคโนโลยี pick and place มาใช้กันอย่างกว้างขวาง ในการประกอบชิ้นส่วน ซึ่งในอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ได้มีการประยุกต์ใช้ในการประกอบชิ้นส่วนที่สำคัญในกระบวนการผลิตคือ การประกอบหัวอ่านเขียนฮาร์ดดิสก์ไดรฟ์ด้วยเครื่องจักรอัตโนมัติ เพื่อหยิบจับชิ้นงานและทำการติดตั้งในตำแหน่งที่ถูกต้อง โดยต้องใช้ความละเอียดและความแม่นยำสูง เนื่องจากชิ้นส่วนมีขนาดเล็กระดับไมครอน กลไกการทำงานคือเครื่องจักรจะได้รับการป้อนโปรแกรมระบุตำแหน่งให้สามารถหยิบจับชิ้นส่วนไปประกอบเป็นชิ้นงานได้อย่างสมบูรณ์ โดยใช้แรงดันสุญญากาศในการหยิบจับงานขึ้นและทำการเคลื่อนย้ายชิ้นงานในการประกอบชิ้นส่วนนั่นเอง ถ้าหากเกิดการสูญเสียแรงดันสุญญากาศ จะมีผลกระทบต่อเครื่องจักรและกระบวนการผลิตได้ ดังนั้นจึงศึกษางานวิจัยและปริทัศน์วรรณกรรมที่เกี่ยวข้องกับการออกแบบระบบตรวจจับและวินิจฉัยข้อบกพร่อง, เทคนิคการเรียนรู้ของเครื่องจักรด้วยแบบจำลองโครงข่ายประสาทเทียมที่มีความคิดที่ลอกเลียนแบบมาจากสมองมนุษย์ ซึ่งจะทำให้เครื่องจักรให้เป็นระบบอัจฉริยะที่ชาญฉลาด

2.2 ความสำคัญของฮาร์ดดิสก์ไดรฟ์ (Hard Disk Drive)

ฮาร์ดดิสก์ (Hard disk) คืออุปกรณ์อิเล็กทรอนิกส์ชิ้นหนึ่งที่เป็นส่วนเก็บสำรองข้อมูลต่าง ๆ ของคอมพิวเตอร์ ไม่ว่าจะเป็นข้อมูลระบบปฏิบัติการที่ใช้ขับเคลื่อนคอมพิวเตอร์ หรือข้อมูลในรูปแบบของโปรแกรม หรือแฟ้มงานต่าง ๆ ส่วนถูกเก็บเอาไว้ในส่วนฮาร์ดดิสก์ เพราะฉะนั้นฮาร์ดดิสก์ไดรฟ์จึงเป็นอุปกรณ์ที่จำเป็นและสำคัญที่สุดเปรียบเสมือนสมองส่วนความทรงจำของคอมพิวเตอร์ ซึ่งข้อมูลในฮาร์ดดิสก์จะเก็บอยู่ในรูปของโดเมนแม่เหล็กที่มีขนาดเล็กมาก ๆ ยิ่งขนาดของโดเมนนี้ยิ่งมีขนาดเล็กเท่าไร ความจุของฮาร์ดดิสก์จะยิ่งมีขนาดเพิ่มขึ้นเท่านั้น และยังสามารถเข้าถึงข้อมูลได้ในเวลาที่รวดเร็วมก แสดงให้เห็นดังรูปที่ 2.1



รูปที่ 2.1 ส่วนประกอบฮาร์ดดิสก์ไดรฟ์ Hard Disk Drive (HDD)

2.1.1 ส่วนประกอบของฮาร์ดดิสก์ไดรฟ์

2.1.1.1 จานแม่เหล็ก (Platters)


มีลักษณะเป็นแผ่นจานกลม ๆ ที่เคลือบด้วยสารแม่เหล็กวางซ้อนกันหลาย ๆ ชั้น ขึ้นอยู่กับความเข้มของข้อมูล ซึ่งจะถูกรอ่านและถูกบันทึกลงในแผ่นจานแม่เหล็ก โดยใช้หัวอ่านเขียนบันทึกข้อมูล (Head Gimbal Assembly: HGA) ซึ่งข้อมูลนั้นจะถูกบันทึกในลักษณะข้อมูลดิจิทัลคือ ตัวเลข 0 และ 1 และที่แผ่นแม่เหล็กนั้นจะติดกับมอเตอร์สำหรับหมุน (Spindle Motor) และสามารถเก็บข้อมูลได้ทั้ง 2 ด้านของแผ่นจานแม่เหล็กตามแนวเส้นรอบวงบนแผ่นจานแม่เหล็กสามารถเก็บข้อมูลได้เป็นจำนวนมาก และเข้าถึงข้อมูลได้อย่างรวดเร็ว ดังรูป 2.2



รูปที่ 2.2 แผ่นจานแม่เหล็ก (Platters)

2.1.1.2 มอเตอร์หมุนแผ่นแม่เหล็ก (Spindle Motor)


รูปที่ 2.3 มอเตอร์หมุนแผ่นแม่เหล็ก เป็นตัวควบคุมงานแม่เหล็กให้หมุนไปยังตำแหน่งที่ต้องการเพื่ออ่านข้อมูล บันทึกข้อมูล หรือแก้ไขข้อมูลปกติมักมีความเร็วในการหมุนประมาณ 5,600 - 7,200 รอบต่อนาที โดยมีแขนจับของหัวอ่าน (Suspension) จะมีหัวอ่าน (Slider) ติดอยู่ที่ปลายแขนจับของหัวอ่าน เพื่อให้สามารถขยับไปมาเพื่ออ่านหรือเขียนข้อมูลบนแผ่นแม่เหล็กได้



รูปที่ 2.3 มอเตอร์หมุนแผ่นแม่เหล็ก (Spindle Motor)

2.1.1.3 หัวอ่านเขียน (Slider)


เป็นส่วนที่ใช้ในการอ่านและเขียนบันทึกข้อมูล ซึ่งหัวอ่านจะสร้างมาจากขดลวด โดยการรับคำสั่งจากตัวคอนโทรลเลอร์ก่อนเกิดความเหนียวนำทางแม่เหล็ก และไปเปลี่ยนแปลงโครงสร้างของสนามแม่เหล็ก และทำให้เกิดการเปลี่ยนแปลงของข้อมูลนั่นเอง โดยจะทำการอ่านหรือเขียนข้อมูลลงบนแผ่นงานแม่เหล็กที่หมุนอย่างรวดเร็ว ทำให้หัวอ่านทำงานได้เร็ว ทำให้สามารถเข้าถึงข้อมูลได้อย่างรวดเร็ว แสดงดังรูปที่ 2.4 ซึ่งหัวอ่านเขียนจะเป็นส่วนประกอบหนึ่งของแขนจับหัวอ่านที่จะต้องทำงานร่วมกัน



รูปที่ 2.4 หัวอ่านเขียนบันทึกข้อมูล (Slider)

2.1.1.4 แขนจับหัวอ่านเขียน (Suspension)

รูปที่ 2.5 แขนจับหัวอ่านเขียนมีลักษณะเป็นแท่งเหล็กยาว ๆ ที่จะมีแอกชูเอเตอร์เป็นส่วนประกอบ ซึ่งเมื่อรับคำสั่งจากวงจรไฟฟ้าให้สามารถเลื่อนไปยังตำแหน่งที่ต้องการ ไฟฟ้าก็จะผ่านแอกชูเอเตอร์ (Actuator) ที่มีคุณสมบัติ piezoelectric สามารถเปลี่ยนพลังงานไฟฟ้าเป็นพลังงานกล ซึ่งทำให้หัวอ่านสามารถอ่านหรือเขียนข้อมูลลงบนแผ่นแม่เหล็กได้ตามตำแหน่งที่ต้องการ โดยแขนจับหัวอ่านเขียนจะต้องทำงานร่วมกับหัวอ่านคู่ควบกันไป



รูปที่ 2.5 แขนจับหัวอ่านเขียน (Suspension)

2.1.1.5 เคส (Case)

เป็นที่บรรจุส่วนประกอบต่าง ๆ ที่ใช้ในการทำงานของฮาร์ดดิสก์ เพื่อเตรียมพร้อมสำหรับการส่งออกสำหรับตลาดและการนำไปใช้งาน แสดงดังรูปที่ 2.6



รูปที่ 2.6 เคส (Case)

2.3 เครื่องจักรและระบบอัตโนมัติ

เครื่องจักรกลอัตโนมัติและระบบอัจฉริยะ ได้มีการนำเทคโนโลยีเข้ามาประยุกต์ใช้และมีบทบาทในการช่วยเพิ่มผลผลิตและลดต้นทุนในอุตสาหกรรม หนึ่งในกระบวนการที่สำคัญอย่างมากสำหรับอุตสาหกรรมการผลิตคือ การประกอบชิ้นส่วน ซึ่งต้องใช้ความละเอียด แม่นยำ จึงเลือกใช้เครื่องจักรอัตโนมัติเนื่องจากสามารถทำงานด้วยความแม่นยำ มีความเที่ยงตรงสูง และรวดเร็ว หลักการของการประกอบชิ้นส่วนด้วยเครื่องจักรอัตโนมัติหีบจับชิ้นงานคือ เครื่องจักรจะได้รับการป้อนโปรแกรมระบุตำแหน่งและแนวการวางที่ถูกต้องของชิ้นส่วนนั้น ๆ เพื่อให้สามารถหีบจับชิ้นส่วนไปประกอบเป็นชิ้นงานได้อย่างสมบูรณ์ อีกทั้งยังสามารถเคลื่อนย้ายชิ้นงานให้ไปตำแหน่งที่ต้องการได้อีกด้วย ซึ่งโดยส่วนมากการหีบจับชิ้นงานจะใช้ระบบสูญญากาศในการหีบจับชิ้นงานขึ้นและทำการเคลื่อนย้ายชิ้นงานในการประกอบชิ้นส่วนนั่นเอง

2.4 ระบบสูญญากาศ (Vacuum system)

คือสถานะของความหนาแน่นของอนุภาคของก๊าซที่น้อยกว่าบรรยากาศที่ระดับพื้นผิวโลก ถ้าความดัน (pressure) ของก๊าซน้อยกว่าความดันบรรยากาศ (atmospheric pressure) สถานะของก๊าซนี้มีชื่อเรียกว่า “สูญญากาศ” โดยการคำนวณหาแรงดันสูญญากาศ สามารถหาได้จากผลต่างระหว่างความดันบรรยากาศ(atmospheric pressure) กับความดันสมบูรณ์ (Absolute pressure) ซึ่งหาได้จากสมการที่ 1 ดังนี้

$$P_{vacuum} = Atmospheric \text{ pressure} - Absolute \text{ pressure} \quad (1)$$

ซึ่งในอุตสาหกรรมมักนิยมใช้แรงดันภายในต่ำกว่าแรงดันภายนอกเสมอ เนื่องจากอากาศภายในภาชนะถูกสูบเพื่อให้เกิดสุญญากาศ ค่าสุญญากาศแสดงถึงค่าที่แท้จริงของความดันระบบต่ำกว่าความดันบรรยากาศ ดังนั้นค่าความดันหรือความดันสัมพัทธ์จะแสดงเป็นค่าลบ ซึ่งหมายความว่าแรงดันภายในภาชนะบรรจุต่ำกว่าแรงดันภายนอก คุณภาพของสุญญากาศ หมายถึงระดับของสถานะที่เข้าใกล้สุญญากาศสมบูรณ์ ความดันของแก๊สที่เหลืออยู่จะถูกใช้เป็นตัววัดคุณภาพของสุญญากาศเป็นหลัก ความดันแก๊สที่ยังเหลือน้อยจะหมายถึงคุณภาพที่ยิ่งมากขึ้น สำหรับสุญญากาศคุณภาพต่ำจะถูกใช้เพื่อการดูดและการสูบ

2.4.1 เทคโนโลยีสุญญากาศ

ระบบสุญญากาศ (Vacuum System) ในอุตสาหกรรมต่าง ๆ จะใช้สำหรับงานหยิบจับ ช่วยให้การดำเนินงานรวดเร็ว และลดระยะเวลาของการทำงาน เพิ่มประสิทธิภาพในการทำงานในการใช้งานระบบสุญญากาศนั้น สามารถที่จะใช้ในการยก ย้าย หยิบ หรือหมุน เป็น มีการพัฒนาเพื่อประยุกต์ใช้งานให้มีความหลากหลายมากยิ่งขึ้น สามารถใช้ดูดสิ่งของได้ทั้งแบบผิวเรียบและผิวไม่เรียบ เหมาะกับการใช้งานร่วมกับแขนกลหุ่นยนต์ (Robot) เพื่อลดระยะเวลาของการทำงาน เพิ่มประสิทธิภาพในการทำงาน เพิ่มความสะอาดรวดเร็วและความปลอดภัยในการทำงานให้มากยิ่งขึ้น แต่ข้อเสียของระบบนี้คือ ต้องมีการเพิ่มแรงดันมากขึ้น เมื่อมีการเกิดการรั่ว เพื่อให้วัตถุไม่หล่นขณะทำงานหรือเคลื่อนที่ โดยการรั่วไหลนี้จะถูกชดเชยด้วยเครื่องกำเนิดสุญญากาศ


2.5 การประมวลผลภาพ (Image processing)

เป็นการประยุกต์การประมวลผลสัญญาณบนสัญญาณ 2 มิติ เช่น ภาพนิ่ง หรือภาพวิดีโอ รวมถึงสัญญาณ 2 มิติอื่น ๆ ที่ไม่ใช่ภาพ เพื่อนำมาเปลี่ยนเป็นข้อมูลดิจิทัลและใช้กรรมวิธีต่าง ๆ มากระทำกับข้อมูลภาพเพื่อให้ได้ตามวัตถุประสงค์ที่ต้องการ โดยพิจารณาปัจจัยต่าง ๆ เช่น ชนิดของภาพ ขนาดความละเอียดของภาพ ความคมชัดของภาพ โหมดของสี โหมดของสีเทา การปรับความเข้มให้อยู่ในค่ามาตรฐาน การกรองสัญญาณรบกวน ซึ่งเทคนิคการประมวลผลภาพสามารถไปประยุกต์ใช้ได้กับงานที่หลากหลาย เช่น ระบบตรวจกระดาษคำตอบ ระบบตรวจจับใบหน้า ระบบอ่านบาร์โค้ด เป็นต้น

2.5.1 ความหมายพิกเซล

จุดเล็ก ๆ ของภาพดิจิทัลที่รวมกันทำให้เกิดเป็นภาพภาพหนึ่ง ๆ ขึ้นมา การแสดงผลพิกเซลนั้นมีความสำคัญต่อการสร้างกราฟฟิกของคอมพิวเตอร์มาก เพราะทุก ๆ ส่วนของ


กราฟฟิก เช่น จุด เส้น แบบลายและสีของภาพ ล้วนเกิดจากพิกเซลทั้งสิ้น ซึ่งจะประกอบไปด้วยจำนวนพิกเซลมากมาย แต่ละจุดจะมีสีที่แตกต่างกันไป ยิ่งภาพมีค่าพิกเซลยิ่งสูง ภาพก็จะยิ่งมีความละเอียดและคมชัดมากยิ่งขึ้น ความใหญ่ของภาพก็จะใหญ่ขึ้นด้วย ซึ่งภาพที่แสดงจะมีความหนาแน่นของพิกเซลที่แตกต่างกันออกไป โดยเมตริกซ์ที่จำนวนคอลัมน์ (Column) และแถว (Row) จะแทนจำนวนของพิกเซล แสดงให้เห็นดังรูปที่ 2.7



รูปที่ 2.7 ตำแหน่งของพิกเซล

2.5.2 การแปลงภาพสี (RGB) เป็นภาพระดับสีเทา (Grayscale)

ภาพสีคือชุดเรียงลำดับของพิกเซลสี $M \times N \times 3$ ซึ่งในทุก ๆ พิกเซลของภาพสีนั้นจะมีค่า ระดับ RGB (Red, Green, Blue) โดยสี RGB ต้องใช้ 8 บิตในเก็บข้อมูลหนึ่งสี ดังนั้นแม้สีแต่ละสีจะมีระดับสีจำนวน $2^8 = 256$ ระดับ เมื่อมีการผสมสีหนึ่งสีจาก RGB จะต้องพิจารณาสีแต่ละส่วนจาก 0 ถึง 255 ส่วน ในการพิจารณาโหมดสีของภาพแบบ RGB การเกิดภาพสีนั้นเกิดจาก สีแดง สีเขียว และ สีน้ำเงิน เป็นส่วนประกอบที่มีแตกต่างกัน ซึ่งความเหมือนจริงของสีที่ผสมด้วยคอมพิวเตอร์ขึ้นอยู่กับในหนึ่งจุดพิกเซล (Pixel) ของการแสดงผล แสดงองค์ประกอบของภาพสี RGB ดังรูปที่ 2.8 แต่ถ้าภาพสีเมื่อแปลงเป็นภาพระดับสีเทา (Grayscale) จะไม่มีค่าของสีเข้ามาเกี่ยวข้องจะมีเฉพาะค่าของความสว่างเท่านั้น ซึ่งเป็นสิ่งสำคัญที่ได้จากการแปลงภาพสีให้เป็นภาพระดับสีเทา ทุก ๆ จุด (Pixel) ของภาพระดับสีเทาโดยทั่วไปแล้วสามารถแบ่งระดับของภาพได้ 256 สี โดยที่ค่าสีแต่ละพิกเซลของภาพจะหมายถึงความเข้มแสงแต่ละตำแหน่งของพิกเซลที่อยู่ในรูประดับสีเทา แสดงดังรูปที่ 2.9



รูปที่ 2.8 องค์ประกอบของภาพสี RGB



รูปที่ 2.9 ระดับภาพสีเทา

การเปลี่ยนภาพจากระบบสี RGB เป็นระดับสีเทา (Gray Scale) จะใช้สมการที่ 2 ดังนี้

$$Gr(x,y) = 0.2989 * R(x,y) + 0.5870 * G(x,y) + 0.1140 * B(x,y) \quad (2)$$

เมื่อ $Gr(x,y)$ คือค่าของระดับสีเทาที่ได้จากการแปลงที่จุด (x,y)

$R(x,y)$, $G(x,y)$, $B(x,y)$ คือค่าระดับสี R,G,B ของภาพสีที่พิกเซล (x,y) ที่ต้องการหา

ภาพที่รับเข้ามาในขั้นตอนแรกเป็นภาพที่อยู่ในระบบปริภูมิสีแบบ RGB ดังนั้นแต่ละพิกัดของภาพจะประกอบด้วยค่าของที่แสดงถึง ค่าของ R ค่าของ G และค่าของ B ระบบจะทำการเปลี่ยนให้เป็นภาพระดับสีเทา (Grayscale) เพื่อให้สามารถวิเคราะห์ภาพได้ง่ายขึ้นเพราะเมื่อแปลงภาพเป็นระดับสีเทาแล้วจะทำให้แต่ละจุดภาพของภาพจะเหลือเพียงค่าความเข้มของสีมีค่าตั้งแต่ 0 ถึง 255 โดยนิยมระบุในช่วง 0-1 แสดงดังรูปที่ 2.10



รูปที่ 2.10 การแปลงภาพ RGB ให้เป็นภาพระดับเทา (Grayscale)

2.5.3 ภาพไบนารี (Binary Image)

เทคนิคนี้เป็นการแปลงโหมดสีเทาของแต่ละจุดในรูปภาพไปยังโหมดสีขาวดำ โดยพิจารณาจากค่าความเข้มสีของจุดในรูปภาพต้นฉบับว่ามากกว่าค่าที่กำหนดหรือไม่ หากมากกว่าจะแปลงค่าเป็นสีขาว ในทางกลับกัน หากน้อยกว่าหรือเท่ากับจะแปลงค่าเป็นสีดำ โดยแสดงดังสมการที่ 3

$$G_{B\&W}(X,Y) = \begin{cases} 1, & \text{if } (L \leq G(x,y)) \\ 0, & \text{if } (L > G(x,y)) \end{cases} \quad (3)$$


โดย $G(x,y)$ คือ ฟังก์ชันค่าความเข้มสีของทั้งรูปภาพในโหมดสีเทา

$G_{B\&W}(x,y)$ คือ ฟังก์ชันของรูปภาพในโหมดขาวดำ

L คือ ค่าคงที่สำหรับกำหนดช่วงความเข้มสี

การแปลงภาพให้เป็นไบนารีเพื่อแปลงค่าของภาพก่อนนำไปสู่กระบวนการประมวลผลภาพแบบดิจิทัล ซึ่งจะถูกแสดงให้เห็นด้วยความเข้มสีขาวดำ สามารถเก็บรายละเอียดภาพได้ 256 ระดับ โดยข้อมูลภาพแต่ละจุดจะถูกกำหนดด้วยค่าสีในโหมดภาพขาวดำ และจะแปลงเป็นภาพไบนารีที่มีขนาด 1 บิต ซึ่งในแต่ละบิตจะกำหนดด้วยค่า 1 หรือ 0 โดยที่ 1 หมายถึงจุดสีขาว และ 0 จะแสดงเป็นจุดสีดำ ซึ่งมีการใช้ค่าเทรชโฮลด์ (Threshold) ในการแปลงภาพ แสดงให้เห็นดังรูปที่ 2.11 เพราะฉะนั้นภาพไบนารีจึงมีข้อจำกัดที่จะนำภาพมาใช้แสดงภาพโดยทั่วไป แต่ทำให้การ

ประมวลผลทำได้รวดเร็วและมีประสิทธิภาพ การประมวลผลภาพไบนารีนำไปใช้มากในการประมวลผลด้านเอกสาร การประมวลผลที่ต้องการความเร็วสูง



รูปที่ 2.11 การแปลงระดับสีเทาให้เป็นภาพขาวดำ

2.5.4 การแยกสีภาพ (Color Thresholding)

รูปภาพ $f(x,y)$ ประกอบด้วยวัตถุ (object) และพื้นหลัง (background) โดยต้องกำหนดขอบเขตค่าสีของแต่ละมิติสีตามสีของภาพที่สนใจออกจากภาพพื้นหลัง โดยการแยกสีภาพเป็นกระบวนการที่เลือกข้อมูลที่สนใจออกจากภาพ ต้องกำหนดค่าคงที่ Threshold (T) หรือค่าที่ทำให้เกิดจุดเปลี่ยนแปลงของภาพต้นฉบับ ซึ่งเป็นการประมวลผลภาพระดับฟิสิกเซลของภาพ มิติของสีจะมีความแตกต่างกันตามทฤษฎี โดยสมการที่ 4 ของ Threshold มีดังนี้

$$B = \begin{cases} 1(\text{white}) & \text{if } f(x, y) > T \\ 0(\text{Black}) & \text{if } f(x, y) \leq T \end{cases} \quad (4)$$


โดยที่ Threshold = 1 คือองค์ประกอบของภาพวัตถุ

Threshold = 0 คือองค์ประกอบของภาพพื้นหลัง

2.6 การคงทนต่อความเสียหาย (Fault Tolerance Control)

เทคนิคที่ถูกรออกแบบและพัฒนาเพื่อแก้ไขระบบ เมื่อมีเหตุการณ์ที่ระบบมีสถานะความเสียหายเกิดขึ้น โดยระบบควบคุมยังสามารถทำให้ระบบยังคงทำงานต่อไปได้ ถึงแม้ระบบจะเกิดข้อบกพร่องขึ้นหรือเกิดความผิดปกติขึ้นก็ตาม โดยหลักการทำงานของระบบเริ่มจากเมื่อระบบตรวจพบข้อผิดพลาดหรือข้อบกพร่องขึ้น และทำการตัดสินใจโดยการปรับปรุงชุดควบคุมหรือชดเชยความเสียหายที่เกิดขึ้น สามารถชดเชยปัญหาต่าง ๆ ได้อย่างมีประสิทธิภาพ โดยการปรับค่า

ควบคุมใหม่ (Reconfiguration mechanism) เพื่อแก้ไขปัญหาที่กำลังเผชิญอยู่ เพื่อทำการประมวลผล ตรวจจับ (Detect) ระบุตำแหน่ง (Isolation) ตลอดจนประเมินค่า (Estimation) ของปัญหาความผิดพลาดและสิ่งรบกวนที่เกิดขึ้นในระบบได้ เพื่อให้ระบบสามารถดำเนินงานต่อไปได้ และสามารถคงทนต่อความเสียหายที่เกิดขึ้นของระบบ อีกทั้งยังป้องกันและลดการล้มเหลวของการทำงานของระบบเท่าที่สามารถทำได้ โดยจะต้องคำนึงถึง การตรวจจับความเสียหาย (Fault Detection), การระบุตำแหน่งความเสียหาย (Fault Location), การจำกัดเขตความเสียหาย (Fault Estimate) และการกู้คืนจากความเสียหาย (Fault Recovery) เป็นต้น แสดงดังรูป 2.12



รูปที่ 2.12 การคงทนต่อความเสียหาย
(แหล่งที่มา International Federation of Automatic Control)

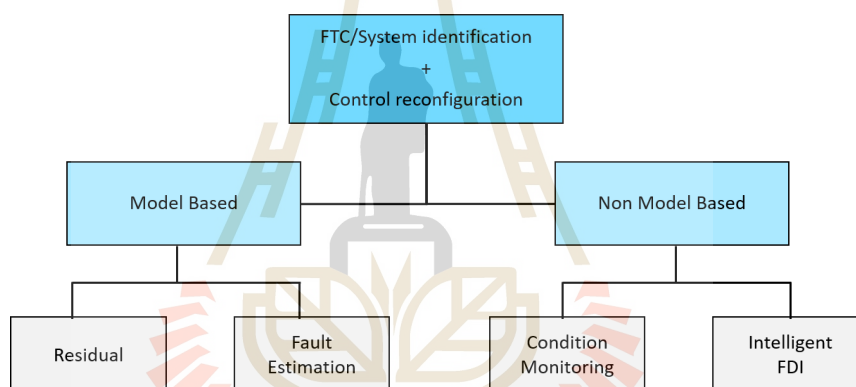
2.7 ระบบตรวจจับและวินิจฉัยความผิดพลาด Fault Detection and Diagnosis (FDD)

การตรวจสอบความผิดพลาดของระบบ (Fault Detection) เป็นขั้นตอนแรกในการตรวจสอบความผิดพลาดของระบบ โดยจะตรวจสอบการทำงานของอุปกรณ์ ที่ตรวจจับว่ามีความเสียหายเกิดขึ้นหรือไม่ ซึ่งการตรวจจับความเสียหายมักเป็นความต้องการแรก ก่อนที่จะดำเนินการไปสู่ขั้นตอนการวินิจฉัยความผิดพลาดของระบบ (Fault Diagnosis) เป็นการวินิจฉัยระบบสืบเนื่องต่อจาก fault detection เพื่อระบุสาเหตุและตำแหน่งของการเกิดความผิดพลาดในระบบ

2.8 ระบบตรวจจับและระบุตำแหน่งความผิดพลาด Fault Detection and Isolation (FDI)

ตรวจจับระบบว่ามีความเสียหายเกิดขึ้น หรือมีการทำงานที่ต่างไปจากสภาวะปกติหรือไม่ ซึ่งเมื่อมีความเสียหายเกิดขึ้น จะต้องหาได้ว่ากระบวนการใดของระบบเกิดความเสียหายขึ้นที่จุด

ใหม่ เพื่อให้ระบบจดจำรูปแบบการทำงานของระบบใหม่ และนำโมเดลที่เสียหายออกจากระบบ เพื่อที่จะสามารถทำการกู้คืนได้อย่างถูกต้อง โดย FDI จะแบ่งออกเป็น 2 วิธี คือ Model Base จะเป็นการประมาณค่าความผิดพลาดที่เกิดขึ้น (Fault Estimation) หรือค่าความผิดพลาดที่สามารถปรับปรุงกระบวนการเพื่อให้ค่าดังกล่าวน้อยลง (Residual) และ Non-Model Base คือ การตรวจสอบสภาพของเครื่องจักรว่ามีลักษณะการทำงานเช่นไร (Condition Monitoring) อีกหนึ่งประเภทที่น่าสนใจคือ Intelligence FDI ซึ่งเป็นการตรวจจับความผิดพลาดแบบชาญฉลาด เครื่องจักรจะสามารถทำความเข้าใจ เรียนรู้ และแก้ปัญหาต่าง ๆ ซึ่งมีความสามารถระดับเดียวกับมนุษย์ สามารถทำทุกอย่างที่มนุษย์ทำได้ และมีประสิทธิภาพใกล้เคียงกับมนุษย์ จะนำไปประยุกต์ใช้กับเครื่องจักรเพื่อให้ทำงานอย่างชาญฉลาด และเต็มไปด้วยประสิทธิภาพ แสดงการจำแนกระบบตรวจจับความเสียหาย และการระบุตำแหน่งความเสียหาย แสดงการจำแนกดังรูปที่ 2.13




รูปที่ 2.13 การจำแนกประเภทของ FDI

2.9 ปัญญาประดิษฐ์ Artificial Intelligence (AI)

Artificial Intelligence หรือปัญญาประดิษฐ์เป็นศาสตร์แขนงหนึ่งของวิทยาศาสตร์ และคอมพิวเตอร์ที่มีกลไกที่เกี่ยวข้องกับความคิดมนุษย์ เช่น การรับรู้ การเรียนรู้ การให้เหตุผล และการแก้ปัญหาต่าง ๆ ซึ่งเครื่องจักร (machine) ที่มีฟังก์ชันที่มีความสามารถในการทำความเข้าใจ เรียนรู้ องค์ความรู้ต่าง ๆ เครื่องจักรที่มีความสามารถเหล่านี้ก็ถือว่าเป็นปัญญาประดิษฐ์ ซึ่ง AI ก็ถูกแบ่งออกเป็นหลายระดับตามความสามารถหรือความฉลาด โดยจะวัดจากความสามารถในการ ให้เหตุผล การพูด และทัศนคติของ AI ตัวนั้น ๆ เมื่อเปรียบเทียบกับมนุษย์ แสดงองค์ประกอบของปัญญาประดิษฐ์ดังรูปที่ 2.14 ชนิดของปัญญาประดิษฐ์ (AI) ถูกแบ่งออกเป็น 3 ประเภท ได้แก่

1. ปัญญาประดิษฐ์ (Artificial Intelligence)

2. การเรียนรู้ของเครื่อง (Machine learning)
3. การเรียนรู้เชิงลึก (Deep Learning)



รูปที่ 2.14 องค์ประกอบของปัญญาประดิษฐ์

AI ถูกจำแนกเป็น 3 ระดับตามความสามารถหรือความฉลาด ดังนี้

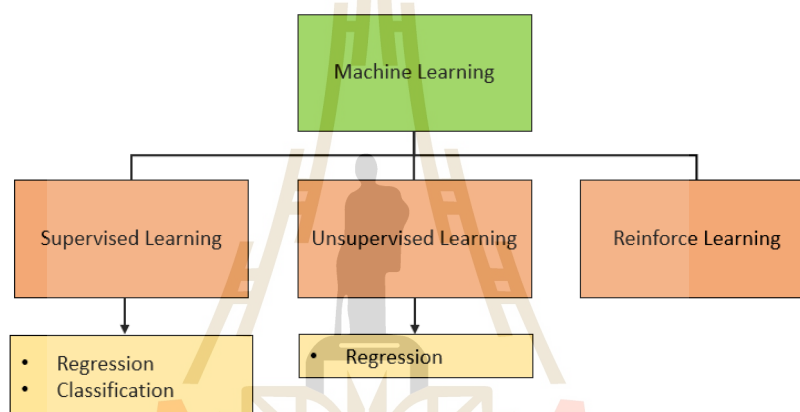
1. ปัญญาประดิษฐ์เชิงแคบ (Narrow AI) คือ AI ที่มีความสามารถเฉพาะทางได้ดีกว่ามนุษย์
2. ปัญญาประดิษฐ์ทั่วไป (General AI) คือ AI ที่มีความสามารถระดับเดียวกับมนุษย์ สามารถทำทุก ๆ อย่างที่มนุษย์ทำได้และได้ประสิทธิภาพที่ใกล้เคียงกับมนุษย์
3. ปัญญาประดิษฐ์แบบเข้ม (Strong AI) คือ AI ที่มีความสามารถเหนือมนุษย์ในหลาย ๆ ด้าน พัฒนาให้เครื่องจักรสามารถเรียนรู้และทำนายองค์ความรู้ได้ สามารถจำลองการทำงานต่าง ๆ เลียนแบบพฤติกรรมของมนุษย์ได้ โดยเน้นแนวคิดตามแบบสมองมนุษย์ที่มีการวางแผนการเรียนรู้ การให้เหตุผล การตัดสินใจ การแก้ปัญหา ตลอดจนการเลือกแนวทาง ดำเนินการในลักษณะคล้ายมนุษย์

2.10 การเรียนรู้ของเครื่องจักร (Machine Learning)

Machine Learning ถูกพัฒนาประกอบกันจากหลายศาสตร์หลายแขนง อาทิเช่น วิทยาศาสตร์ คณิตศาสตร์ สถิติ ความน่าจะเป็น และ คอมพิวเตอร์ ที่มีเทคนิคที่ถูกใช้ร่วมกัน “Mathematical Optimization Problem” ซึ่งเป็นหัวใจหลักอย่างหนึ่งของ Machine Learning เป็นการทำให้ระบบคอมพิวเตอร์เรียนรู้ได้ด้วยตนเองโดยใช้ข้อมูล ศึกษาวิธีการคิด (Algorithm) ที่ใช้ในการ

เรียนรู้ (Learn) และวิเคราะห์ข้อมูลจากตัวอย่างและประสบการณ์ แล้วทำการคาดการณ์หรือประเมินผล โดยมีพื้นฐานหลักการที่มีรูปแบบที่สามารถบ่งบอกได้ว่าสิ่งนั้น ๆ คืออะไร เพื่อนำไปประยุกต์ใช้ในการทำนายถึงความเป็นไปได้ในอนาคต การใช้ข้อมูลสามารถใช้ได้หลายแบบ แสดงประเภทการเรียนรู้ของเครื่องจักรดังรูปที่ 2.15 ซึ่งแบ่งตามประเภทของ Machine Learning ได้ 3 แบบดังนี้

1. Supervised Learning เรียนรู้โดยมีข้อมูลมาสอน
2. Unsupervised Learning เรียนรู้โดยไม่มีข้อมูลสอน
3. Reinforcement Learning เรียนรู้ตามสภาพแวดล้อม







รูปที่ 2.15 ประเภทการเรียนรู้ของเครื่องจักร

2.10.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

รูปที่ 2.16 แสดงการเรียนรู้แบบมีผู้สอนคือ มีการเรียนรู้โดยมีการบอกโมเดลว่าคำตอบที่ถูกต้องคืออะไร แล้วให้โมเดลพยายามเรียนรู้ที่จะตอบให้ถูก เช่น สร้าง Model ที่จะทำให้คอมพิวเตอร์รู้จักแอปเปิ้ลและกล้วยเข้าไปเป็นข้อมูลเข้า (input) โดยนำเอาคุณลักษณะข้อมูลของแอปเปิ้ลและกล้วยใส่เข้าไป เช่น ใสีเขียว ใสีส้ม ลักษณะของแต่ละอย่างเข้าไป โดยแปลงให้เป็นภาษาคอมพิวเตอร์ก่อน หรือเป็นข้อมูลที่เป็นตัวเลขนั่นเอง (เรียกว่า feature) พร้อมให้คำตอบว่านี่คือแอปเปิ้ลและกล้วย ซึ่งมีลักษณะ feature หรือข้อมูลที่แตกต่างกัน โดยใส่ข้อมูลเป็นตัวเลข (เรียกว่า labels) และนำภาพแอปเปิ้ลใส่เข้าไปพร้อมเฉลยว่านี่คือแอปเปิ้ล เมื่อใส่ Input เสร็จแล้ว ทำการเรียนรู้ข้อมูลโดยการฝึกสอน (Training) เพื่อให้คอมพิวเตอร์สามารถแยกแยะแอปเปิ้ลและกล้วยได้


ตาม features แต่วิธีการนี้มีข้อเสียคือ จำเป็นที่จะต้องเตรียมข้อมูลเหล่านี้เอาไว้ในปริมาณมากเพื่อให้มีข้อมูลที่สามารถเรียนรู้ได้มากพอที่จะทำนายผลลัพธ์ได้อย่างถูกต้อง

	Features	Labels
 <div style="border: 1px solid red; padding: 2px; display: inline-block;">Apple</div>	$X_1 = (57,186,255,102,...)$	$y_1 = 1$
 <div style="border: 1px solid red; padding: 2px; display: inline-block;">Apple</div>	$X_2 = (43,112,244,115,...)$	$y_2 = 1$
 <div style="border: 1px solid yellow; padding: 2px; display: inline-block;">Banana</div>	$X_3 = (196,40,215,5,...)$	$y_3 = -1$
 <div style="border: 1px solid gray; padding: 2px; display: inline-block;">???</div>	$X_4 = (77,143,205,...)$	$y_4 = f(x_4) = 1$

รูปที่ 2.16 แสดงการเรียนรู้แบบมีผู้สอน (Supervised Learning)

2.10.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

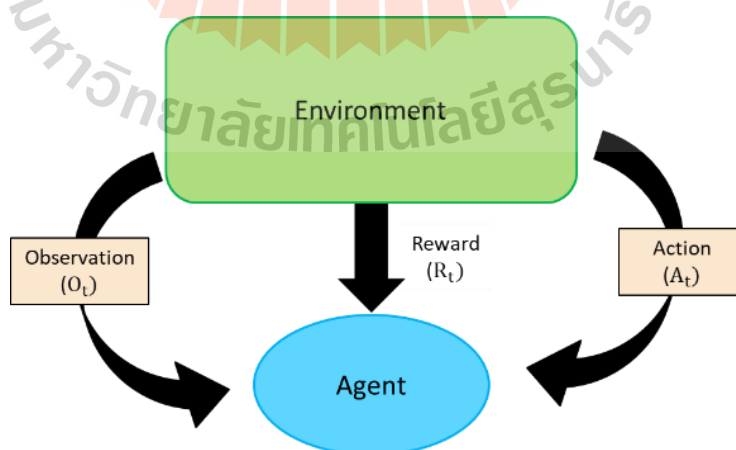
รูปที่ 2.17 แสดงการเรียนรู้แบบไม่มีผู้สอนคือ ไม่ต้องมีการเตรียมคำตอบที่ถูกต้องมาให้โมเดล เพราะมันจะทำการเรียนรู้จากรูปแบบของข้อมูลเอง ว่าข้อมูลแบบไหนคล้ายกัน อยู่ใกล้กัน แต่วิธีนี้มีปัญหาในเรื่องของประสิทธิภาพและการนำไปใช้จริง เช่น ในบางครั้งเราไม่รู้ว่สิ่งที่โมเดลมันแบ่งออกมา มันแบ่งด้วยอะไรกันแน่ ซึ่งเป็นการเรียนรู้แบบที่ให้ Input ผ่านเข้าไปในโมเดล เพื่อสร้าง Output ที่หน้าตาเหมือนกับ Input แล้วนำเอาคุณสมบัติตรงกลางของโมเดลมาใช้



รูปที่ 2.17 แสดงการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

2.10.3 การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning)


คือข้อมูลที่ใช้สอนบางส่วนมีการบอกว่า Output ควรเป็นอย่างไร และข้อมูลบางส่วนไม่มีการบอกคำตอบที่ถูกต้อง โดยจะให้ข้อมูลเรียนรู้จากสภาพแวดล้อม กล่าวคือ ถ้าโมเดลสามารถทำนายถูก ประสิทธิภาพก็จะสูงขึ้น ถ้าหากโมเดลมีการทำนายที่ผิดพลาด มันจะสามารถเรียนรู้จากข้อมูลที่ผิดพลาด เพื่อให้ครั้งต่อไปสามารถทำนายผลลัพธ์ออกมาได้อย่างถูกต้องแสดงดังรูปที่ 2.18



รูปที่ 2.18 แสดงการเรียนรู้แบบเสริมกำลัง (Reinforcement Learning)

2.11 โครงข่ายประสาทเทียมนิวรอลเน็ตเวิร์ก Artificial Neural Networks (ANN)

โครงข่ายประสาทเทียม (Artificial Neural Networks) คือ โมเดลทางคณิตศาสตร์สำหรับประมวลผลสารสนเทศด้วยการคำนวณแบบคอนเนกชันนิสต์ (Connectionist) เพื่อจำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ เพื่อที่จะสร้างความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการสร้างความรู้ใหม่ (Knowledge Extraction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาโครงข่ายไฟฟ้าชีวภาพ (Bioelectric Network) ในสมอง การที่จะสามารถเข้าใจสิ่งต่าง ๆ ได้จำเป็นต้องมี Dendrite เป็น Accept Input จากนั้นจะประเมินชุดข้อมูลด้วย Soma เป็น Hidden Layer และ Axon จะทำหน้าที่แปลงข้อมูลให้ได้ผลลัพธ์ที่ต้องการ และแสดงผลด้วย Synapses เป็น Output Layer ซึ่งเป็นการเลียนแบบระบบเซลล์ประสาทในสมองของมนุษย์ (neural Network) ให้คอมพิวเตอร์รู้จักคิด เรียนรู้ และจดจำ โดยจำลองการทำงานเหมือนกับกลุ่มเซลล์ประสาทที่เชื่อมโยงกันเป็นระบบประสาทที่สามารถรับรู้หลาย ๆ สิ่งในเวลาเดียวกัน แสดงให้เห็นดังรูปที่ 2.19




รูปที่ 2.19 การเรียนรู้ของโครงข่ายประสาทเทียม

2.11.1 ส่วนประกอบของนิวรอลเน็ตเวิร์ก (Neural Network)

1. Input Layer ที่ชั้นนี้จะเป็นข้อมูล input ซึ่งจำนวนของ โหนดขึ้นอยู่กับจำนวนของ input ว่ามีข้อมูลอะไรบ้างที่นำเข้ามาคิดในโมเดล เช่น ถ้าข้อมูลของลูกค้าเป็น input ซึ่งประกอบด้วย อายุ เพศ จังหวัดที่อาศัย รวมทั้งสิ้น 4 อย่าง input layer ก็จะมี 4 โหนด (ปกติแล้วใน Machine Learning เราจะเรียกปัจจัยที่นำมาวิเคราะห์เหล่านี้ว่า feature)

2. Hidden Layer เป็นชั้นที่อยู่ระหว่างกลาง ซึ่งจะมีผลอย่างมากต่อประสิทธิภาพในการเรียนรู้ของโมเดล ซึ่ง hidden layer นั้นจะมีกี่ชั้นก็ได้ แล้วแต่ผู้สร้างโมเดล โดยแต่ละชั้นจะมีจำนวนของ Neuron เท่าไหร่ก็ได้เช่นกัน ซึ่งการเพิ่มชั้นและจำนวน neuron ก็จะส่งผลต่อการทำงานของโมเดล ในส่วนของ hidden layer มีการทำงานเปรียบเสมือนส่วนที่เรียนรู้ข้อมูลเชิงลึก หรือ deep learning


3. Output Layer ชั้นที่เราจะนำเอาข้อมูลจากการคำนวณไปใช้ จำนวนของ โหนดในชั้นนี้ ขึ้นอยู่กับรูปแบบของ output ที่จะนำไปใช้ เช่น ถ้างานที่ทำเป็น Regression โดยกำหนดให้ output layer เป็นแบบ 1 โหนด เพราะต้องการคำตอบค่าเดียว ถ้าเป็นหลายค่าก็เพิ่มไปตามที่ต้องการ เช่น อาจจะ predict หาดำแหน่งของภาพในแกน x และ y พร้อม ๆ กัน ในกรณีนี้ต้องใส่ output layer เป็น 2 โหนด เป็นต้น



รูปที่ 2.20 แสดงโครงสร้างของโครงข่ายประสาทเทียม

2.11.2 องค์ประกอบของโครงข่ายประสาทเทียม

1. ข้อมูลป้อนเข้า (input) เป็นข้อมูลที่เป็นตัวเลข หากเป็นข้อมูลเชิงคุณภาพต้องแปลงให้อยู่ในรูปเชิงปริมาณที่โครงข่ายประสาทเทียมยอมรับได้
2. ข้อมูลส่งออก (output) คือ ผลลัพธ์ที่เกิดขึ้นจริง (actual output) จากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม
3. ค่าน้ำหนัก (Weight) คือสิ่งที่ได้จากการเรียนรู้ของโครงข่ายประสาทเทียม หรือเรียกอีกอย่างหนึ่งว่า ความรู้ (Knowledge) ค่านี้อาจถูกเก็บเป็นทักษะเพื่อใช้ในการจดจำข้อมูลอื่น ๆ ที่อยู่ในรูปแบบเดียวกัน
4. ฟังก์ชันผลรวม (Summation function : S) เป็นผลรวมของข้อมูลป้อนเข้า โดยจะนำอินพุตคูณกับค่าน้ำหนักของแต่ละขา ผลที่ได้จากอินพุตทุก ๆ ขาของ neuron จะเอมารวมกัน
5. ฟังก์ชันการแปลง (Transfer function) เป็นการคำนวณการจำลองการทำงาน ของโครงข่ายประสาทเทียม ซึ่ง activation function ที่นิยมนำมาใช้คือ ซิกมอยด์ฟังก์ชัน (Sigmoid function) ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic tangent function) และ Rectified Linear Unit (ReLU) แสดงให้เห็นในรูปที่ 2.21




รูปที่ 2.21 Activation Function

2.11.3 หลักการทำงาน

2.11.3.1 โครงข่ายการส่งข้อมูลไปข้างหน้า (Feed forward network)

การทำงานของ Neural Networks คือเมื่อมี input เข้ามายัง network ก็เอา input มาคูณกับ weight ของแต่ละขา ผลที่ได้จาก input ทุก ๆ ขาของ neuron จะเอมารวมกันแล้วก็เอามาเทียบกับ threshold ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า threshold แล้ว neuron ก็จะส่ง output ออกไป output นี้ก็จะถูกส่งไปยัง input ของ neuron อื่น ๆ ที่เชื่อมกันใน network ถ้าค่าน้อยกว่า threshold ก็จะไม่เกิด output สิ่งสำคัญคือเราต้องทราบค่า weight และ threshold สำหรับสิ่งที่เราต้องการเพื่อให้

คอมพิวเตอร์รู้จำ ซึ่งเป็นค่าที่ไม่แน่นอน แต่สามารถกำหนดให้คอมพิวเตอร์ปรับค่าเหล่านั้นได้โดยการสอนให้มันรู้จัก pattern ของสิ่งที่เราต้องการให้มันรู้จำ ซึ่งปกติ Neural Network จะเรียกว่า Feed Forward คือการไปข้างหน้า กล่าวคือ Neural Network จะรับข้อมูลจาก Input Layer สร้างน้ำหนัก (W) แล้วประมวลผลผ่าน Hidden Layer แล้วออกที่ Output เลย แสดงดังรูปที่ 2.22



รูปที่ 2.22 แบบจำลองโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า

โดยที่การใช้ในการหาค่าเอาต์พุตสามารถคำนวณได้จากสมการที่ 5

$$y = f(Wx + b) \quad (5)$$

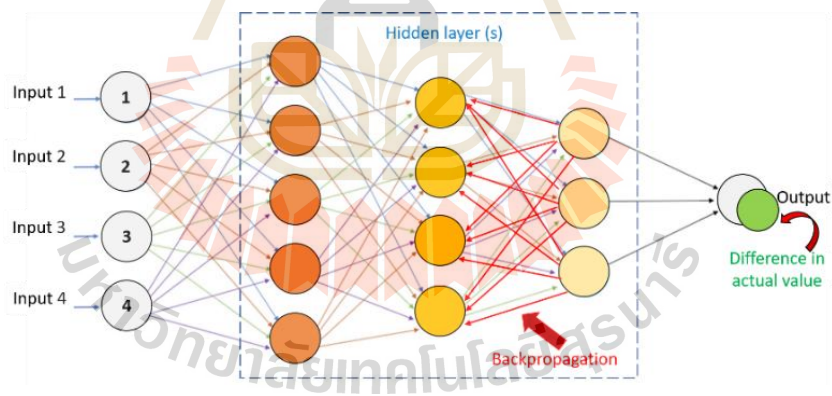
โดยที่ $x^T = [x_1 \ x_2 \ \dots \ x_s]$ คือเมทริกซ์อินพุต

$$b^T = [b_1 \ b_2 \ \dots \ b_R] \quad \text{คือเมทริกซ์ไบอัส}$$

$$W = \begin{pmatrix} W_{11} & \dots & W_{1R} \\ \vdots & \ddots & \vdots \\ W_{S1} & \dots & W_{SR} \end{pmatrix} \quad \text{คือเมทริกซ์ค่าถ่วงน้ำหนัก}$$

2.11.3.2 โครงข่ายการส่งข้อมูลย้อนกลับ (Back-propagation network)

การทำงานของ Neural Networks คือเมื่อมี input เข้ามายัง network ก็เอา input มาคูณกับ weight ของแต่ละขา ผลที่ได้จาก input ทุก ๆ ขาของ neuron จะเอามารวมกันแล้วก็เอามาเทียบกับ threshold ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า threshold แล้ว neuron ก็จะส่ง output ออกไป output นี้ก็จะถูกส่งไปยัง input ของ neuron อื่น ๆ ที่เชื่อมกันใน network ซึ่งเป็นกระบวนการย้อนกลับของการรู้จำในการฝึก feed-forward Neural Networks แต่ถ้าหากให้มันย้อนกลับจาก output กลับมาที่ input จะเรียกว่า "back propagation" จะมีการใช้อัลกอริทึมแบบ back-propagation เพื่อใช้ในการปรับปรุงน้ำหนักคะแนนของเครือข่าย (Network Weight) หลังจากใส่รูปแบบข้อมูลสำหรับฝึกให้แก่เครือข่ายในแต่ละครั้งแล้ว ค่าที่ได้รับ (output) จากเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวัง แล้วทำการคำนวณหาค่าความผิดพลาด (Error Estimation) ซึ่งค่าความผิดพลาดนี้จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้แก้ไขค่าน้ำหนักคะแนนต่อไป โครงข่ายประสาทเทียมที่มีการสร้างโมเดลแบบการส่งข้อมูลย้อนกลับคือจะมีการนำค่าความผิดพลาดของเอาต์พุตของโมเดลกับเอาต์พุตจริงย้อนกลับเพื่อทำการปรับค่าถ่วงน้ำหนักใหม่เพื่อให้โมเดลเกิดความผิดพลาดน้อยที่สุด แสดงให้เห็นดังรูปที่ 2.23



รูปที่ 2.23 แบบจำลองโครงข่ายประสาทเทียมแบบย้อนกลับ

ซึ่งสมการค่าความผิดพลาดของการสร้างโมเดลสามารถหาในรูปแบบของค่าเฉลี่ยกำลังสอง (Mean Square Error, MSE) โดยที่ Y_{target} คือ ค่าผลลัพธ์ที่สอนให้โมเดลเรียนรู้และ Y_{output} คือ ค่าผลลัพธ์ที่โมเดลทำนายออกมา ดังสมการที่ 6 ดังนี้

$$Error = \frac{1}{2} (y_{target} - y_{output})^2 \quad (6)$$

2.11.3.3 การเรียนรู้สำหรับโครงข่ายประสาทเทียม

1. การเรียนรู้แบบมีการสอน (Supervised Learning)


เป็นการเรียนแบบที่มีการเตรียมคำตอบเพื่อให้โครงข่ายประสาทเทียมรับรู้ ชุดข้อมูลที่ใช้สอนโครงข่ายประสาทเทียมจะมีคำตอบไว้คอยตรวจดูว่าโครงข่ายประสาทเทียมให้คำตอบที่ถูกต้องหรือไม่ ถ้าตอบไม่ถูก โครงข่ายประสาทเทียมก็จะปรับตัวเองเพื่อให้ได้คำตอบที่ดีขึ้น

2. การเรียนรู้แบบไม่มีการสอน (Unsupervised Learning)

เป็นการเรียนแบบไม่มีผู้สอน ไม่มีการเตรียมคำตอบไว้ว่าถูกหรือผิด โครงข่ายประสาทเทียมจะจัดเรียงโครงสร้างด้วยตัวเองตามลักษณะของข้อมูล ผลลัพธ์ที่ได้โครงข่ายประสาทเทียมจะสามารถจัดหมวดหมู่ของข้อมูลได้

2.12 การเรียนรู้เชิงลึก (Deep Learning)


การสร้างโมเดลจะเป็นลักษณะการส่งข้อมูลของอินพุตไปเอาต์พุต หากโครงสร้างมีจำนวนชั้นซ่อน (Hidden layer) เพียง 1 ชั้นจะเรียกว่า โครงข่ายประสาทเทียมแบบง่าย (Single Layer Perceptron Network) แต่หากมีชั้นซ่อนมากกว่า 1 ชั้นจะเรียกว่า โครงข่ายประสาทเทียมแบบซับซ้อน (Multi-Layer Perceptron Network) หรือเรียกว่า Deep Learning แสดงให้เห็นดังรูปที่ 2.24 Artificial Neural Network (ANN) ที่มีจำนวน hidden layer หลายชั้น เพื่อให้มีความสามารถในการคิดที่มากกว่าปกติ สามารถแยกแยะสิ่งต่าง ๆ ได้อย่างแม่นยำมากยิ่งขึ้น เป็นกระบวนการที่ทำนายผลลัพธ์จากข้อมูลนำเข้า (input) โดยใช้การเรียนรู้แบบมีการสอน (Supervised) หรือการเรียนรู้แบบไม่มีการสอน (Unsupervised) นอกจากนี้ Artificial Neural Network (ANN) ที่สามารถใช้ในการพยากรณ์หรือการจำแนกได้แล้ว ยังถูกเอาไปพัฒนาต่อยอดเป็น Deep Neural Network (DNN), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN)



รูปที่ 2.24 แสดงลักษณะโครงสร้างของโครงข่ายประสาทเทียม

2.13 แบบจำลองโครงข่ายประสาทเทียมคอนโวลูชัน Convolution Neural Network (CNN)

Convolutional Neural Network (CNN) หรือ โครงข่ายประสาทแบบคอนโวลูชัน เป็นโครงข่ายประสาทเทียมหนึ่งในกลุ่ม bio-inspired โดยที่ CNN จะจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นที่ย่อย ๆ และนำกลุ่มของพื้นที่ย่อย ๆ มาพหุกัน โดย CNN ประสบความสำเร็จในการแก้ปัญหาการจำแนกที่เกี่ยวข้องกับรูปภาพ ซึ่งในปัจจุบันมีการนำแนวคิดไปใช้ต่อยอดในด้านต่าง ๆ อย่างมากมาย แต่ก็ยังมีข้อเสียที่ต้องพึ่งมนุษย์ในการออกแบบ architecture ของ Neural Network ในการแก้ปัญหาใดปัญหาหนึ่ง ซึ่งจะดึงจุดเด่นของภาพนั้น ๆ ออกมาได้ เพื่อนำมาใช้เป็น feature ของพื้นที่ และ layer ในการสร้างอัลกอริทึมที่เน้นใช้กับรูปภาพ เพื่อนำมาจำแนก (Classification) ว่าเป็นกลุ่มของอะไร แสดงให้เห็นดังรูปที่ 2.25



รูปที่ 2.25 โครงสร้างของโครงข่ายประสาทแบบคอนโวลูชัน (CNN)

2.13.1 หลักการทำงาน

โดยหลักการทำงานของ Convolution ประกอบด้วย 6 ขั้นตอนดังนี้


1. Convolution stage

1.1 การดึงคุณลักษณะเด่น (Feature Extraction)

การคำนวณตามแนวคิดนี้ใช้หลักการเดียวกับคอนโวลูชันเชิงพื้นที่ (Spatial Convolution) ในการทำงานด้าน Image Processing โดยการคำนวณนี้จะเริ่มจากการกำหนดค่าในตัวกรอง (filter) หรือเคอร์เนล (kernel) ที่ช่วยดึงคุณลักษณะที่สำคัญในการรู้จำวัตถุออก โดยปกติตัวกรองอันหนึ่งจะดึงคุณลักษณะที่สนใจออกมาได้หนึ่งอย่าง ดังนั้นจึงจำเป็นต้องตัวกรองหลายตัวกรอง เพื่อหาคุณลักษณะทางพื้นที่หลายอย่างประกอบกัน

1.2 ลักษณะของ Filter

ในภาพดิจิทัลตัวกรองจะเป็นตารางสองมิติที่มีขนาดตามพื้นที่ย่อย ๆ ที่อยากพิจารณา โดยใช้ตัวกรอง (filter) หรือ เคอร์เนล (kernel) ทาบลงในพิกเซลแรกของภาพข้อมูลเข้า จากนั้นจะถูกเลื่อนไป ทาบบนพิกเซลอื่นในภาพทีละพิกเซลจนครบทุกพิกเซลในภาพ เมื่อเลื่อนตัวกรองไปเรื่อย ๆ จน ครบทุกพิกเซลที่สามารถเลื่อนได้ในภาพแล้ว จะได้เป็นผังคุณลักษณะ (feature map) แสดงให้เห็น ดังรูปที่ 2.26




รูปที่ 2.26 ลักษณะตัวกรอง

(ภาพจาก <https://blog.datawow.io/>)

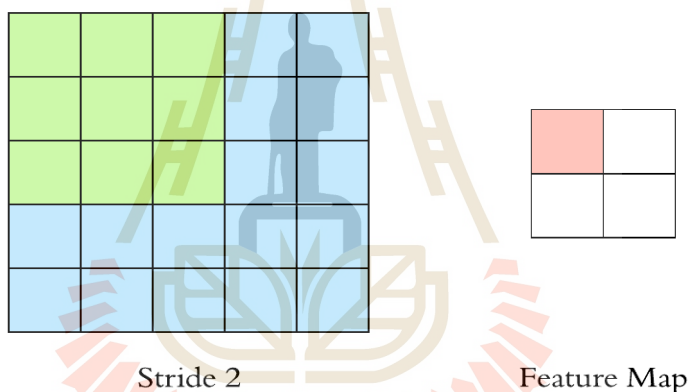
1.3 Stride

เป็นตัวกำหนดว่าจะเลื่อนตัวกรอง (filter) ไปด้วย Step เท่าไร (กำหนด Stride เท่ากับ 1) แสดงให้เห็นดังรูปที่ 2.27 และสามารถกำหนดค่าของ Stride ให้มากขึ้นได้ ถ้าต้องการให้การคำนวณหาคุณลักษณะมีพื้นที่ทับซ้อนกันน้อยขึ้น แต่ถ้ากำหนดค่าของ Stride ที่มากขึ้นจะทำให้เราได้ผังคุณลักษณะ (feature map) ที่มีขนาดเล็กลง แสดงให้เห็นดังรูปที่ 2.28



รูปที่ 2.27 กำหนดเลื่อนตัวกรองเท่ากับ 1

(ภาพจาก <https://blog.datawow.io/>)




รูปที่ 2.28 กำหนดเลื่อนตัวกรองเท่ากับ 2

(ภาพจาก <https://blog.datawow.io/>)

1.4 Padding

การทำ padding เพื่อแก้ปัญหาที่ Input ที่อยู่ตามขอบภาพ ซึ่งอาจมีความสำคัญที่ส่งผลต่อการตัดสินใจบางอย่าง ดังนั้นจึงจำเป็นต้องเก็บคุณลักษณะตามขอบของรูปภาพไว้ด้วย จากรูปที่ 2.29 จะเห็นว่าพื้นที่สีเทาขอบ ๆ Input พื้นที่เหล่านี้เป็นพื้นที่ที่เติมเข้าไป โดยอาจจะเป็นเติม 0 หรือค่าต่าง ๆ เข้าไป เพื่อให้เวลาในการทำ CNN นั้น ยังคงได้ Feature Map ที่มีขนาดเท่ากับ Input



รูปที่ 2.29 การทำ padding

(ภาพจาก <https://blog.datawov.io/>)

2. Detector stage

ทำหน้าที่รับข้อมูล output จากการทำ convolution stage แล้วแปลงให้อยู่ในรูปของ nonlinear โดยใช้ activation อย่างเช่น Rectified Linear Units (ReLU) เพื่อความง่ายในการคำนวณและประสิทธิภาพของผลลัพธ์ของโมเดล

3. Pooling

รูปภาพมีขนาดสเกลที่เล็กลง แต่ก็ยังสามารถมองออกว่ามันคืออะไร แสดงว่าการจำแนกวัตถุชิ้นนี้ที่มีความละเอียดต่ำลง แต่ทำให้ CNN มีความละเอียดสูงขึ้นแสดงให้เห็นดังรูปที่ 2.30



รูปที่ 2.30 การทำ Pooling

ดังนั้นถ้าโครงข่ายควรจะต้องมีการย่อรูป เพื่อให้สามารถเข้าถึงความสามารถด้านการวิเคราะห์ที่หลากหลายความละเอียดได้ โดย Pooling คือความสามารถในการย่อรูปแบบหนึ่ง ซึ่งมี 2 ประเภทคือ max


pooling และ average pooling ซึ่งจะนิยมเรียกกันว่า pool size คือ ค่าคุณลักษณะที่เด่นที่สุดจะถูกเก็บไว้จำนวนต่อ โดยที่รายละเอียดของ input ยังครบถ้วนเหมือนเดิม แต่อาจได้ output ที่ได้จะมีขนาดเล็กลง ซึ่งขึ้นอยู่กับ stride ที่กำหนด สามารถประมวลผลได้รวดเร็วขึ้น และแก้ปัญหา overfitting ได้ ดังรูปที่ 2.31

3.1 Max Pooling

เป็นตัวกรองแบบหนึ่งที่ทำค่าสูงสุดในบริเวณที่ตัวกรองทาอยู่มาเป็นผลลัพธ์ โดยจะต้องเตรียมตัวกรองในลักษณะเดียวกับการทำ Feature Extraction ของ CNN มาทาบนข้อมูลแล้วเลือกค่าที่สูงที่สุดบนตัวกรองนั้นมาเป็นผลลัพธ์ใหม่ และจะเลื่อนตัวกรองไปตาม Stride ที่กำหนด

3.2 Mean Pooling

เป็นตัวกรองแบบหนึ่งที่ทำค่าเฉลี่ยในบริเวณที่ตัวกรองทาอยู่มาเป็นผลลัพธ์ โดยจะต้องเตรียมตัวกรองในลักษณะเดียวกับการทำ Feature Extraction ของ CNN มาทาบนข้อมูลแล้วนำค่าเฉลี่ยของตัวกรองนั้นมาเป็นผลลัพธ์ใหม่ และจะเลื่อนตัวกรองไปตาม Stride ที่กำหนด



รูปที่ 2.31 การทำ Max pooling และ Mean pooling

4. Flatten

การนำข้อมูลของ pool size ที่ได้แบบ 3 มิติมาแปลงให้เป็น 1 มิติ (คอลัมน์เดียว) เพื่อเตรียมไว้สำหรับเป็น input ที่ป้อนเข้าไปในโครงข่ายประสาทเทียมในรูปแบบของ Artificial Neural Network (ANN) ที่จะมีส่วนประกอบเป็น Input layer, Hidden layer และ Output layer

5. Fully connected

หลังจากการทำ Flatten แล้ว นำข้อมูลที่ได้มาสร้างเป็น Multi-layer perceptron ก็จะมีการเชื่อมต่อ โดยมี Hidden layer หลายชั้น แต่ละโหนดจะมีการเชื่อมต่อกัน อาจจะมีการใช้ dropout เพื่อเพิ่มประสิทธิภาพในการ train จากนั้นถึงส่งออกไปยัง output layer

6. Classification

ในขั้นตอนนี้จะเป็นการจำแนกหรือจัดกลุ่มหลังจากผ่านกระบวนการต่าง ๆ โดยจะใช้ Softmax activation ในการวิเคราะห์ข้อมูล เพื่อที่จะจำแนกว่า output คืออะไรกันแน่

2.14 ปรัชญ่วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

2.14.1 งานวิจัยเกี่ยวกับระบบสุญญากาศ

ในปีค.ศ. 2019 Ahn และคณะ ได้นำเสนอการวินิจฉัยการรั่วไหลของการตรวจจับ ล้วงหน้าอย่างมีประสิทธิภาพสำหรับระบบท่อ เมื่อมีการแลกเปลี่ยนความร้อนและรอยแตกของท่อ พิจารณาจากสัญญาณและคุณสมบัติเด่นที่ได้สกัดจากข้อมูล เพื่อนำไปประเมินประสิทธิภาพการ จำแนกประเภทสำหรับการตรวจสอบ และพิจารณาสภาพของท่อด้วยปัญญาประดิษฐ์ที่เป็นการ เรียนรู้ของเครื่องจักร โดยการเปรียบเทียบระหว่าง GA และ principal component analysis (PCA) สำหรับการจำแนกคุณลักษณะ โดยใช้ SVM

ในปี ค.ศ 2017 Yokomichi และคณะ ได้ทำการศึกษาการตรวจสอบการรั่วของ สุญญากาศที่เกิดการขัดข้อง (VI) ที่มีการปล่อยออกบางส่วน (PD) ขณะทำงานโดยประยุกต์การ ตรวจวัดคิซาร์จด้วยเซนเซอร์ที่แตกต่างกันแต่ละจุด เพื่อเปรียบเทียบ Sensitivity ของ PD ภายใน VI โดยวิเคราะห์จากสัญญาณที่ตอบสนองและขนาดของคลื่นสัญญาณที่เกิดขึ้น การตรวจจับด้วย เซนเซอร์สามารถสังเกตลักษณะการรั่วที่ขนาดแตกต่างกันได้และสามารถนำไปใช้งานกับ แรงดันไฟฟ้าและแรงดันสุญญากาศ ได้

ในปี ค.ศ 2009 Krysander และคณะ ได้ทำการศึกษาการเสื่อมสลายของสุญญากาศ จึงทำการตรวจจับการระเหยของสุญญากาศ โดยการใช้เซ็นเซอร์ไปติดที่ถังเชื้อเพลิงเพื่อตรวจจับการ รั่วขนาดเล็กภายใต้สภาวะการทำงานที่แตกต่างกัน ดำเนินการทดสอบการตรวจจับการรั่วของ สุญญากาศเมื่อมีแรงดันต่ำในถังเชื้อเพลิงโดยขณะเปิดและปิดวาล์วในอุณหภูมิและแรงดันที่พิจารณา คือ 3KPa ใช้เวลาทดสอบประมาณ 10 วินาที ผลการทดสอบคือ สามารถตรวจจับโดยใช้เวลาน้อย กว่า 10 วินาที สำหรับการรั่วขนาด 0.5mm และใช้เวลา 5 วินาทีหรือน้อยกว่านี้ ถ้าเกิดการรั่วขนาด 1mm - 3.5mm ดังนั้นอัลกอริทึมนี้ประสบความสำเร็จในการตรวจจับการรั่วขนาดเล็กได้

ในปี ค.ศ 2016 Zhu และคณะ ได้ศึกษาการพยากรณ์การรั่วของวาล์ว ซึ่งเมื่อเกิดการรั่วของแก๊สออกสู่ภายนอกจะทำให้สูญเสียเงินทุน อีกทั้งยังส่งผลต่อสภาพแวดล้อมที่เป็นมลพิษ ดังนั้นจึงเสนอเทคโนโลยีอนุตติภูมิทัศน์ในการตรวจจับการรั่วที่ถูกนำมาใช้อย่างแพร่หลาย โดยนำปัญญาประดิษฐ์มาประยุกต์ใช้ในการตรวจจับอัตราการรั่วที่เกิดขึ้นด้วย support vector regression using linear (L-SVR), polynomial (P-SVR), Radial basis function (RBF-SVR) kernels และ regression-based deep belief network (DBN) เพื่อวิเคราะห์และเปรียบเทียบความสามารถในการพยากรณ์การรั่วของแก๊สที่เกิดขึ้น สรุปได้ว่า DBN มีค่าความถูกต้องในการพยากรณ์มากที่สุดคือ 0.98%

ในปี ค.ศ 2011 Preusche และคณะ ได้ทำการศึกษาวิธีการที่ใช้ข้อมูลสำหรับการตรวจสอบการรั่วไหลของอากาศเข้าสู่กระบวนการ สาเหตุจากการรั่วไหลของอากาศจะมีผลกระทบต่อต้นทุน ถึงเวลาจะมองว่าการรั่วอาจจะเป็นปัญหาเล็ก ๆ แต่มันกลับกลายเป็นส่งผลกระทบต่อประสิทธิภาพในกระบวนการอย่างมาก ดังนั้นจึงตรวจจับและระบุตำแหน่งที่เกิดการรั่ว เพื่อทำการบำรุงรักษาในขั้นตอนต่อไป โดยรวบรวมข้อมูลเพื่อเข้าสู่กระบวนการวิเคราะห์ด้วยหลักการ PCA เพื่อหาแบบจำลองที่เหมาะสม ตัวแปรที่ได้จากการวิเคราะห์ด้วย PCA พบว่าช่วยให้ตรวจสอบในกระบวนการได้ดีสำหรับการตรวจจับและการระบุตำแหน่งที่เกิดการรั่วขึ้น

2.14.2 งานวิจัยเกี่ยวกับระบบตรวจจับความผิดพลาด

ในปี ค.ศ 2009 Puig Cayuela และคณะ ได้ทำการศึกษาของกนของการตรวจจับและระบุตำแหน่งข้อบกพร่องและการคงทนต่อความเสียหาย วิธีการเหล่านี้มีจุดประสงค์เพื่อเช็คความมั่นคงของระบบระหว่างการผลิตและการพยากรณ์พฤติกรรม โดยใช้การประมาณค่าที่ใกล้เคียงกับระบบ ซึ่งเป็นอีกหนึ่งทางเลือกที่น่าเชื่อถือความน่าจะเป็นมาประยุกต์ใช้ เมื่อเกิดความผิดปกติขึ้นสามารถตรวจจับข้อบกพร่องและระบุข้อบกพร่องที่เกิดขึ้นได้ เพื่อพัฒนาระบบให้คงทนต่อความเสียหาย

ในปี ค.ศ 2018 Hajihosseini และคณะ ได้ทำการศึกษาการตรวจจับและระบุตำแหน่งความผิดพลาดในกระบวนการ Tennessee Eastman โดยใช้เทคนิคการประมวลผลภาพ ซึ่งเป็นที่นิยมนำมาประยุกต์ใช้ในอุตสาหกรรมจำนวนมาก เพื่อป้องกันการเกิดความเสียหายของอุปกรณ์ต่าง ๆ ที่ทำให้เกิดความผิดปกติขณะดำเนินงาน โดยจะใช้สัญญาณจากเซ็นเซอร์มาแปลงเป็นรูปภาพเพื่อใช้ในการตรวจจับ ซึ่งแต่ละสัญญาณที่ได้มาก็จะมีลักษณะที่แตกต่างกันไป เช่น ลักษณะคลื่น, ความแปรปรวน ค่าเฉลี่ย เป็นต้น โดยจะใช้ MLP และ RBF เป็นตัวจำแนกในการ

ตรวจจับและระบุตำแหน่งที่ผิดพลาดในกระบวนการ พบว่ามีความถูกต้องในการช่วยตรวจจับความผิดปกติที่เกิดขึ้นได้ดี

2.14.3 งานวิจัยเกี่ยวกับโครงข่ายประสาทเทียม

ในปี ค.ศ 2017 Widyarto และคณะ ได้ทำการศึกษาการตรวจจับพื้นผิวไม้ด้วยคอนจูเกตเกรเดียนนิวโรลเน็ตเวิร์กโดยการทดลองนี้จะพัฒนาอัลกอริทึมให้มีความสามารถในการตรวจจับที่ถูกต้องมากที่สุด โดยจะใช้โครงข่ายประสาทเทียม Artificial Neural Network (ANN) แบบ Backpropagation และ conjugate gradient ในกระบวนการฝึกสอน โมเดล ขั้นตอนทดสอบแบ่งเป็น 3 ส่วนคือ 1. นำภาพจำนวน 56 ภาพ ขนาด 146x84 ที่ได้ไปทำการตัดป้ายชื่อเพื่อจำแนกหรือระบุพื้นผิวแล้วให้โมเดลได้เรียนรู้ 2. เมื่อโมเดลเรียนรู้แล้วให้มันปรับปรุงโมเดลจากความผิดพลาด 3. นำภาพมาแบ่งเป็นส่วน ๆ เพื่อปรับปรุงในกระบวนการให้มีความถูกต้องในการพยากรณ์ ผลการทดสอบของวิธีการนี้ สามารถพัฒนาความถูกต้องในการตรวจจับได้ 96.43% โดยใช้ Learning 0.2 จำนวน Hidden layer 200 และจำนวนรอบ (Epoch) ในการฝึกสอน 100 รอบ การใช้จำนวน Hidden layer และ Epoch ที่เพิ่มมากขึ้น ยิ่งส่งผลให้มีค่าความถูกต้องที่เพิ่มขึ้น

ในปี ค.ศ 2018 Seongmin และคณะ ได้ทำการศึกษาตรวจสอบพิจารณากระบวนการที่สำคัญในระบบที่มีนัยสำคัญต่อการนำไปประยุกต์ใช้การเรียนรู้ของเครื่องจักร ซึ่งได้เสนอโครงข่ายประสาทเทียมนิวโรลเน็ตเวิร์กมาใช้ในการตรวจจับและจำแนกข้อบกพร่องเพื่อเพิ่มประสิทธิภาพให้ตัวมันเอง โดยเปรียบเทียบประสิทธิภาพของจำนวนชั้นซ่อน (Hidden layer) และวิธีการเพิ่มจำนวนข้อมูล *Data augmentation) พบว่าเมื่อมีการเพิ่มจำนวน Hidden layer ที่มากขึ้น จะทำให้มีความถูกต้องในการเรียนรู้การตรวจจับมากขึ้น อีกทั้งวิธีการเพิ่มจำนวนข้อมูลก็ทำให้มีค่าความถูกต้องเพิ่มขึ้นด้วยเช่นกัน

ในปี ค.ศ 2016 Aghdam และคณะ ได้ศึกษาการตรวจจับและจำแนกสัญญาณไฟจราจรโดยอัตโนมัติเป็นงานสำคัญในระบบอัจฉริยะและอัตโนมัติ ซึ่ง Convolutional Neural Networks ประสบความสำเร็จอย่างมากในการจำแนกสัญญาณจราจรและมีประสิทธิภาพที่สูง ซึ่งจะใช้ ConvNets เพื่อช่วยในการตรวจจับและจำแนก เพื่อช่วยเพิ่มความแม่นยำในการตรวจจับสัญญาณจราจรและเพิ่มประสิทธิภาพการตรวจจับแบบเรียลไทม์สามารถทำให้รวดเร็วและแม่นยำยิ่งขึ้น ความแม่นยำเฉลี่ยเท่ากับ 99.89% การใช้เวลาประมวลผลภาพความละเอียดสูง 37.72 ต่อวินาที และการจำแนกประเภทสามารถจำแนกได้ 99.55% ของตัวอย่างทดสอบ

ในปี ค.ศ 2017 Litjens, Geert, et al. และคณะ ได้ศึกษาอัลกอริธึมการเรียนรู้เชิงลึก โดยเฉพาะอย่างยิ่ง โครงข่ายแบบ convolutional ได้กลายเป็นวิธีการทางเลือกสำหรับการวิเคราะห์ ภาพทางการแพทย์อย่างรวดเร็ว ในการวิเคราะห์ภาพทางการแพทย์ ซึ่งใช้การเรียนรู้เชิงลึกสำหรับการ จำแนกภาพการตรวจจับ, การแบ่งส่วน และงานอื่น ๆ โดยงานวิจัยจะใช้วิเคราะห์ ระบบ ประสาท, ปอด, เต้านม, หัวใจ, ช่องท้อง, กล้ามเนื้อและกระดูก โดยการใช้ CNNs ที่ข้อมูลผ่านการ ฝึกรอบมาแล้วนำมาสกัดคุณลักษณะ สามารถนำไปใช้กับภาพทางการแพทย์ได้ ช่วยอำนวยความสะดวก ในการใช้งานในการวิเคราะห์ภาพทางการแพทย์เพื่อวินิจฉัย

ในปี ค.ศ 2019 Dung และคณะ ได้ศึกษาการตรวจจับรอยแตกเป็นงานที่สำคัญใน การตรวจสอบ ซึ่งทางวิศวกรรมโยธาได้การตรวจสอบ โครงสร้าง การจำแนกภาพในการตรวจจับ รอยแตกคอนกรีตแบบอัตโนมัติ โดยวิธีการที่ใช้โครงข่ายประสาทเทียมแบบเรียนรู้เชิงลึก ได้เสนอ วิธีการตรวจจับด้วย Fully Convolution Neural Network (FCN) ประเมินการจัดหมวดหมู่ภาพบน ชุดข้อมูลคอนกรีตสาธารณะที่มีรอยแตกขนาดภาพ 227×227 พิกเซล โดยแบ่งส่วนที่ภาพร้าวของ คอนกรีตเพื่อทำการตรวจจับประสิทธิภาพการทำงานของสถาปัตยกรรมโครงข่ายที่ผ่านการ ฝึกรอบมาแล้ว และ โครงข่ายประสาทเทียม FCN แบบ encoder-decoder ที่ใช้ VGG16 ผ่านการ ฝึกรอบ 500 ครั้ง ซึ่งโครงข่าย FCN ประสบความสำเร็จที่ความแม่นยำเฉลี่ย 90% ใช้รูปภาพที่ดึง มาจากวิดีโอของการทดสอบโหลดแบบวงกลมบนชิ้นงานคอนกรีตเพื่อตรวจสอบวิธีการที่เสนอ สำหรับการตรวจจับรอยแตกคอนกรีต พบว่ามีการตรวจพบรอยแตกที่สมเหตุสมผล และความ หนาแน่นของรอยแตกก็ถูกประเมินอย่างแม่นยำเช่นกันด้วยโครงข่าย FCN encoder-decoder ที่ใช้ VGG16

ในปี ค.ศ. 2019 Bu, Xingyuan และคณะ ได้ศึกษาการใช้ประโยชน์จากการใช้งาน ของชั้น convolutional ที่เหมาะสมเพื่อเป็นตัวบ่งชี้ที่มีประสิทธิภาพสำหรับการจำแนกพื้นผิวภายใต้ กรอบการเรียนรู้แบบ end-to-end ส่วนประกอบหลักของวิธีการของเราคือจำนวนชั้นที่สามารถ แก้ไขได้อย่างง่ายดายผ่านการฝึกรอบผ่าน backpropagation เนื่องจากกระบวนการวิเคราะห์ในการ แก้ปัญหา มีความสามารถในการรวบรวมข้อมูลเฉพาะของชั้นที่เรียนรู้ ซึ่งทำให้คุณสมบัติทางด้าน convolutional ที่ได้เรียนรู้นั้นแข็งแกร่งยิ่งขึ้น การแสดงผลลัพธ์นั้นมีประโยชน์อย่างยิ่งสำหรับการ จำแนกพื้นผิว

ในปี ค.ศ 2019 Wang และคณะ ได้ศึกษาออกแบบและฝึกรอบตัวจำแนก SFA + SFGN เพื่อดำเนินการระบุและแยกประเภทภาพเบลอ 4 ประเภท ในการตรวจสอบประสิทธิภาพ ของตัวจำแนกเสนอ ensemble ทดสอบกับ Alexnet, GoogleNet และวิธีการจำแนกการเบลออื่น ๆ ตามชุดข้อมูลของภาพเบลอที่สร้างขึ้นและชุดข้อมูลภาพเบลอแบบธรรมชาติที่เกิดขึ้นใน BHFID ผล

การทดลองแสดงให้เห็นถึงประสิทธิภาพที่เหนือกว่าของตัวจำแนกแบบ ensemble ที่เสนอให้เป็นตัววัดความถูกต้องของการจำแนก เนื่องจากประสิทธิภาพในการคำนวณเวลาการฝึกอบรมแบบจำลองของตัวจำแนก ensemble นั้นเปรียบได้กับ Alexnet และ GoogleNet ในขณะที่ใช้เวลาเฉลี่ยในการจัดประเภทภาพ 0.159 วินาที โดยตัวจำแนก ensemble นั้นมีประสิทธิภาพเหนือกว่า Alexnet และ GoogleNet ดังนั้นความสำเร็จของตัวแยกประเภท ensemble ที่เสนอทำให้ที่มีประสิทธิภาพซึ่งสามารถอำนวยความสะดวกในการใช้งานโครงข่ายประสาทที่ซับซ้อนที่มีชื่อเสียงในการใช้งานที่หลากหลาย

2.15 สรุป

จากการศึกษาทฤษฎีและปรัทัศน์วรรณกรรมที่เกี่ยวข้อง มีเป้าหมายที่จะพัฒนาเครื่องจักรอัตโนมัติให้เป็นระบบอัจฉริยะแบบชาญฉลาด ซึ่งจะเห็นได้ว่าเครื่องจักรอัตโนมัติในอุตสาหกรรมจะมีกลไกการทำงานในการประกอบชิ้นส่วนแบบหยิบจับและวางในตำแหน่งที่ถูกต้อง (pick and place) โดยจะใช้ระบบสุญญากาศ (vacuum gripper system) ในการหยิบจับชิ้นงานขึ้น และเคลื่อนย้ายตำแหน่งเพื่อไปทำการประกอบสามารถช่วยให้การทำงานรวดเร็ว ลดระยะเวลาของการทำงาน และเพิ่มประสิทธิภาพในการทำงาน อีกทั้งยังมีความแม่นยำและเที่ยงตรงสูง แต่ถ้าหากเกิดการรั่วของสุญญากาศจะทำให้หยิบจับหัวอ่านไปทำการติดตั้งในตำแหน่งที่ถูกต้องไม่ได้ ดังนั้นจากการศึกษาปรัทัศน์วรรณกรรมที่เกี่ยวข้องกับการตรวจจับและวินิจฉัยข้อบกพร่องและเทคนิคการเรียนรู้ของเครื่องจักร (Machine learning) จึงถูกนำมาประยุกต์ใช้ร่วมกันเพื่อช่วยในการตรวจจับและจำแนกข้อบกพร่อง โดยใช้โครงข่ายประสาทเทียม Artificial Neural Network (ANN) ที่สามารถวิเคราะห์ได้ทั้งข้อมูลเชิงปริมาณและรูปภาพ มีแนวความคิดที่ลอกเลียนแบบมาจากสมองมนุษย์สามารถเรียนรู้และจดจำรูปแบบได้อย่างมีประสิทธิภาพ และโครงข่ายประสาทเทียม Convolution Neural Network (CNN) จะมีความสามารถเฉพาะทางด้านรูปภาพ เช่น การตรวจจับใบหน้า, การจำแนกรูปภาพ และการวิเคราะห์รูปภาพ เป็นต้น ในงานวิจัยนี้จึงเลือกใช้โครงข่ายประสาทเทียมทั้ง ANN และ CNN มาช่วยในการตรวจจับและจำแนกข้อบกพร่องของ Mount head เพื่อไม่ให้เกิดปัญหาหัวอ่านเขียนหล่นหายระหว่างเคลื่อนที่ (Slider Loss Defect) อีกทั้งยังป้องกันการขัดข้องของเครื่องจักร Alarm71 และการหยุดทำงานของเครื่องจักร (Machine downtime) ในกระบวนการผลิต

บทที่ 3

วิธีการดำเนินงานวิจัย

3.1 บทนำ


การศึกษานี้มุ่งเน้นการตรวจจับและการวินิจฉัยข้อบกพร่อง Fault Detection and Diagnosis (FDD) เพื่อใช้ในการตรวจจับข้อบกพร่องในกระบวนการติดตั้งหัวอ่านเขียนอัตโนมัติ (Slider attachment process) ของเครื่องจักร Auto Core Adhesive Mounting machine (ACAM) ซึ่ง Mount head จะทำหน้าที่ติดตั้งหัวอ่านเขียนลงบนแขนจับของหัวอ่านเขียน โดยอาศัยแรงดันสุญญากาศในระหว่างการติดตั้ง ถ้าหากเกิดการสูญเสียแรงดันสุญญากาศจะทำให้เกิดปัญหาหัวอ่านเขียนหล่นหายระหว่างการเคลื่อนที่ ส่งผลกระทบทำให้เครื่องจักรขัดข้องเกิด Alarm 71 และทำให้เครื่องจักรหยุดทำงานในที่สุด อีกทั้งยังส่งผลต่ออัตราการผลิตที่ลดลง เนื่องจากเครื่องจักรไม่สามารถทำงานได้อย่างต่อเนื่อง ดังนั้นจึงวิเคราะห์หาปัจจัยที่มีผลกระทบต่อประสิทธิภาพการทำงานของกระบวนการติดตั้งหัวอ่านเขียนเพื่อนำมาใช้เป็นข้อมูลในการสร้างระบบ FDD โดยการออกแบบระบบจะมีการใช้เทคนิคการประมวลผลภาพเพื่อเสริมสร้างประสิทธิภาพ และมีการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องจักรด้วยโครงข่ายประสาทเทียมนิเวรอลเน็ตเวิร์กและโครงข่ายประสาทเทียมคอนโวลูชันมาช่วยในการตรวจจับและจำแนกข้อบกพร่องของ Mount head เพื่อป้องกันการเกิดปัญหา SLD, Alarm 71 และ Machine downtime ได้

3.2 วิเคราะห์ปัจจัยในกระบวนการติดตั้งหัวอ่านเขียน

พิจารณาหาปัจจัยที่มีผลต่อการตรวจจับและจำแนกข้อบกพร่องในกระบวนการติดตั้งหัวอ่านเขียน โดยทำการเก็บข้อมูลในกระบวนการผลิตจริงเพื่อวิเคราะห์การเปลี่ยนแปลงของแรงดันสุญญากาศประกอบกับรูปภาพของ Mount head ที่มีความสัมพันธ์กัน เพื่อพิจารณายสำคัญของข้อมูลและแนวโน้มของระดับความเสียหายที่เกิดขึ้นในขณะที่ทำการติดตั้งหัวอ่านเขียน เพื่อนำข้อมูลมาใช้ในการประยุกต์การตรวจจับและจำแนกข้อบกพร่องก่อนเกิดความเสียหายในกระบวนการผลิตได้

3.2.1 ลักษณะความเสียหาย

ทำการเก็บตัวอย่างของ Mount head ที่ผ่านการใช้งานในกระบวนการผลิตการติดตั้งหัวอ่านเขียนมาแล้ว จากนั้นนำ Mount head ไปถ่ายภาพเพื่อใช้ในการวินิจฉัย จะสังเกตเห็นได้ว่า Mount head มีรูปแบบความเสียหายที่แตกต่างกันออกไป ดังนั้นจึงจัดกลุ่มตามความเสียหายของ Mount head โดยใช้สายตาในการประเมินเพื่อจำแนกสภาพเบื้องต้น ซึ่งสามารถจำแนกออกเป็น 4 ระดับ คือ Good, Fault I, Fault II และ Fault III ดังแสดงให้เห็นในรูปที่ 3.1 เพื่อใช้ในจำแนกข้อบกพร่องในกระบวนการติดตั้งหัวอ่านเขียน เมื่อ Mount head เริ่มเกิดความเสียหายจากสภาพ Good เป็นสภาพ Fault I และเริ่มมีความเสียหายมากขึ้นจนกระทั่งเข้าสู่สภาพ Fault II แต่จะหลีกเลี่ยงการเข้าสู่สภาพ Fault III เพราะจะทำให้เกิดความเสียหายอื่น ๆ ในกระบวนการผลิตได้



รูปที่ 3.1 แสดงสภาพความเสียหายของ Mount head


3.2.1.1 สภาพ Good

จำแนกลักษณะความเสียหายของ Mount head โดยการประเมินจากรูปภาพด้วยสายตาจะเห็นว่าสภาพของ Mount head ยังมีสภาพที่ดีต่อการใช้งานจึงจัดอยู่ในสภาพ Good ดังแสดงในรูปที่ 3.2 ซึ่งสภาวะนี้จะมีอัตราการผลิตหัวอ่านเขียนประมาณ 7,000 – 12,000 ชิ้น จากนั้นนำ Mount head ไปใช้ในกระบวนการผลิตหัวอ่านเขียน เพื่อทดสอบการทำงานจากสัญญาณ

ของแรงดันสุญญากาศ (vacuum pressure) พบว่าสัญญาณการทำงานของแรงดันสุญญากาศ (vacuum pressure) และแรงดันไฟฟ้า (voltage) มีสัญญาณการทำงานที่เป็นปกติ และสามารถติดตั้งหัวอ่านเขียนได้จนครบจำนวน 10 ชิ้น ซึ่งในกระบวนการผลิตจะมีการผลิตหัวอ่านเขียน 10 ชิ้น ต่อ 1 pallet แสดงให้เห็นในรูปที่ 3.3 กราฟความสัมพันธ์ระหว่างจำนวนข้อมูล (Data point) และแรงดันสุญญากาศ (vacuum pressure)



รูปที่ 3.2 แสดงรูปภาพ Mount head สภาวะ Good




รูปที่ 3.3 แสดงสัญญาณแรงดันสุญญากาศสภาวะ Good


3.2.1.2 สภาวะ Fault I

จำแนกลักษณะความเสียหายของ Mount head โดยการประเมินจากรูปภาพด้วยสายตาจะเห็นได้ว่าสภาพของ Mount head เริ่มมีการเปลี่ยนแปลงอันเนื่องมาจากความเสียหายจากการทำงานหรือการเสื่อมอายุ จึงจัดอยู่ในสภาวะ Fault I ดังแสดงในรูปที่ 3.4

ซึ่งในสภาวะนี้จะมีอัตราการผลิตหัวอ่านเขียนประมาณ 9,000 - 90,000 ชิ้น จากนั้นนำ Mount head ไปใช้ในกระบวนการผลิตหัวอ่านเขียน เพื่อทดสอบการทำงานจากสัญญาณของแรงดันสุญญากาศ (vacuum pressure) พบว่าสัญญาณการทำงานของแรงดันสุญญากาศ (vacuum pressure) และแรงดันไฟฟ้า (voltage) มีสัญญาณการทำงานที่เป็นปกติยังคงสามารถรักษาแรงดันสุญญากาศในการหยิบหัวอ่านได้ดี และสามารถติดตั้งหัวอ่านเขียนได้จนครบจำนวน 10 ชิ้น แสดงให้เห็นในรูปที่ 3.5 กราฟความสัมพันธ์ระหว่างจำนวนข้อมูล (Data point) และแรงดันสุญญากาศ (vacuum pressure)



รูปที่ 3.4 แสดงรูปภาพ Mount head ระดับข้อบกพร่อง Fault I




รูปที่ 3.5 แสดงสัญญาณแรงดันสุญญากาศสภาพ Fault I

3.2.1.3 สภาพ Fault II

จำแนกลักษณะความเสียหายของ Mount head โดยการประเมินจากรูปภาพด้วยสายตาจะเห็นได้ว่าสภาพของ Mount head มีการเปลี่ยนแปลงอันเนื่องมาจากความเสียหายจากการทำงานหรือการเสื่อมอายุที่มีสภาพความเสียหายมากขึ้นจากสภาพแบบ Fault I จึงจัดอยู่ในสภาพ Fault I ดังแสดงในรูปที่ 3.6 ซึ่งในสถานะนี้จะมีอัตราการผลิตหัวอ่านเขียนประมาณ 30,000 - 130,000 ชิ้น จากนั้นนำ Mount head ไปใช้ในกระบวนการผลิตหัวอ่านเขียน เพื่อทดสอบการทำงานจากสัญญาณของแรงดันสุญญากาศ (vacuum pressure) พบว่าสัญญาณการทำงานของแรงดันสุญญากาศ (vacuum pressure) และแรงดันไฟฟ้า (voltage) มีสัญญาณการทำงานที่เป็นปกติ ยังคงพยายามรักษาสภาพของแรงดันสุญญากาศในการหยิบหัวอ่านได้ และสามารถติดตั้งหัวอ่านเขียนได้จนครบจำนวน 10 ชิ้น แต่ถ้าหากยังคงใช้งานอย่างต่อเนื่องต่อไปอาจจะเกิดการรั่วของสุญญากาศแล้วส่งผลกระทบต่อเครื่องจักรได้ แสดงให้เห็นในรูปที่ 3.7 กราฟความสัมพันธ์ระหว่างจำนวนข้อมูล (Data point) และแรงดันสุญญากาศ (vacuum pressure)



รูปที่ 3.6 แสดงรูปภาพ Mount head สภาพ Fault II




รูปที่ 3.7 แสดงสัญญาณแรงดันสุญญากาศระดับข้อบกพร่อง Fault II

3.2.1.4 สภาพ Fault III

จำแนกลักษณะความเสียหายของ Mount head โดยการประเมินจากรูปภาพด้วยสายตาจะเห็นได้ว่าสภาพของ Mount head มีสภาพความเสียหายที่เปลี่ยนแปลงมากขึ้นอย่างชัดเจนอันเนื่องมาจากความเสียหายจากการทำงาน จึงจัดอยู่ในสภาพ Fault III ดังแสดงในรูปที่ 3.8 จากนั้นนำ Mount head ไปใช้ในกระบวนการผลิตหัวอ่านเขียน เพื่อทดสอบการทำงานจากสัญญาณของแรงดันสุญญากาศ (vacuum pressure) จะเห็นได้ว่าสัญญาณการทำงานของแรงดันสุญญากาศ (vacuum pressure) และแรงดันไฟฟ้า (voltage) มีสัญญาณการทำงานที่ผิดปกติ ซึ่งสามารถติดตั้งหัวอ่านเขียนได้เพียงจำนวน 5 ชิ้น แสดงให้เห็นในรูปที่ 3.9 กราฟความสัมพันธ์ระหว่างจำนวนข้อมูล (Data point) และแรงดันสุญญากาศ (vacuum pressure) ซึ่งจะหลีกเลี่ยงการทำงานในสภาวะนี้ เนื่องจาก Mount head เกิดความเสียหายค่อนข้างมากทำให้เกิดการรั่วของแรงดันสุญญากาศ จึงไม่สามารถผลิตชิ้นงานได้อย่างต่อเนื่อง




รูปที่ 3.8 แสดงรูปภาพ Mount head สภาพ Fault III



รูปที่ 3.9 แสดงสัญญาณแรงดันสุญญากาศสภาพ Fault III

3.2.1.5 สรุปปัจจัยที่มีผล


การวิเคราะห์และทดสอบดังกล่าวพบว่า สภาพความเสียหายของ Mount head ในสภาพ Good, Fault I, Fault II และ Fault III ที่ทำการจัดกลุ่มตามลักษณะความเสียหายจากรูปภาพของ Mount head ด้วยการประเมินด้วยสายตา เพื่อนำไปใช้ในการทดสอบการทำงานของแรงดันสูญญากาศและแรงดันไฟฟ้า ทำให้เห็นว่า Fault III จะมีการทำงานที่ไม่สมบูรณ์ในกระบวนการติดตั้งหัวอ่านเขียน เนื่องจากเกิดการสูญเสียแรงดันสูญญากาศ มีสาเหตุมาจาก Mount head เกิดความเสียหายหรือเสื่อมอายุในระดับที่ค่อนข้างรุนแรง จึงหลีกเลี่ยงการใช้งานของ Mount head สภาพ Fault III เพราะไม่ต้องการให้เกิดเหตุการณ์แบบนี้ขึ้นในกระบวนการผลิตหัวอ่านเขียน รูปที่ 3.10 - 3.12 รวมทั้งวิเคราะห์แรงดันสูญญากาศและแรงดันไฟฟ้าเพื่อดูความสัมพันธ์และแนวโน้มจากการติดตั้งหัวอ่านเขียนในกระบวนการผลิตจริง และรูปที่ 3.12 – 3.14 พิจารณาจากจำนวนพื้นที่พิกเซลของรูปภาพ Mount head โดยนำไปวิเคราะห์หาจำนวนพื้นที่พิกเซลด้านนอก (outer area), จำนวนพิกเซลด้านใน (inner area) และจำนวนพิกเซลทั้งหมด (total area) เพื่อดูความสัมพันธ์และแนวโน้ม



รูปที่ 3.10 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ยของแรงดันไฟฟ้า


รูปที่ 3.10 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและจำนวนพื้นที่พิกเซลด้านนอกของ Mount head โดยนำค่าเฉลี่ย (mean) ของแต่ละระดับความเสียหายมาพิจารณา จากกราฟแสดงให้เห็นว่าจำนวนพื้นที่พิกเซลด้านนอกสภาพ Good จะมีค่าเฉลี่ยประมาณ 19,144 พิกเซล สภาพ Fault I มีค่าเฉลี่ยของจำนวนพื้นที่พิกเซลด้านนอกประมาณ 17,512 พิกเซล สภาพ Fault II มีค่าเฉลี่ยของจำนวนพื้นที่พิกเซลด้านนอกประมาณ 16,020 พิกเซล และแบบ Fault III มีค่าเฉลี่ยของจำนวนพื้นที่

พิกเซลด้านนอกประมาณ 11,992 พิกเซล ซึ่งจะเห็นได้ว่าจากกราฟมีแนวโน้มของจำนวนพื้นที่พิกเซลด้านนอกที่ลดลงตามระดับความเสียหายที่เกิดขึ้น




รูปที่ 3.11 แสดงความสัมพันธ์ระดับความเสียหายและค่าเฉลี่ยของแรงดันสุญญากาศ

รูปที่ 3.11 แสดงความสัมพันธ์ระดับความเสียหายและค่าเฉลี่ยของแรงสุญญากาศ (vacuum pressure) ซึ่งในกระบวนการติดตั้งหัวอ่านเขียนจะใช้ Mount head ในการติดตั้งหัวอ่านเขียนลงบนแขนจับหัวอ่านเขียน โดยจะอาศัยแรงดันสุญญากาศในการหยิบหัวอ่านเขียนจากตำแหน่งหนึ่งเพื่อเคลื่อนที่ไปตามกระบวนการ จากกราฟจะเห็นได้ว่าในช่วงระดับความเสียหายแบบ Good, Fault I และ Fault II มีค่าเฉลี่ยแรงสุญญากาศที่เท่ากันอยู่ที่ 0.31 บาร์ แต่ที่ระดับข้อบกพร่องแบบ Fault III จะเห็นได้ว่ามีค่าเฉลี่ยของแรงสุญญากาศที่ลดลงอย่างชัดเจนอยู่ที่ 0.22 บาร์ เนื่องจากระดับนี้เกิดความเสียหายเป็นอย่างมากจึงทำให้เกิดการรั่วของแรงดันสุญญากาศ ทำให้ Mount head ไม่สามารถหยิบหัวอ่านเขียนเพื่อไปติดตั้งได้




รูปที่ 3.12 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ยของจำนวนพื้นที่พิกเซลด้านนอก

รูปที่ 3.12 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและจำนวนพื้นที่พิกเซลด้านในของ Mount head โดยนำค่าเฉลี่ย (mean) ของแต่ละระดับความเสียหายมาพิจารณา จากกราฟแสดงให้เห็นว่าจำนวนพื้นที่พิกเซลด้านในแบบ Good จะมีค่าเฉลี่ยประมาณ 5,889 พิกเซล ระดับความเสียหายสภาพ Fault I มีค่าเฉลี่ยของจำนวนพื้นที่พิกเซลด้านในประมาณ 6,069 พิกเซล ระดับความเสียหายสภาพ Fault II มีค่าเฉลี่ยของจำนวนพื้นที่พิกเซลด้านในประมาณ 6,730 พิกเซล และระดับความเสียหายสภาพ Fault III มีค่าเฉลี่ยของจำนวนพื้นที่พิกเซลด้านในประมาณ 8,541 พิกเซล ซึ่งจะเห็นได้จากกราฟมีแนวโน้มของจำนวนพื้นที่พิกเซลด้านในที่เพิ่มขึ้นตามระดับความเสียหายที่เกิดขึ้น



รูปที่ 3.13 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ยของจำนวนพื้นที่พิกเซลด้านใน

รูปที่ 3.13 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและพื้นที่พิกเซลทั้งหมดของ Mount head โดยนำค่าเฉลี่ย (mean) ของแต่ละระดับความเสียหายมาพิจารณา จากกราฟแสดงให้เห็นว่าพื้นที่พิกเซลทั้งหมดแบบ Good จะมีค่าเฉลี่ยประมาณ 25,034 พิกเซล ระดับความเสียหายแบบ Fault I มีค่าเฉลี่ยของพื้นที่พิกเซลทั้งหมดประมาณ 23,580 พิกเซล ระดับความเสียหายแบบ Fault II มีค่าเฉลี่ยของพื้นที่พิกเซลทั้งหมดประมาณ 22,750 พิกเซล และระดับความเสียหายแบบ Fault III มีค่าเฉลี่ยของพื้นที่พิกเซลทั้งหมดประมาณ 20,533 พิกเซล ซึ่งจะเห็นได้ว่าจากกราฟมีแนวโน้มของพื้นที่พิกเซลทั้งหมดมีแนวโน้มที่ลดลงตามระดับความเสียหายที่เกิดขึ้น



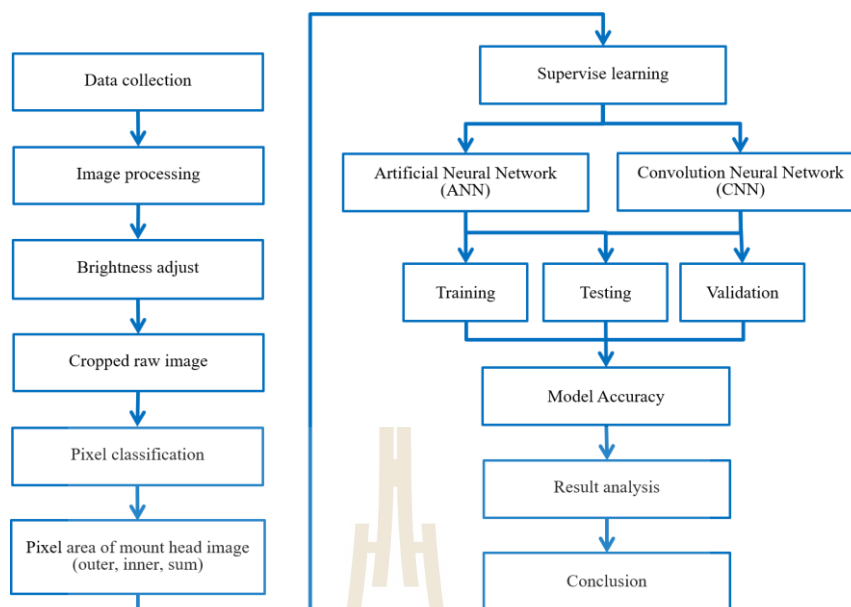
รูปที่ 3.14 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ยของจำนวนพื้นที่พิกเซลทั้งหมด

รูปที่ 3.14 แสดงความสัมพันธ์ระหว่างระดับความเสียหายและค่าเฉลี่ยของแรงดันไฟฟ้า (voltage) ซึ่งในกระบวนการติดตั้งหัวอ่านเขียนจะใช้ Mount head ในการติดตั้งหัวอ่านเขียนลงบนแกนจับหัวอ่านเขียน โดยจะอาศัยแรงดันสุญญากาศในการหีบหัวอ่านเขียนจากตำแหน่งหนึ่ง เพื่อเคลื่อนที่ไปตามกระบวนการ ซึ่งการใช้แรงดันสุญญากาศนั้นจะต้องมีการจ่ายแรงดันไฟฟ้าเพื่อให้ระบบสุญญากาศทำงาน จากกราฟจะเห็นได้ว่าในช่วงระดับความเสียหายแบบ Good, Fault I และ Fault II มีค่าเฉลี่ยแรงดันไฟฟ้าที่เท่ากันอยู่ที่ 0.27 โวลต์ แต่ที่ระดับความเสียหายแบบ Fault III จะเห็นได้ว่ามีค่าเฉลี่ยของแรงดันไฟฟ้าที่ลดลงอย่างชัดเจนอยู่ที่ 0.14 โวลต์ เนื่องจากระดับนี้เกิดความเสียหายเป็นอย่างมากจึงทำให้ไม่สามารถจ่ายแรงดันไฟฟ้าเพื่อให้แรงดันสุญญากาศของ Mount head สามารถหีบหัวอ่านเขียนเพื่อไปติดตั้งได้

ดังนั้นการพิจารณาหาปัจจัยที่ในการตรวจจับและวินิจฉัยข้อบกพร่องที่เกิดขึ้นพบว่า แรงดันไฟฟ้าและแรงดันสัญญาณมีค่าที่เท่ากันในระดับความเสียหายสภาพ Good, Fault I และ Fault II ซึ่งไม่สามารถแยกแยะข้อมูลหรือระดับความเสียหายให้เป็นไปตามเกณฑ์ของกลุ่มที่จำแนกได้ ถึงแม้ว่าลักษณะความเสียหายของ Mount head จะมีสภาพที่เปลี่ยนแปลงไปก็ตาม และจะเห็นได้อย่างชัดเจนว่าแนวโน้มของแรงดันไฟฟ้าและแรงดันสัญญาณจะมีค่าลดลงอย่างฉับพลันในสภาพ Fault III เพราะฉะนั้นแรงดันไฟฟ้าและแรงดันสัญญาณจึงไม่เหมาะสมที่จะนำข้อมูลมาใช้ในการวิเคราะห์การตรวจจับและจำแนกข้อบกพร่อง ในงานวิจัยนี้จึงเลือกนำรูปภาพของ Mount head มาใช้ในการตัดสินใจการทำงานของกระบวนการติดตั้งหัวอ่านเขียน เพื่อใช้ตรวจจับและจำแนกข้อบกพร่อง เนื่องจากแนวโน้มการเปลี่ยนแปลงสภาพของ Mount head เป็นข้อมูลที่สามารนำไปจำแนกระดับข้อบกพร่องของเครื่องจักรได้ จึงได้ออกแบบระบบ FDD ซึ่งทำการตรวจจับเมื่อ Mount head มีการใช้งานที่อยู่ในสภาพ Fault II เพราะถ้าหากเข้าสู่สภาพ Fault III จะเกิดความเสียหายที่รุนแรงมากส่งผลกระทบต่อกระบวนการผลิตหัวอ่านเขียนและการหยุดทำงานของเครื่องจักร (Machine downtime)

3.3 วิธีการทดลอง

ออกแบบระบบตรวจจับและจำแนกข้อบกพร่องโดยใช้รูปภาพของ Mount head ในการจำแนกประเภทลักษณะของข้อบกพร่องที่เกิดขึ้น และนำไปวิเคราะห์ด้วยหลักการ Image Processing เพื่อสร้างเกณฑ์ในการจำแนกประเภทของลักษณะความเสียหาย และนำมาประยุกต์ใช้กับการเรียนรู้ของเครื่องจักร (machine learning) โดยใช้โครงข่ายประสาทเทียมแบบ Artificial Neural Network (ANN) และโครงข่ายประสาทเทียมแบบ Convolution Neural Network (CNN) เพื่อทำการเปรียบเทียบประสิทธิภาพความถูกต้องในการตรวจจับและจำแนกข้อบกพร่องที่เกิดขึ้น ซึ่งโครงข่ายประสาทจะมีความคิดที่ลอกเลียนแบบมาจากสมองของมนุษย์ที่สามารถเข้าใจชุดข้อมูลและเรียนรู้ได้โดยไม่ต้องอาศัยชุดข้อมูลจำนวนมาก และสามารถเห็นรูปแบบที่ซ่อนกันอยู่ในข้อมูล ซึ่งทำให้การคาดการณ์ข้อมูลบางประเภทเป็นไปอย่างแม่นยำ วิธีการดำเนินงานแสดงให้เห็นในรูปที่ 3.15



รูปที่ 3.15 ขั้นตอนการดำเนินงาน


3.3.1 การเก็บข้อมูล (Data collection)

ทำการเก็บรูปภาพของ Mount head จากเครื่องจักร ACAM ในกระบวนการผลิตจริงของการติดตั้งหัวอ่านเขียน ซึ่งสามารถเก็บรูปภาพของ Mount head มาได้ทั้งหมด 500 ภาพ โดยรูปภาพจะมีสภาพความเสียหายที่แตกต่างกัน และมีอายุการใช้งานที่ไม่เท่ากันตามการใช้งานจริงในกระบวนการผลิต

3.3.2 เทคนิคการประมวลผลภาพ (Image processing)

3.3.2.1 การปรับความสว่างภาพ


รูปที่ 3.16 แสดงการปรับความสว่างของรูปภาพ Mount head โดยการนำรูปภาพมาทำการปรับความสว่างโดยใช้โปรแกรม Visual studio ในการเพิ่มความสว่าง 20% และลดความสว่างลง 20% การปรับเพิ่ม-ลดความสว่างในช่วงนี้ รูปภาพของ Mount head จะมีลักษณะของความสว่างที่ครอบคลุมกับการปรับแสงที่เครื่องจักร ACAM ในกระบวนการผลิตจริง โดยทำการเพิ่มความสว่างที่ 20% จากรูปภาพ Original ของ Mount head และทำการลดความสว่างที่ 20% จากรูปภาพ Original ของ Mount head ซึ่งวิธีการนี้จะช่วยเพิ่มจำนวนของข้อมูลรูปภาพเพื่อใช้ในการวิเคราะห์ เนื่องจากความสว่างของรูปมีผลต่อการเปลี่ยนแปลงของพิกเซล อีกทั้งยังช่วยเพิ่มประสิทธิภาพการประมวลผลภาพอีกด้วย



รูปที่ 3.16 การปรับความสว่างของรูปภาพ Mount head

3.2.2 การตัดส่วนภาพที่สำคัญ


ขนาดรูปภาพของ Mount head ที่ได้มาจากเครื่องจักร ACAM แสดงให้เห็นดังรูปที่ 3.17 (a) จะมีขนาด 640x480 พิกเซล ซึ่งจะมีความละเอียด 307,200 พิกเซล จะเห็นได้ว่ามีพื้นที่ที่ไม่จำเป็นต้องใช้ในการวิเคราะห์ข้อมูลจากภาพ ดังนั้นจึงทำการครอบตัดภาพส่วนที่สำคัญและสนใจเพื่อใช้ในการวิเคราะห์ โดยวิธีนี้จะเป็นการลดขนาดรูปภาพให้มีขนาดที่เล็กลง ซึ่งหลังจากการครอบตัดภาพจะมีขนาด 250x250 พิกเซลและมีความละเอียด 62,500 พิกเซล แสดงให้เห็นในรูปที่ 3.17 (b) ซึ่งการลดขนาดของรูปภาพจะช่วยให้มีจำนวนพื้นที่พิกเซล ที่ลดลงและลดเวลาในการประมวลผลในขั้นตอนของโครงข่ายประสาทเทียมแบบคอนโวลูชัน



รูปที่ 3.17 การครอบตัดส่วนภาพที่สำคัญ

3.4 กำหนดเงื่อนไขของระดับข้อบกพร่อง

นำรูปภาพของ Mount head มาหาจำนวนพื้นที่พิกเซลเพื่อใช้ในการวิเคราะห์ โดยใช้โปรแกรม Vision pro ในการคำนวณหาบริเวณจำนวนพื้นที่พิกเซลด้านนอก (outer area), พื้นที่จำนวนที่พิกเซลด้านใน (inner area) และจำนวนพื้นที่พิกเซลทั้งหมด (total area) ของ Mount head จากรูปที่ผ่านกระบวนการประมวลผลภาพแล้ว เพื่อนำค่าของจำนวนพื้นที่พิกเซลไปกำหนดเงื่อนไขในการจัดกลุ่มความเสียหายตามระดับข้อบกพร่องของ Mount head ที่เกิดขึ้น แสดงในรูปที่ 3.18 โดยจะแบ่งระดับข้อบกพร่องเป็น 4 ระดับ คือ Good, Fault I, Fault II และ Fault III โดยสรุปเป็นตารางแสดงเงื่อนไขของพื้นที่พิกเซลตามระดับข้อบกพร่องดังตารางที่ 3.1 จะเห็นได้ว่าจำนวนพื้นที่พิกเซลด้านนอก (outer area) และจำนวนพื้นที่พิกเซลทั้งหมด (total area) ของ Mount head จะมีแนวโน้มที่ลดลงตามระดับข้อบกพร่องเมื่อเกิดความเสียหายที่มากขึ้น ในทางกลับกันจำนวนพื้นที่พิกเซลด้านใน (inner area) ของ Mount head จะมีแนวโน้มที่เพิ่มมากขึ้นตามระดับข้อบกพร่อง



รูปที่ 3.18 แสดงการวิเคราะห์หาพื้นที่ของรูปภาพ Mount head

ตารางที่ 3.1 แสดงเงื่อนไขของพื้นที่พิกเซลตามระดับข้อบกพร่อง

Fault Level	Pixel number range:		Pixel number range:
	Outer area	Inner area	Total area
Good	18,000-23,000 (19,753)	5,000-6,500 (5,843)	23,000-27,000 (25,559)
Fault I	16,000-18,000 (17,356)	5,500-9,000 (6,502)	22,000-26,000 (23,730)
Fault II	14,000-16,000 (16,020)	5,500-12,000 (7,625)	21,000-25,000 (22,634)
Fault III	Less than 14,000 (11,749)	7,000-16,000 (9,376)	14,000-24,000 (20,126)

3.5 การจำแนกข้อบกพร่องของ Mount head

3.5.1 จัดกลุ่มข้อมูลตามระดับข้อบกพร่อง

การเก็บข้อมูลรูปภาพของ Mount head จากเครื่องจักร ACAM ในกระบวนการผลิตหัวอ่านเขียนฮาร์ดดิสก์ไดรฟ์ สามารถเก็บรูปภาพมาได้ทั้งหมดจำนวน 500 ภาพ ซึ่งได้ทำการจัดกลุ่มตามเกณฑ์ของเงื่อนไขที่กำหนดเพื่อจำแนกความเสียหายตามระดับข้อบกพร่องด้วยจำนวนพื้นที่ซิกเซลด้านนอก (outer area), จำนวนพื้นที่ด้านใน (inner area) และจำนวนพื้นที่ทั้งหมด (total area) สามารถจัดระดับข้อบกพร่องที่เรียงระดับความเสียหายจากน้อยไปมาก ออกเป็น 4 ระดับ ประกอบด้วย Good, Fault I, Fault II และ Fault III ดังนี้

1. Good จำนวน 80 ภาพ
2. Fault I จำนวน 231 ภาพ
3. Fault II จำนวน 91 ภาพ
4. Fault III จำนวน 98 ภาพ

ซึ่งจะเห็นว่าได้จำนวนรูปภาพในแต่ละระดับข้อบกพร่องมีจำนวนที่ไม่เท่ากัน เนื่องจาก Mount head ไม่มีรูปแบบของการเกิดความเสียหายที่แน่นอน เมื่อนำภาพมาจัดกลุ่มตามเกณฑ์ในการจำแนกระดับข้อบกพร่องด้วยจำนวนพื้นที่ซิกเซลด้านนอก (outer area), จำนวนพื้นที่ด้านใน (inner area) และจำนวนพื้นที่ทั้งหมด (total area) จะทำให้รูปภาพถูกจัดไปอยู่ในกลุ่มที่มีจำนวนพื้นที่ซิกเซลที่อยู่ในช่วงนั้น ๆ ของระดับข้อบกพร่อง

3.5.2 การเพิ่มจำนวนข้อมูล


เมื่อนำรูปที่จัดกลุ่มตามระดับไปประยุกต์ใช้การประมวลผลภาพ (Image processing) ด้วยวิธีการปรับความสว่างเพิ่มขึ้นจากรูปเดิม 20% จะมีจำนวนรูปภาพเพิ่มขึ้นมาจาก 500 เป็น 1,000 ภาพ และลดความสว่างจากรูปเดิมลง 20% จะมีจำนวนรูปภาพเพิ่มขึ้นมาจาก 1,000 เป็น 1,500 ภาพ จากนั้นทำการครอบตัดส่วนที่สำคัญของภาพจำนวนทั้งหมด 1,500 ภาพ วิธีนี้จะทำให้มีจำนวนรูปที่เพิ่มมากขึ้น เนื่องจากความสว่างหรือแสงสว่างมีผลต่อจำนวนพิกเซลของรูปที่เปลี่ยนแปลงไป ดังนั้นจำนวนข้อมูลรูปภาพตามระดับข้อบกพร่องรวมทั้งสิ้นจะมี 1,500 ภาพ จำแนกตามระดับ ดังนี้

1. Good จำนวน 240 ภาพ
2. Fault I จำนวน 693 ภาพ
3. Fault I จำนวน 273 ภาพ
4. Fault I จำนวน 294 ภาพ

3.5.3 การเตรียมข้อมูลเพื่อสร้างโมเดล

เมื่อได้ข้อมูลที่เตรียมพร้อมสำหรับการสร้างโมเดลแล้ว จากนั้นนำข้อมูลที่ได้มาจัดแบ่งและใช้งานอย่างเหมาะสม โดยปกติจะแบ่งข้อมูลออกเป็น 3 ชุด คือ Training, Validation และ Testing โดยทั่วไปจะแบ่งข้อมูลสำหรับการ Training 80% และสำหรับ Validation กับ Test 20% ซึ่งในแต่ละกระบวนการจะมีหน้าที่ดังนี้

1. Training จะเป็นการฝึกสอนให้โครงข่ายประสาทเทียมสามารถเรียนรู้และแก้ไขข้อผิดพลาดของโครงข่ายเพื่อให้ได้ค่าที่ดีที่สุด
2. Validation เป็นการตรวจสอบข้อมูล เพื่อวัดภาพรวมของโครงข่ายประสาทเทียมหลังจากเสร็จสิ้นกระบวนการ training ว่าโมเดลมีความผิดพลาดที่น้อยที่สุดและสามารถทำงานได้ดีแค่ไหนเมื่อโครงข่ายประสาทเทียมหยุดการพัฒนาแล้ว
3. Testing เป็นการนำข้อมูลตัวอย่างเข้าสู่โครงข่ายประสาทเทียม เพื่อทดสอบคุณภาพของโครงข่ายประสาทเทียมหลังจากกระบวนการ training แล้วได้โมเดลที่ดีที่สุดมาทดสอบว่าโมเดลทำงานได้ดีแค่ไหนสำหรับข้อมูลที่ไม่เคยเห็นมาก่อน



รูปที่ 3.19 แสดงการแบ่งข้อมูลสำหรับ โมเดล ANN

3.6 แบบจำลองโครงข่ายประสาทเทียมนิวรอลเน็ตเวิร์ก

3.6.1 เตรียมข้อมูลสำหรับโครงข่ายประสาทเทียมแบบนิวรอลเน็ตเวิร์ก

โครงข่ายประสาทเทียมหรือ Neural Network คือการจำลองโครงข่ายภายในสมองมนุษย์ ซึ่งภายในสมองมนุษย์มีหน่วยประมวลจำนวนมากและเชื่อมต่อกัน ดังนั้นโครงข่ายประสาทเทียมของ Neural Network จึงถูกสร้างขึ้นมาเพื่อจำลองการคิดและวิเคราะห์แบบมนุษย์ ซึ่งสามารถแยกแยะสิ่งต่าง ๆ หรือข้อมูลต่าง ๆ ได้ โดยใช้กระบวนการเรียนรู้เครื่องจักร (Machine Learning) หรือการสอนให้คอมพิวเตอร์แยกแยะสิ่งต่างๆ จากลักษณะที่แตกต่างกันไปของข้อมูล ซึ่งโปรแกรม

MATLAB ได้มีเครื่องมือในการจำลองโครงข่ายประสาทเทียม Neural Network โดยใช้เครื่องมือที่เรียกว่า Neural Pattern Recognition ซึ่งข้อมูลที่นำมาใช้นั้นสามารถใช้ข้อมูลตัวอย่างที่มีมาพร้อมกับตัวเครื่องนั้นได้ทันที โดยจะให้โมเดลเรียนรู้ข้อมูลแบบ Supervised learning คือ การเรียนรู้แบบมีผู้สอน ดังนั้นต้องเตรียมข้อมูลอินพุตที่มีคุณลักษณะที่สำคัญเพื่อใช้ในการจำแนกคลาส และข้อมูลเอาต์พุตมีค่าที่เป็น 0 และ 1 กำหนดตามคลาสของข้อมูลอินพุต ซึ่งข้อมูลจะต้องเป็นไฟล์ Excel เพื่อใช้โหลดเข้าสู่การทำโมเดล โดยข้อมูลตัวอย่างที่ใช้คือ ค่าพื้นที่พิกเซลของ Mount head ซึ่งมีข้อมูลทั้งหมด 1,500 ตัวอย่าง โดยนำมาแบ่งเป็น Training 80%, Test 10% และ Validation 10% แสดงดังรูปที่ 3.19 คือจะมีข้อมูลที่นำมาเป็นอินพุตของระบบ 1,200 ตัวอย่าง เพื่อใช้สำหรับฝึกสอนข้อมูล (Training) มีข้อมูลไว้สำหรับทดสอบ (Test) 150 ตัวอย่าง และมีข้อมูลสำหรับตรวจสอบ (Validation) 150 ข้อมูล โดยจะจำแนกกลุ่มข้อมูลตามระดับข้อบกพร่องสามารถแบ่งออกเป็น 4 ระดับ คือ Good, Fault I, Fault II และ Fault III ซึ่งการทดลองจะพิจารณาที่จำนวนอินพุตที่ป้อนเข้าไปเพื่อให้โมเดลเรียนรู้ คือ 2 อินพุต และ 3 อินพุต เพื่อเปรียบเทียบประสิทธิภาพความถูกต้องในการตรวจจับและจำแนกข้อบกพร่อง

3.6.2 โครงข่ายประสาทเทียมแบบนิวรอลเน็ตเวิร์ก

3.6.2.1 กรณีที่ 1 สองอินพุต

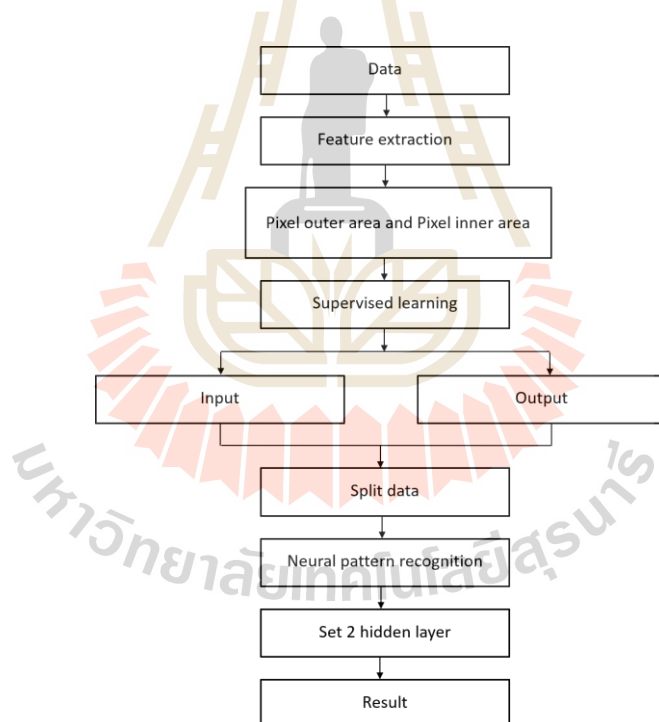
กรณี 2 อินพุต สิ่งทีนำมาเป็นคุณลักษณะในการแยกคลาของระดับข้อบกพร่องของ Mount head ได้แก่

1. จำนวนพื้นที่ด้านนอก (outer area)
2. จำนวนพื้นที่ด้านใน (inner area)

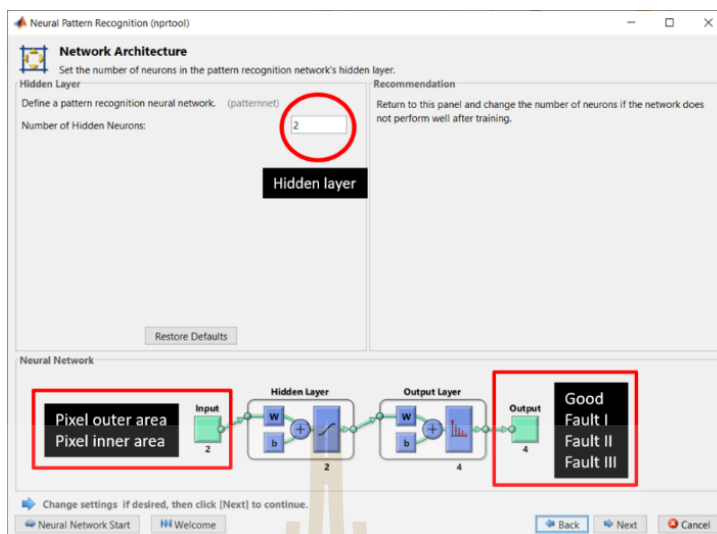
3.6.2.2 วิธีการทดสอบ

การที่จะสอน Neural Network ให้สามารถพยากรณ์ผลลัพธ์ของสิ่งต่าง ๆ ที่ต้องการได้ จำเป็นต้องมีปัจจัยที่สำคัญอย่างยิ่ง ได้แก่ ข้อมูลป้อนเข้า (Input) และเป้าหมาย (Target) ซึ่งข้อมูลทั้งสองจะมีความสัมพันธ์ต่อกัน และการที่จะทำให้โมเดลของ Neural Network จะสามารถทำการพยากรณ์ได้อย่างถูกต้อง และจำเป็นต้องมีข้อมูลอินพุตที่มากเพียงพอเพื่อที่จะสอนให้โมเดลสามารถเรียนรู้ถึงความสัมพันธ์ของข้อมูลอินพุตได้ สามารถแสดงผลลัพธ์ของข้อมูลที่พยากรณ์ออกมาในรูปแบบข้อมูลเป้าหมาย (Target) ได้อย่างถูกต้องและแม่นยำ โดยโมเดลนี้จะเลือกใช้ข้อมูลอินพุต 2 คุณลักษณะเด่น คือ จำนวนพื้นที่พิกเซลด้านนอก (pixel outer area) และจำนวนพื้นที่พิกเซลด้านใน (pixel inner area) ซึ่งมีจำนวนข้อมูลทั้งหมด 1,500 ตัวอย่าง จากนั้นเลือกข้อมูลเป้าหมาย (Target) โดยแบ่งกลุ่มหรือคลาของตัวอย่างออกเป็น 4 คลาส กำหนดเป้าหมายเป็นค่า 1

และคลาสที่ไม่ใช่เป้าหมายเป็น 0 หลังจากการกำหนด Input และ Target เรียบร้อยแล้ว เข้าสู่กระบวนการเรียนรู้ของโมเดล โดยแบ่งข้อมูลออกเป็น 3 ส่วน คือ Training 80% (1200 ตัวอย่าง), Validation 10% (150 ตัวอย่าง), และ Test 10% (150 ตัวอย่าง) จากนั้นสามารถแบ่งโครงสร้างการทำงานของโครงข่ายออกได้เป็น Input, Hidden Layer, Output Layer และ Output ซึ่งเครื่องมือนี้สามารถปรับค่าหรือใส่จำนวน Hidden Layer ลงไปให้เหมาะสมได้ ซึ่งในส่วนของ Hidden Layer นี้มีหน้าที่สำคัญในการพยายามแปลงข้อมูลที่เข้าให้สามารถแยกแยะความแตกต่างได้โดยใช้ Linearly Separable ซึ่งจำนวน Hidden Layer ควรมีความสัมพันธ์ Input และ Output Layer เพื่อให้ได้ประสิทธิภาพของโครงข่ายที่ดีที่สุด หากมีการกำหนด Hidden layer ที่น้อยหรือมากเกินไปอาจทำให้ความถูกต้องในการพยากรณ์ผลลัพธ์ลดลง ซึ่งในงานวิจัยนี้จะกำหนด Hidden layer มีค่าเท่ากับ 2 หลังจากนั้นจะเข้าสู่กระบวนการเรียนรู้ของข้อมูล แสดงวิธีการทดสอบกรณีสองอินพุตดังรูปที่ 3.20 และแสดงโมเดลโครงข่ายประสาทเทียมกรณีสองอินพุตดังรูปที่ 3.21



รูปที่ 3.20 แสดงไดอะแกรมวิธีการทดสอบแบบสองอินพุต



รูปที่ 3.21 แสดงโมเดลโครงข่ายประสาทเทียมแบบสองอินพุต

3.6.2.3 กรณีที่ 2 สามอินพุต

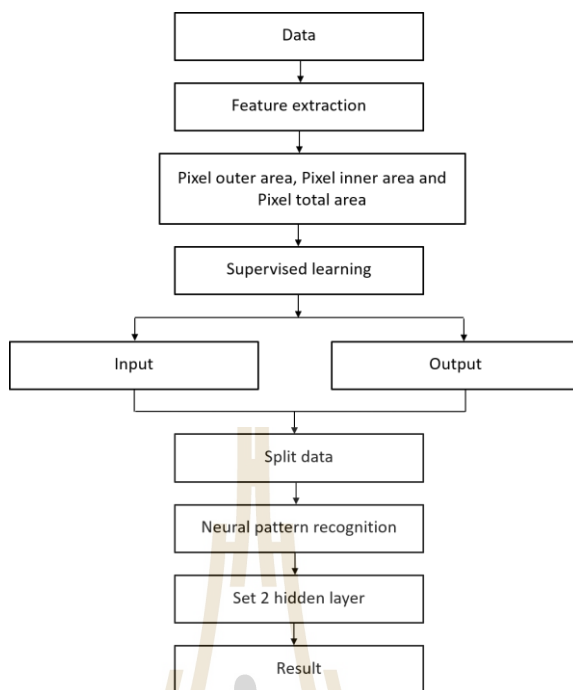
กรณี 3 อินพุต สิ่งที่จะนำมาเป็นคุณลักษณะในการแยกคลาสของระดับ

ข้อบกพร่องของ Mount head ได้แก่


1. จำนวนพื้นที่ด้านนอก (outer area)
2. จำนวนพื้นที่ด้านใน (inner area)
3. จำนวนพื้นที่ทั้งหมด (total area)

3.6.2.4 วิธีการทดสอบ

ในขั้นตอนการทดสอบกรณี 3 อินพุตก็จะมีรูปแบบการทดสอบที่เหมือนกันกับวิธีการทดสอบแบบ 2 อินพุต แต่แตกต่างตรงที่ขั้นตอนแรกในการเลือกอินพุตป้อนเข้าสู่โมเดลเพื่อให้เกิดการเรียนรู้ โดยจะทำการเลือกใช้ 3 คุณลักษณะเด่น คือ จำนวนพื้นที่พิกเซลด้านนอก, จำนวนพื้นที่พิกเซลด้านใน และจำนวนพื้นที่พิกเซลทั้งหมด ซึ่งมีจำนวนข้อมูลทั้งหมด 1,500 ตัวอย่าง จากนั้นการทดสอบมีวิธีการทำเช่นเดียวกันกับกรณี 2 อินพุต โดยเลือกข้อมูลเป้าหมาย (Target) และแบ่งกลุ่มหรือคลาสของตัวอย่างออกเป็น 4 คลาส หลังจากการกำหนด Input และ Target เรียบร้อยแล้วจะเข้าสู่กระบวนการเรียนรู้ของโมเดล โดยแบ่งข้อมูลออกเป็น 3 ส่วน คือ Training 80% (1200 ตัวอย่าง), Validation 10% (150 ตัวอย่าง), และ Test 10% (150 ตัวอย่าง) จะสามารถแบ่งโครงสร้างการทำงานของโครงข่ายออกได้เป็น Input, Hidden Layer, Output Layer และ Output ซึ่งในโมเดลนี้จะกำหนด Hidden layer มีค่าเท่ากับ 2 เช่นเดียวกันแสดงวิธีการทดสอบกรณีสามอินพุตดังรูปที่ 3.22 และแสดงโมเดลโครงข่ายประสาทเทียมกรณีสามอินพุตดังรูปที่ 3.23



รูปที่ 3.22 แสดงไดอะแกรมวิธีการทดสอบแบบสามอินพุต




รูปที่ 3.23 แสดงโมเดลโครงข่ายประสาทเทียมสามอินพุต

3.7 แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน

3.7.1 เตรียมข้อมูลสำหรับโครงสร้างประสาทเทียมแบบ CNN

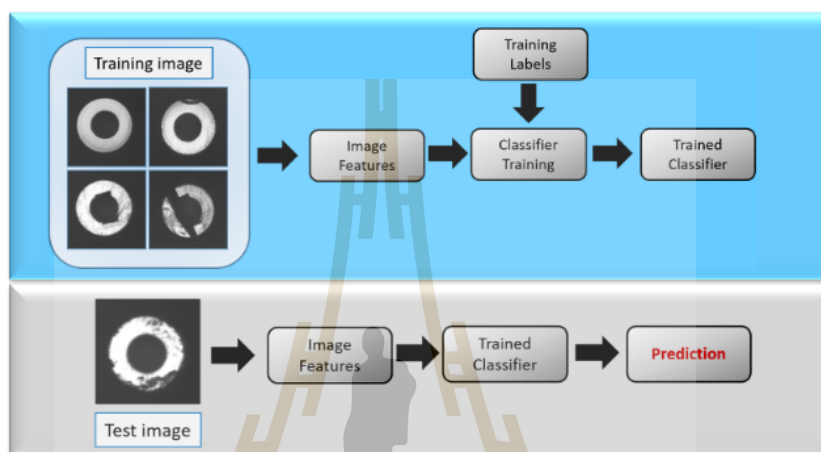
Convolutional Neural Network (CNN) หรือ โครงข่ายประสาทเทียมแบบคอนโวลูชัน คือ Neural Network ซึ่งเป็นโครงข่ายประสาทเทียมที่มีการลอกเลียนแบบมาจากสมองของมนุษย์ โดยที่ CNN จะจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นที่ย่อยๆ และนำกลุ่มของพื้นที่ย่อยๆ มาผสานกัน เพื่อดูว่าสิ่งที่เห็นคืออะไร ซึ่งการมองพื้นที่ย่อยของมนุษย์จะมีการแยกคุณลักษณะ (feature) ของพื้นที่ย่อยๆ เช่น ขอบ ลายเส้น ลักษณะพื้นผิว สี และการตัดกันของสี โดยการคำนวณใช้หลักการเดียวกันกับคอนโวลูชันเชิงพื้นที่ (Spatial Convolution) ในการทำงานด้าน Image Processing ซึ่งถูกนำมาใช้งานในด้าน Computer vision หรือ การวิเคราะห์รูปภาพ เช่น การจำแนกรูปภาพ, การตรวจจับวัตถุ, การเรียนรู้จดจำใบหน้า โดยการทดสอบด้วยโครงข่ายประสาทเทียมแบบ CNN จะใช้การเรียนรู้แบบ Supervised learning คือ การเรียนรู้แบบมีผู้สอน ซึ่งจะต้องสอนให้คอมพิวเตอร์หาความสัมพันธ์ระหว่างคำถามและคำตอบให้ได้ด้วยชุดข้อมูลสอน (Training Data) โดยจะจำแนกกลุ่มข้อมูลจากพื้นที่พิกเซลของ Mount head ตามระดับข้อบกพร่องสามารถแบ่งออกเป็น 4 ระดับ คือ Good, Fault I, Fault II และ Fault III ซึ่งข้อมูลทั้งหมด 1,500 รูปภาพ โดยนำมาแบ่งเป็น Training 80%, Test 10% และ Validation 10% แสดงดังรูปที่ 3.24 คือจะมีข้อมูลที่นำมาเป็นอินพุต 1,200 รูปภาพ เพื่อใช้สำหรับฝึกสอนข้อมูล (Training) มีข้อมูลไว้สำหรับทดสอบ (Test) 150 รูปภาพ และมีข้อมูลสำหรับตรวจสอบ (Validation) 150 รูปภาพ



รูปที่ 3.24 แสดงการแบ่งข้อมูลเพื่อใช้สร้างโมเดล CNN

รูปที่ 3.25 แสดงหลักการการทำงานของ CNN คือจะนำรูปที่เตรียมไว้สำหรับให้โมเดลเรียนรู้ (Training) เข้าสู่โมเดล โดยมันจะเรียนรู้ตามพิกเซลของรูปภาพเพื่อคัดคุณลักษณะเด่นออกมา (Feature) แต่ละรูปจะถูกแปลงเป็นเวกเตอร์ของคุณลักษณะ (feature vector) และการทำสัญลักษณ์ไว้ (label) เพื่อเป็นการบอกให้คอมพิวเตอร์สามารถรู้ว่รูปภาพนั้นคืออะไร จากนั้นเลือก

อัลกอริทึมเพื่อฝึกสอนให้โมเดลเรียนรู้ เมื่อโมเดลสิ้นเสร็จการเรียนรู้แล้ว นำรูปที่ยังไม่ผ่านกระบวนการ Training (รูปที่โมเดลยังไม่เคยเห็นมาก่อน) เข้าสู่โมเดล เพื่อทดสอบและตรวจสอบว่าโมเดลสามารถทำนายได้หรือไม่ ในงานวิจัยนี้จะเลือกใช้ Google colab ในกระบวนการสร้างโมเดลของ CNN ซึ่งเป็นเครื่องมือที่ฟรี มี GPU ที่เร็ว และ CPU ที่ดีเหมาะสำหรับการใช้รันงานที่จำเป็นต้องใช้พลังการคำนวณที่สูง

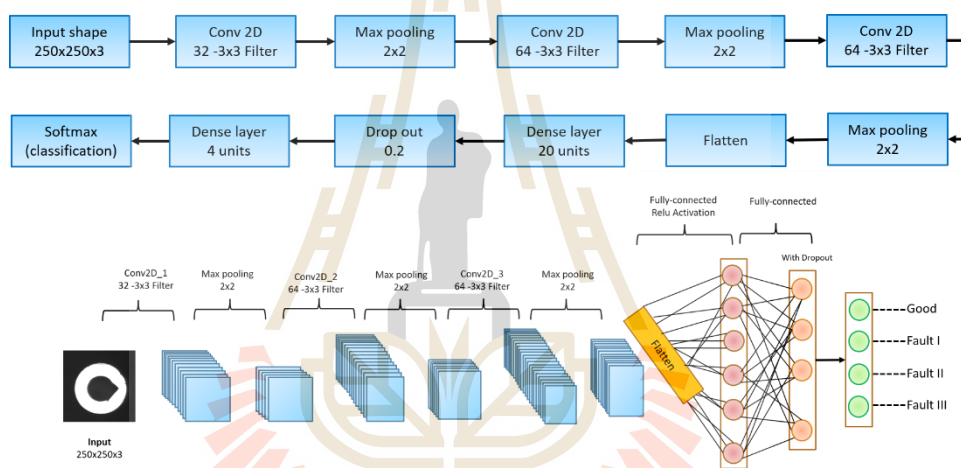


รูปที่ 3.25 แสดงหลักการเรียนรู้ของโมเดล CNN

3.7.2 โครงสร้างของโมเดล

ทดสอบการตรวจจับและการจำแนกข้อบกพร่องด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดย input จะเป็นรูปของ Mount head ที่มีขนาด 250x250 พิกเซล ซึ่งเป็นภาพแบบ 3 ชาติ (RGB) ดังนั้น CNN จะรับ input เข้ามาเป็น 250x250x3 จากนั้นจะผ่าน Convolution โดยเริ่มจากแตกนรูปภาพ Input โดยจะมีการสร้างตัวกรอง (Filter) ขึ้นมาในรูปแบบเมทริกซ์แบบ 3x3 เพื่อคัดคุณลักษณะเด่นหรือองค์ประกอบต่าง ๆ ของรูปภาพแต่ละภาพ จากนั้นใช้ Rectified Linear Unit (ReLU) เพื่อทำให้เกิดการเรียนรู้ของข้อมูลที่ได้รับมาจากขั้นตอนการตรวจสอบรูปภาพก่อนหน้า โดยข้อมูลจะถูกแปลงมาอยู่ในรูปของ non-linear เพื่อเข้ามาช่วยเพิ่มประสิทธิภาพของ CNN ในการประมวลผล แล้วพิจารณาว่าจะส่งต่อ output เท่าไร หลังจากนั้นทำ max pooling เพื่อลดขนาดของรูปภาพให้เล็กลงให้การทำงานของ CNN มีความรวดเร็วมากขึ้น และยังลดการใช้พื้นที่ความจำลงได้อีกด้วย กำหนดแบบ 2x2 (ขั้นตอนดังกล่าวถือเป็น 1 layer) จากนั้นทำตามขั้นตอนเดิมอีก โดยผ่านตัวกรอง (Filter) แบบ 3x3 และ max pooling แบบ 2x2 (layer ที่ 2) และผ่านตัวกรอง Filter แบบ 3x3 และ max pooling แบบ 2x2 (layer ที่ 3) รวมทั้งสิ้น 3 Hidden layers จากนั้นจะเข้าสู่กระบวนการ

ของการจำแนก (Classification) โดยทำ Flatten คือการแปลงข้อมูล 3 มิติให้อยู่ใน 1 มิติ เพื่อนำข้อมูลเข้าสู่กระบวนการของโมเดล multi-layer perceptron (Neural Network) จะประกอบไปด้วย layer แบบ fully connected (จะเชื่อมกับทุก node ของ layer ก่อนหน้า) โดยกำหนดทั้งหมด 20 Dense (Node) แล้วเพิ่ม Drop out 0.2 เพื่อช่วยลดปัญหา over fitting จากนั้นจึงส่งข้อมูลไปขั้นตอนต่อไปโดยกำหนด 4 Dense (Node) เพื่อให้จำแนกผลลัพธ์ออกมาเป็น 4 output หลังจากนั้นจะผ่าน activation function อีกครั้ง โดยใช้ Softmax function เนื่องจากเป็นฟังก์ชันที่มีความสามารถในการจำแนกประเภท ซึ่งกระบวนการ train จะใช้ batch size 32 และสอนโมเดลด้วยข้อมูลทั้งหมด 100 รอบ แสดงกระบวนการเรียนรู้ของโมเดล CNN ดังรูปที่ 3.26 และตารางที่ 3.2 จะแสดงการบรรยายพารามิเตอร์ที่เกิดขึ้นในกระบวนการทำ CNN



รูปที่ 3.26 แสดงกระบวนการเรียนรู้ของโมเดล CNN

ตารางที่ 3.2 แสดงการบรรยายกระบวนการของโครงข่ายประสาทเทียมคอนโวลูชัน

Layer (Type)	Output shape	Parameter
Conv2D_1	(None, 248, 248, 32)	896
Activation_1 (Relu)	(None, 248, 248, 32)	0
Maxpooling2D_1	(None, 124, 124, 32)	0
Conv2D_2	(None, 122, 122, 64)	18496
Activation_2 (Relu)	(None, 122, 122, 64)	0
Maxpooling2D_2	(None, 61, 61, 64)	0
Conv2D_3	(None, 59, 59, 64)	36928
Activation_3 (Relu)	(None, 59, 59, 64)	0
Activation_3 (Relu)	(None, 29, 29, 64)	0
Flatten	(None, 53824)	0
Dense	(None, 40)	2153000
Activation (Relu)	(None, 40)	0
Dropout	(None, 40)	160
Dense	(None, 4)	164
Activation (Softmax)	(None, 4)	0
Total parameter: 2,209,484		
Trainable parameter: 2,209,484		
Non-trainable parameter: 0		

3.8 สรุป

วิธีการดำเนินงานวิจัยจะต้องมีความรู้พื้นฐาน และมีความเข้าใจในเชิงปฏิบัติ หลักการการทำงาน การออกแบบการทดลอง และในทางทฤษฎี ศึกษาเรียนรู้เทคนิคต่าง ๆ ที่จะสามารถนำมาประยุกต์ในงานวิจัยได้ โดยหลักการทำงานพื้นฐานที่เกี่ยวข้องกับฮาร์ดแวร์และซอฟต์แวร์ แบ่งเป็น 3 ส่วน คือ

ส่วนที่ 1 ศึกษาเครื่องจักร Auto Core Adhesive Mounting machine (ACAM) ที่ใช้ในกระบวนการติดตั้งหัวอ่านเขียนของฮาร์ดดิสก์ไดรฟ์ โดยจะต้องทราบหลักการทำงานและขั้นตอนต่าง ๆ ในกระบวนการติดตั้งหัวอ่าน ตลอดจนระบบควบคุม ระบบสุญญากาศ ที่อาจจะมีผลต่อการเกิดปัญหาหัวอ่านเขียนหล่นหายระหว่างการเคลื่อนที่ Slider Loss Defect (SLD) ที่ทำให้เครื่องจักร

จัดซื้อเครื่อง Alarm71 เพื่อพิจารณาหาปัจจัยที่มีผลในกระบวนการติดตั้งหัวอ่านเขียน

ส่วนที่ 2 เป็นความเข้าใจทฤษฎีที่เกี่ยวกับการออกแบบระบบตรวจจับและจำแนกข้อบกพร่อง เทคนิคการประมวลผลภาพเพื่อเพิ่มประสิทธิภาพของข้อมูลในการตรวจจับข้อบกพร่อง นอกจากนี้ยังมีการประยุกต์การเรียนรู้ของเครื่องจักร (machine learning) โดยใช้โครงข่ายประสาทเทียมเข้ามาช่วยในการตรวจจับข้อบกพร่อง จึงจำเป็นต้องเรียนรู้และเข้าใจในการออกแบบการทดลองเพื่อเก็บข้อมูล การเตรียมข้อมูล และการฝึกสอน โมเดลให้เกิดการเรียนรู้ ซึ่งต้องใช้ความรู้ทางด้านสถิติพื้นฐานและการเลือกใช้วิธีการสอน โมเดลที่เหมาะสม

ส่วนที่ 3 นำเทคนิคประมวลผลภาพมาร่วมใช้เพื่อเพิ่มประสิทธิภาพในการวินิจฉัยข้อบกพร่อง ซึ่งวิธีการนี้จะใช้ภาษา Python ในการเขียน โปรแกรม Visual Studio Code และวิเคราะห์หาพื้นที่พิกเซลของรูปภาพด้วยโปรแกรม Vision Pro เพื่อสร้างเงื่อนไขในการจัดกลุ่มความเสียหายตามระดับข้อบกพร่อง นอกจากนี้ยังสามารถเขียนโปรแกรมสำหรับงานทางด้านการเรียนรู้ของเครื่องจักร (Machine learning) โดยที่มีอัลกอริทึมใช้งานหลากหลาย และหนึ่งในนั้นคือโครงข่ายประสาทเทียมที่ผู้วิจัยเลือกนำมาใช้ในการตรวจจับ

เมื่อมีความเข้าใจในทฤษฎีและหลักการงานทั้งในส่วนของฮาร์ดแวร์และซอฟต์แวร์ ดังนั้นจะเริ่มทำการทดลอง โดยแบ่งออกเป็น 9 ขั้นตอนคือ

ขั้นตอนที่ 1 ออกแบบการทดลอง โดยจะต้องมีการวางแผนการทดลองและการเก็บข้อมูลเป็นอย่างดี เนื่องจากทำการทดลองและเก็บข้อมูลในกระบวนการผลิตจริง โดยเก็บข้อมูลรูปภาพของ Mount head ประกอบกับสัญญาณของแรงดันสุญญากาศและแรงดันไฟฟ้า เพื่อพิจารณาหาปัจจัยสำคัญของข้อมูลที่จะนำไปใช้ในการตรวจจับและวินิจฉัยข้อบกพร่อง จากการวิเคราะห์ข้อมูลเบื้องต้นพบว่า ข้อมูลของสัญญาณแรงดันสุญญากาศและแรงดันไฟฟ้าข้อมูลไม่มีนัยสำคัญและแนวโน้มตามระดับข้อบกพร่องที่เกิดขึ้น ไม่สามารถแยกแยะข้อมูลได้อย่างชัดเจนเพื่อที่จะสอนให้โมเดลเรียนรู้ได้ จึงสรุปว่าข้อมูลจากสัญญาณแรงดันสุญญากาศและแรงดันไฟฟ้าไม่มีนัยสำคัญที่จะนำมาใช้ในการตรวจจับข้อบกพร่อง ดังนั้นเมื่อพิจารณาจากรูปภาพของ Mount head พบว่ามีแนวโน้มการเปลี่ยนแปลงตามระดับของข้อบกพร่องที่เกิดขึ้น จึงนำรูปภาพมาใช้ในการตรวจจับและจำแนกข้อบกพร่องในงานวิจัยนี้

ขั้นตอนที่ 2 นำข้อมูลรูปที่ได้มาประยุกต์ใช้เทคนิคการประมวลผลภาพเพื่อเพิ่มจำนวนข้อมูล เพื่อที่จะเพิ่มประสิทธิภาพในการตรวจจับข้อบกพร่อง โดยจะใช้เทคนิคการปรับความสว่างของภาพ และการครอบตัดส่วนที่สำคัญของภาพเพื่อนำไปใช้ในการวิเคราะห์

ขั้นตอนที่ 3 ทำการวิเคราะห์หาจำนวนพื้นที่พิกเซลของรูปภาพ โดยจะพิจารณาทุกส่วนของรูปที่มีนัยสำคัญต่อการตรวจจับข้อบกพร่อง คือจำนวนพื้นที่พิกเซลด้านนอก, จำนวนพื้นที่พิกเซลด้านใน และจำนวนพื้นที่พิกเซลรวมทั้งหมดของรูปภาพ Mount head เพื่อนำมาสร้างเกณฑ์พิกเซลด้านใน และจำนวนพื้นที่พิกเซลรวมทั้งหมดของรูปภาพ Mount head เพื่อนำมาสร้างเกณฑ์ในการจัดกลุ่มความเสียหายตามระดับข้อบกพร่องที่เกิดขึ้นในกระบวนการผลิตหัวอ่านเขียน

ขั้นตอนที่ 4 เป็นการเตรียมชุดข้อมูลเพื่อใช้ในการสร้างโมเดลเพื่อให้เรียนรู้ โดยข้อมูล 100% จะแบ่งข้อมูลออกเป็น 80% ใช้สำหรับการฝึกสอน, 10% ใช้สำหรับการทดสอบ และอีก 10% ใช้สำหรับการตรวจสอบ จากนั้นนำข้อมูลเข้าสู่โมเดล Artificial Neural Network (ANN) ซึ่งในขั้นตอนนี้จะใช้การเขียนโปรแกรมด้วย MATLAB/M-file เพื่อสร้างชุดข้อมูลอินพุตและเอาต์พุตสำหรับฝึกสอนที่เหมาะสม โดยแบ่งเป็น 2 กรณี คือ กรณีที่ 1 แบบ 2 อินพุต คือ จำนวนพื้นที่พิกเซลด้านนอก และจำนวนพื้นที่พิกเซลด้านใน และกรณีที่ 2 แบบ 3 อินพุต คือ จำนวนพื้นที่พิกเซลด้านนอก, จำนวนพื้นที่พิกเซลด้านใน และจำนวนพื้นที่พิกเซลทั้งหมด เพื่อเปรียบเทียบว่าจำนวนอินพุตที่ป้อนเข้าไปเพื่อให้โมเดลเรียนรู้ มีประสิทธิภาพของความถูกต้องในการตรวจจับและจำแนกข้อบกพร่องเป็นเช่นไร

ขั้นตอนที่ 5 ใช้โครงข่ายประสาทเทียมแบบ Convolution Neural Network (CNN) มาใช้ในการตรวจจับและจำแนกข้อบกพร่อง โดยจะใช้การเขียนโปรแกรมภาษาไพธอนบน Google Colab เพื่อสร้างโมเดลในการประมวลผล เพื่อเปรียบเทียบประสิทธิภาพในการตรวจจับและจำแนกข้อบกพร่องกับ ANN โดยจะใช้รูปภาพความเสียหายของ Mount head ตามระดับของข้อบกพร่องเป็นอินพุตที่ป้อนเข้าไปให้โมเดลเกิดการเรียนรู้

บทที่ 4

ผลการศึกษา และการวิเคราะห์ผล

4.1 บทนำ

ในบทนี้จะเป็นการทดสอบการตรวจจับและจำแนกข้อบกพร่องโดยวิเคราะห์จากรูปภาพของ Mount head ที่มีสภาพความเสียหายจากการทำงานหรือการเสื่อมอายุ ซึ่งจะส่งผลให้ Mount head เกิดการสูญเสียแรงดันสูญญากาศทำให้หัวอ่านเขียนหล่นหายระหว่างการเคลื่อนที่ไปติดตั้งและเครื่องจักรเกิด Alarm71 ดังนั้นจึงนำกลไกการทำงานอย่างชาญฉลาดมาประยุกต์ใช้ โดยมีชุดข้อมูลที่เตรียมไว้เพื่อสร้างแบบจำลองโครงข่ายประสาทเทียม เพื่อจำแนกข้อบกพร่องของ Mount head เป็น 4 ระดับ คือ Good, Fault I, Fault II และ Fault III และศึกษาอายุการใช้งานของ Mount head ทั้งแบบปกติและแบบผิดปกติ เพื่อประกอบกับการวินิจฉัยการทำงานของ Mount head ในกระบวนการติดตั้งหัวอ่านเขียน

โดยการทดสอบจะเปรียบเทียบค่าความถูกต้องในการจำแนกของโครงข่ายประสาทเทียม นิวรอลเน็ตเวิร์กด้วยการใช้ข้อมูลจำนวนพิกเซลเพื่อให้โมเดลเกิดการเรียนรู้แบ่งเป็น 2 กรณี คือ แบบสองอินพุต (จำนวนพิกเซลด้านนอกและจำนวนพิกเซลด้านใน) และสามอินพุต (จำนวนพิกเซลด้านนอก, จำนวนพิกเซลด้านใน และจำนวนพิกเซลทั้งหมด) และเปรียบเทียบอีกหนึ่งอัลกอริทึมคือ โครงข่ายประสาทเทียมคอนโวลูชัน โดยจะใช้รูปภาพเป็นอินพุตเพื่อให้โมเดลเกิดการเรียนรู้


4.2 ผลการตรวจจับข้อบกพร่องของโครงข่ายประสาทเทียมนิวรอลเน็ตเวิร์ก

4.2.1 การจำแนกข้อบกพร่องแบบสองอินพุต

4.2.1.1 กระบวนการเรียนรู้แบบสองอินพุต


หลังจากผ่านกระบวนการเรียนรู้ของข้อมูลแล้ว โปรแกรมจะแสดงข้อมูลต่าง ๆ ที่เกิดจากกระบวนการ เช่น ประสิทธิภาพ, จำนวนรอบในการเรียนรู้, เวลาที่ใช้ รวมทั้งแสดงกราฟ Confusion matrix และ Receiver Operating Characteristic เพื่อตรวจสอบความสามารถในการตรวจจับและจำแนกข้อบกพร่องได้ จากโมเดลนี้จะความสามารถในการจำแนกข้อบกพร่องที่ความถูกต้องที่สูงที่สุด จากรูปที่ 4.1 จะเห็นว่ามีจำนวนรอบในการเรียนรู้ (Training) ที่ดีที่สุดของข้อมูล 66 รอบ และจำนวนรอบในการตรวจสอบข้อมูล (Validation) ที่ดีที่สุดของข้อมูลชุดนี้ คือ 60 รอบ ดังแสดงให้

เห็นในรูปที่ 4.2 จากกราฟจะเห็นได้ว่าข้อมูลมีการเรียนรู้ที่ดีทั้งการฝึกสอน, การทดสอบ และการตรวจสอบข้อมูล



รูปที่ 4.1 แสดงรายละเอียดในกระบวนการที่ถูกต้องสูงที่สุดของสองอินพุต

มหาวิทยาลัยเทคโนโลยีสุรนารี



รูปที่ 4.2 แสดงประสิทธิภาพในการตรวจสอบของสองอินพุต

4.2.1.2 การประเมินผลการจำแนกด้วยคอนฟิวชันเมทริกซ์

คอนฟิวชันเมทริกซ์เป็นการประเมินผลลัพธ์ในการทำงานของโมเดลเปรียบเทียบกับผลลัพธ์จริง โดยจะแบ่งออกเป็นเอาต์พุตจาก โมเดล (Output Class) และเอาต์พุตจริง (Target Class) ในแต่ละแถวและหลักคือกรณีของ Mount head ที่สภาพดีและที่เกิดข้อบกพร่อง แถวขวาสุดและล่างสุดในแต่ละช่องจะเป็นการคำนวณหาค่าความถูกต้องและค่าความผิดพลาดของการจำแนกข้อบกพร่องในแต่ละระดับข้อบกพร่อง โดยที่ความถูกต้องโดยรวมจะสามารถหาได้จากแนวทะแยงของคอนฟิวชันเมทริกซ์ พิจารณารูปที่ 4.3 คือคอนฟิวชันเมทริกซ์ของการจำแนกข้อบกพร่องของ Mount head ประกอบด้วย ฟิวชันเมทริกซ์สำหรับการฝึกสอน ฟิวชันเมทริกซ์สำหรับการประเมินผล ฟิวชันเมทริกซ์สำหรับการทดสอบ และผลรวมของฟิวชันเมทริกซ์ในการจำแนกข้อบกพร่อง ซึ่งจะเห็นว่าจะเห็นได้ว่า Training confusion matrix มีค่าความถูกต้อง 95.6% มีค่าเปอร์เซ็นต์ Error เป็น 4.4% Validation confusion matrix มีค่าความถูกต้อง 94.7% มีค่าเปอร์เซ็นต์ Error เป็น 5.3% Test confusion matrix มีค่าความถูกต้อง 98.7% มีค่าเปอร์เซ็นต์ Error เป็น 1.3% และ All confusion matrix มีค่าความถูกต้อง 95.8% มีค่าเปอร์เซ็นต์ Error เป็น 4.2%


Training Confusion Matrix						Validation Confusion Matrix							
Output Class	Good	173	10	0	1	94.0%	Output Class	Good	19	1	0	0	95.0%
	Fault I	17	564	21	0	93.7%		Fault I	4	61	2	0	91.0%
	Fault II	0	0	185	0	100%		Fault II	0	0	26	0	100%
	Fault III	0	0	4	225	98.3%		Fault III	0	0	1	36	97.3%
		91.1%	98.3%	88.1%	99.6%	95.6%			82.6%	98.4%	89.7%	100%	94.7%
		8.9%	1.7%	11.9%	0.4%	4.4%			17.4%	1.6%	10.3%	0.0%	5.3%
		Good	Fault I	Fault II	Fault III			Good	Fault I	Fault II	Fault III		
		Target Class						Target Class					

Test Confusion Matrix						All Confusion Matrix							
Output Class	Good	27	0	0	0	100%	Output Class	Good	219	11	0	1	94.8%
	Fault I	0	57	2	0	96.6%		Fault I	21	682	25	0	93.7%
	Fault II	0	0	32	0	100%		Fault II	0	0	243	0	100%
	Fault III	0	0	0	32	100%		Fault III	0	0	5	293	98.3%
		100%	100%	94.1%	100%	98.7%			91.3%	98.4%	88.0%	99.7%	95.8%
		0.0%	0.0%	5.9%	0.0%	1.3%			8.8%	1.6%	11.0%	0.3%	4.2%
		Good	Fault I	Fault II	Fault III			Good	Fault I	Fault II	Fault III		
		Target Class						Target Class					

รูปที่ 4.3 คอนฟิวชันเมตริกซ์ของโมเดลที่มีความถูกต้องสูงที่สุดของสองอินพุต

4.2.1.3 การประเมินผลประสิทธิภาพของแบบ โมเดล

ประเมินการทดสอบประสิทธิภาพจาก Receiver operating characteristic curve (ROC curve) ซึ่งจะใช้จุด cut-off ที่เหมาะสมที่สุด ณ จุดที่มีความแม่นยำของ test เกิดขึ้นสูงที่สุด จากการคำนวณ sensitivity, specificity ของแต่ละ test value กรณีใช้ค่าอื่น ๆ เป็น cut-off value ของการวินิจฉัย เพื่อให้การจำแนกมีความถูกต้องมากที่สุด โดยคำนวณในแต่ละจุด แล้วเอาค่าที่คำนวณได้มา plot ลงบน ROC curve จะได้ curve ที่มีลักษณะโค้ง ๆ โกง ๆ เข้าหามุม ถ้า test ที่ perfect ควรจะมีจุดมุมนี้เข้าใกล้มุมซ้ายบนมากที่สุด เพราะว่ามีมุมซ้ายบนของ ROC curve จะเป็นจุดที่ sensitivity = 100% และ specificity = 100% จากรูปที่ 4.4 จะมีการ test ที่แตกต่างอยู่ 4 ระดับ คือ Good, Fault I, Fault II และ Fault III จะเห็นว่า ROC curve ของ Fault III มีค่าความถูกต้องและแม่นยำที่สุด รองลงมาคือสถานะ Good, Fault I และ Fault II ตามลำดับ




รูปที่ 4.4 แสดงการเปรียบเทียบประสิทธิภาพการตรวจจับของสองอินพุต


4.2.2 การจำแนกข้อบกพร่องแบบสามอินพุต

4.2.2.1 กระบวนการเรียนรู้แบบสามอินพุต

หลังจากผ่านการเรียนรู้ของข้อมูลแล้ว โปรแกรมจะแสดงข้อมูลต่าง ๆ ที่เกิดจากกระบวนการ จากรูปที่ 4.5 จะเห็นว่า มีจำนวนรอบในการเรียนรู้ (Training) ที่ดีที่สุดของข้อมูล 92 รอบ และจำนวนรอบในการตรวจสอบข้อมูล (Validation) ที่ดีที่สุดของข้อมูลชุดนี้ คือ 86 รอบ ดังแสดงให้เห็นในรูปที่ 4.6 จะเห็นได้ว่าลักษณะกราฟในการฝึกสอน, การทดสอบ และการตรวจสอบค่อนข้างไม่นิ่ง อาจเกิดจากอินพุตที่ป้อนเพิ่มเข้าไป คือ จำนวนพื้นที่พิกเซลทั้งหมดเป็นข้อมูลไม่มีนัยสำคัญที่เด่นชัดมากพอทำให้ใช้เวลาในการเรียนรู้ของข้อมูลมากขึ้น รวมถึงจำนวนรอบในการเรียนรู้ด้วย



รูปที่ 4.5 แสดงรายละเอียดในกระบวนการที่ถูกต้องสูงที่สุดของสามอินพุต



รูปที่ 4.6 แสดงประสิทธิภาพในการตรวจสอบของสามอินพุต

4.2.2.2 การประเมินผลการจำแนกด้วยคอนฟิวชันเมทริกซ์

คอนฟิวชันเมทริกซ์เป็นการประเมินผลลัพธ์ในการทำงานของโมเดลเปรียบเทียบกับผลลัพธ์จริง โดยจะแบ่งออกเป็นเอาต์พุตจากโมเดล (Output Class) และเอาต์พุตจริง (Target Class) พิจารณารูปที่ 4.7 คือคอนฟิวชันเมทริกซ์ของการจำแนกข้อบกพร่องของ Mount head ประกอบด้วย ฟิวชันเมทริกซ์สำหรับการฝึกสอน ฟิวชันเมทริกซ์สำหรับการประเมินผล ฟิวชันเมทริกซ์สำหรับการทดสอบ และผลรวมของฟิวชันเมทริกซ์ในการจำแนกข้อบกพร่อง ซึ่งจะเห็นได้ว่า Training confusion matrix มีค่าความถูกต้อง 94.3% มีค่าเปอร์เซ็นต์ Error เป็น 5.8% Validation confusion matrix มีค่าความถูกต้อง 92.7% มีค่าเปอร์เซ็นต์ Error เป็น 7.3% Test confusion matrix มีค่าความถูกต้อง 96.0% มีค่าเปอร์เซ็นต์ Error เป็น 4.0% และ All confusion matrix มีค่าความถูกต้อง 94.3% มีค่าเปอร์เซ็นต์ Error เป็น 5.7%

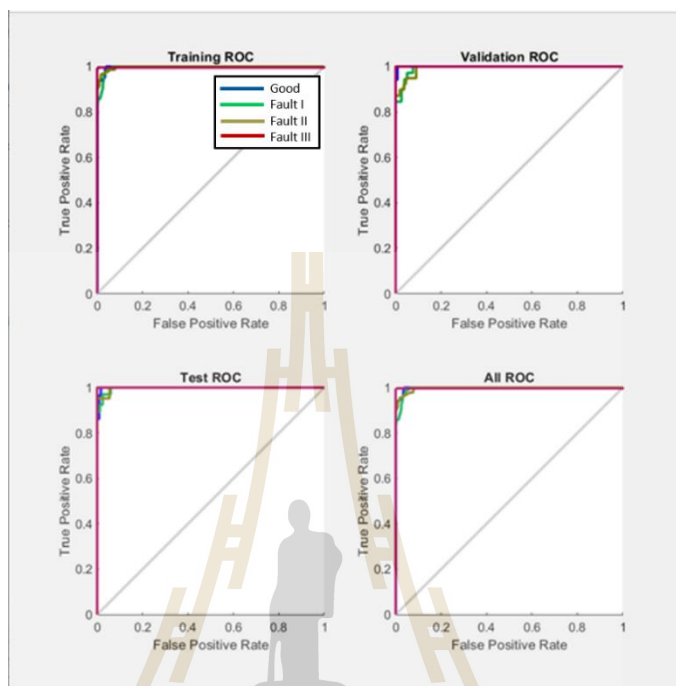
Training Confusion Matrix					Validation Confusion Matrix									
Output Class	Good	178 14.8%	6 0.5%	0 0.0%	1 0.1%	96.2%	3.8%	Good	19 12.7%	1 0.7%	0 0.0%	0 0.0%	95.0%	5.0%
	Fault I	21 1.8%	526 43.8%	9 0.8%	0 0.0%	94.6%	5.4%	Fault I	4 2.7%	70 46.7%	3 2.0%	0 0.0%	90.9%	9.1%
	Fault II	0 0.0%	13 1.1%	205 17.1%	11 0.9%	89.5%	10.5%	Fault II	0 0.0%	0 0.0%	23 15.3%	2 1.3%	92.0%	8.0%
	Fault III	0 0.0%	0 0.0%	8 0.7%	222 18.5%	96.5%	3.5%	Fault III	0 0.0%	0 0.0%	1 0.7%	27 18.0%	96.4%	3.6%
		89.4%	96.5%	92.3%	94.9%	94.3%		82.6%	98.6%	85.2%	93.1%	92.7%		
		10.6%	3.5%	7.7%	5.1%	5.8%		17.4%	1.4%	14.8%	6.9%	7.3%		
		Good	Fault I	Fault II	Fault III			Good	Fault I	Fault II	Fault III			
		Target Class						Target Class						
Test Confusion Matrix					All Confusion Matrix									
Output Class	Good	17 11.3%	1 0.7%	0 0.0%	0 0.0%	94.4%	5.6%	Good	214 14.3%	8 0.5%	0 0.0%	1 0.1%	96.0%	4.0%
	Fault I	1 0.7%	76 50.7%	1 0.7%	0 0.0%	97.4%	2.6%	Fault I	26 1.7%	672 44.8%	13 0.9%	0 0.0%	94.5%	5.5%
	Fault II	0 0.0%	0 0.0%	22 14.7%	2 1.3%	91.7%	8.3%	Fault II	0 0.0%	13 0.9%	250 16.7%	15 1.0%	89.9%	10.1%
	Fault III	0 0.0%	0 0.0%	1 0.7%	29 19.3%	96.7%	3.3%	Fault III	0 0.0%	0 0.0%	10 0.7%	278 18.5%	96.5%	3.5%
		94.4%	98.7%	91.7%	93.5%	96.0%		89.2%	97.0%	91.6%	94.6%	94.3%		
		5.6%	1.3%	8.3%	6.5%	4.0%		10.8%	3.0%	8.4%	5.4%	5.7%		
		Good	Fault I	Fault II	Fault III			Good	Fault I	Fault II	Fault III			
		Target Class						Target Class						

รูปที่ 4.7 คอนฟิวชันเมทริกซ์ของโมเดลที่มีความถูกต้องสูงที่สุดของสามอินพุต

4.2.2.3 การประเมินผลประสิทธิภาพของโมเดล

กราฟ ROC curve ของกรณีสามอินพุต จะเห็นได้ว่าการ test ที่แตกต่างกันอยู่ 4 ระดับ คือ Good, Fault I, Fault II และ Fault III จะเห็นว่า ROC curve ของ Fault III มีค่าความ

ถูกต้องและแม่นยำที่สุด แต่จะเห็นได้ว่าสถานะ Good, Fault I และ Fault II มีค่าความถูกต้องและแม่นยำที่ใกล้เคียงกันมากเนื่องจากกราฟค่อนข้างซ้อนทับกันอยู่ แสดงให้เห็นดังจากรูปที่ 4.8




รูปที่ 4.8 แสดงการเปรียบเทียบประสิทธิภาพการตรวจจับของสามอินพุต


4.3 การตรวจจับข้อบกพร่องของโครงข่ายประสาทเทียมคอนโวลูชัน

4.3.1 ผลการทดสอบการจำแนกข้อบกพร่อง

จากผลลัพธ์ชุดข้อมูลของ Mount head ที่ทำการจำแนกข้อบกพร่องแสดงให้เห็นว่ามีค่าความถูกต้องอยู่ที่ 87.66% สำหรับการฝึกสอนข้อมูล (Training) และเกิดการสูญเสีย (Loss) 0.2884% สำหรับการตรวจสอบ (Validation) ซึ่งโมเดลจะมีการจดจำรูปแบบและเรียนรู้เมื่อมีการฝึกสอนให้ข้อมูลมีการเรียนรู้ไปเรื่อยๆ ค่าความถูกต้อง (Accuracy) ก็จะค่อยๆ เพิ่มขึ้น และเกิดการสูญเสีย (Loss) จะค่อยๆ ลดลง แสดงดังรูปที่ 4.9 และสำหรับ Model Accuracy จะเห็นได้ว่ามี Accuracy 87.66% สำหรับ Training และ 86.13% สำหรับ Validation บ่งบอกว่า Accuracy ของ training มากกว่าจะทำให้ข้อมูลมีการจดจำรูปแบบของ train set ถ้าหากเจอข้อมูลที่ไม่เคยเห็นมาก่อนใน validation set อาจจะทำให้การจำแนกหรือการทำนายผิดพลาดไป แสดงดังรูปที่ 4.10



รูปที่ 4.9 แสดงความถูกต้องในการฝึกสอนและการสูญเสียจากการตรวจสอบของโมเดล CNN



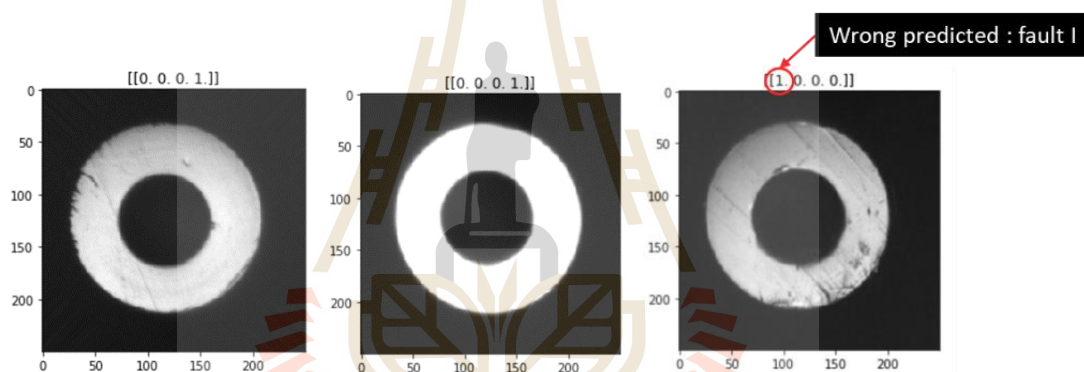
รูปที่ 4.10 แสดงความถูกต้องของ โมเดล CNN

4.3.2 การทดสอบการทำนายประสิทธิภาพในการจำแนก

การทดสอบประสิทธิภาพในการตรวจจับและจำแนกข้อบกพร่อง โดยผลลัพธ์ที่จำแนกมีทั้งหมด 4 ระดับ ได้แก่ Fault I, Fault II, Fault III และ Good ซึ่งผลลัพธ์จะแสดงเป็นตัวเลข 0 และ 1 ที่ออกมาในรูปแบบ [1, 0, 0, 0] ตามลำดับ โดย 1 จะหมายถึงผลลัพธ์ที่ทำนายออกมาเป็นระดับนั้น ๆ อย่างเช่นกรณีนี้ สามารถทำนายได้ว่าลักษณะข้อบกพร่องเป็นแบบ Fault I นั่นเอง

4.3.2.1 การทดสอบการทำนายข้อบกพร่องแบบ Good

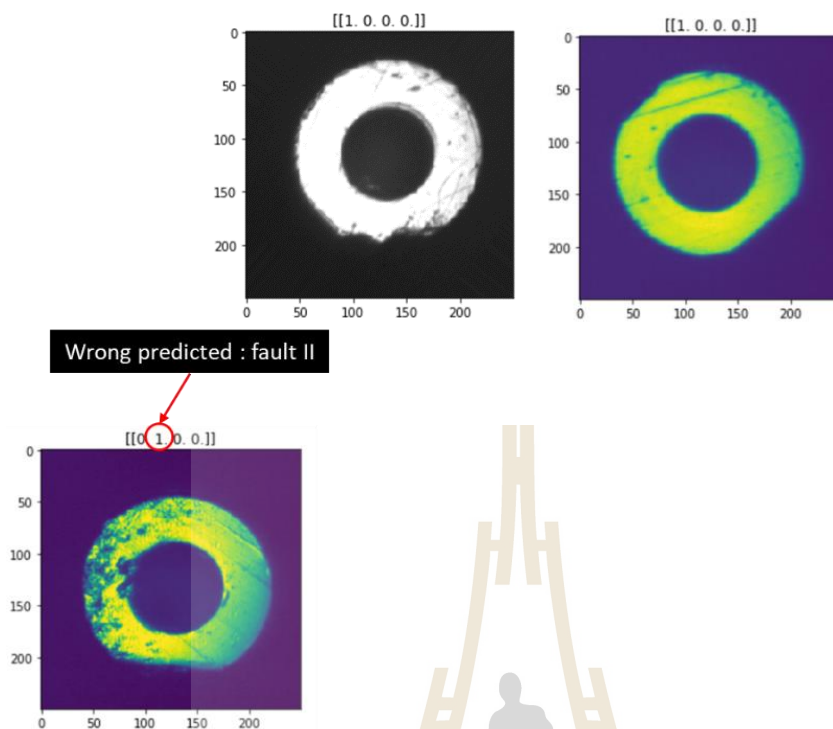
ทำการทดสอบประสิทธิภาพในการจำแนกข้อบกพร่อง โดยนำรูปภาพที่จัดอยู่ในระดับข้อบกพร่องแบบ Good เข้าสู่โมเดล CNN ที่ได้จากระบบการมาทำการทดสอบและตรวจสอบความถูกต้องในการทำนาย จากรูปที่ 4.11 จะเห็นได้ว่ามีรูปภาพที่อยู่ในสภาพ Good ถูกทำนายผิดพลาดว่าเป็นสภาพ Fault I



รูปที่ 4.11 แสดงการทดสอบการทำนายข้อบกพร่องแบบ Good

4.3.2.2 การทดสอบการทำนายข้อบกพร่องแบบ Fault I

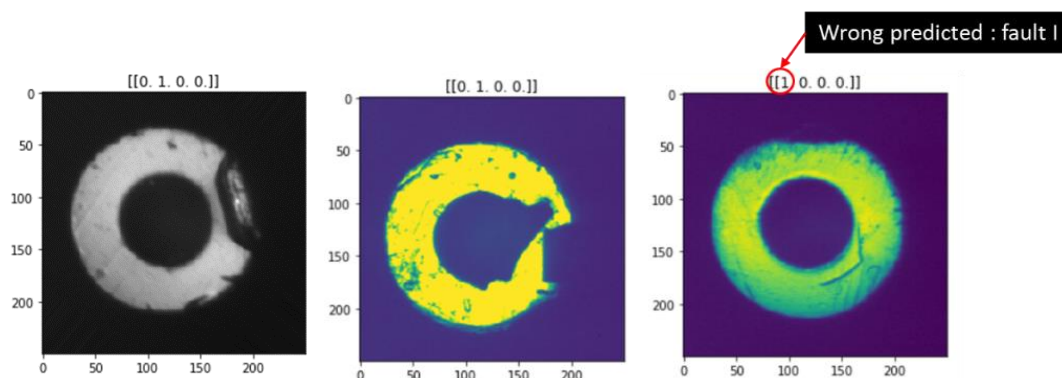
ทดสอบประสิทธิภาพในการจำแนกข้อบกพร่อง โดยนำรูปภาพที่จัดอยู่ในระดับข้อบกพร่องแบบ Fault I เข้าสู่โมเดล CNN ที่ได้จากระบบการมาทำการทดสอบและตรวจสอบความถูกต้องในการทำนาย จากรูปที่ 4.12 จะเห็นได้ว่ามีรูปภาพที่อยู่ในสภาพ Fault I ถูกทำนายผิดพลาดว่าเป็นสภาพ Fault II



รูปที่ 4.12 แสดงการทดสอบการทำนายข้อบกพร่องแบบ Fault I

4.3.2.3 การทดสอบการทำนายข้อบกพร่องแบบ Fault II


ทำการทดสอบประสิทธิภาพในการจำแนกข้อบกพร่อง โดยนำรูปภาพที่จัดอยู่ในระดับข้อบกพร่องแบบ Fault II เข้าสู่โมเดล CNN ที่ได้จากระบวนการมาทำการทดสอบและตรวจสอบความถูกต้องในการทำนาย จากรูปที่ 4.13 จะเห็นได้ว่ามีรูปภาพที่อยู่ในสภาพ Fault II ถูกทำนายผิดพลาดว่าเป็นสภาพ Fault I



รูปที่ 4.13 แสดงการทดสอบการทำนายข้อบกพร่องแบบ Fault II

4.3.2.4 การทดสอบการทำนายข้อบกพร่องแบบ Fault III

ทำการทดสอบประสิทธิภาพในการจำแนกข้อบกพร่อง โดยนำรูปภาพที่จัดอยู่ในระดับข้อบกพร่องแบบ Fault III เข้าสู่โมเดล CNN ที่ได้จากระบวนการมาทำการทดสอบ และตรวจสอบความถูกต้องในการทำนาย จากรูปที่ 4.14 จะเห็นได้ว่ามีรูปภาพที่อยู่ในสภาพ Fault III มีการทำนายที่ถูกต้อง ไม่มีการทำนายที่ผิดพลาดไปเป็นคลาสของระดับข้อบกพร่อง ๆ อื่น ๆ



รูปที่ 4.14 แสดงการทดสอบการทำนายข้อบกพร่องแบบ Fault III

4.4 วิเคราะห์ผลการตรวจจับและจำแนกข้อบกพร่อง

4.4.1 โครงข่ายประสาทเทียมนิวรอลเน็ตเวิร์ก Artificial Neural Network (ANN)

4.4.1.1 กรณีสองอินพุต

- %Recall (โมเดลสามารถตอบได้ถูกต้องสูงที่สุดในคลาส) คือ Fault III 99.7% > Fault I 98.4% > Good 91.3% > Fault II 89.0%

- %Precision (ความแม่นยำที่โมเดลสามารถตอบได้ถูกต้องสูงที่สุดเมื่อเทียบกับคลาสอื่น ๆ) คือ Fault II 100% > Fault III 98.3% > Good 94.8% > Fault I 93.7%

- %Accuracy (ความถูกต้องและความแม่นยำโดยรวมของโมเดล) คือ 95.8%

- โมเดลนี้สามารถช่วยลดปัญหา SLD และ Alarm71 ได้ 1.916%

4.4.1.2 กรณีสามอินพุต

- %Recall คือ Fault I 97.0% > Fault III 94.6% > Fault II 91.6% > Good 89.0%

- %Precision คือ Fault III 96.5% > Good 96.0% > Fault I 94.5% > Fault II 89.9%

- %Accuracy คือ 94.3%

- โมเดลนี้สามารถช่วยลดปัญหา SLD และ Alarm71 ได้ 1.886%

4.4.2 โครงข่ายประสาทเทียมคอนโวลูชัน Convolution Neural Network (CNN)

- %Accuracy คือ 87.7%

- โมเดลนี้สามารถช่วยลดปัญหา SLD และ Alarm71 ได้ 1.756%

ตารางที่ 4.1 แสดงผลเปรียบเทียบค่าความถูกต้องในการจำแนกข้อบกพร่อง

Algorithms	Input	Class	Recall (%)		Precision (%)		Accuracy Training (%)	Accuracy Validation (%)
			Accuracy (%)	Error (%)	Accuracy (%)	Error (%)		
Artificial Neural Network (ANN)	2 Input	Good	91.3	8.8	94.8	5.2	95.6	94.7
		Fault I	98.4	1.6	93.7	6.3		
		Fault II	89.0	11.0	100	0		
		Fault III	99.7	0.3	98.3	1.7		
	3 Input	Good	89.2	10.8	96.0	4.0	94.3	92.7
		Fault I	97.0	3.0	94.5	5.5		
		Fault II	91.6	8.4	89.9	10.1		
Fault III		94.6	5.4	96.5	3.5			
Convolution Neural Network (CNN)	Image Mount head	Good	78.33	21.66	82.46	17.54	87.66	86.13
		Fault I	86.87	13.13	86.49	13.51		
		Fault II	86.62	15.38	81.91	18.09		
		Fault III	100.00	0.00	100.00	0.00		

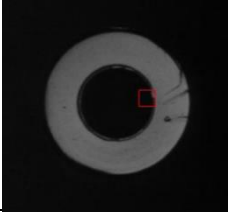
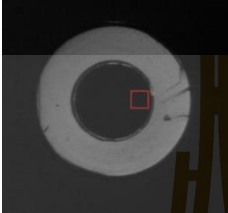




4.5 ศึกษาอายุการใช้งานของ Mount head

Mount head ถือเป็นองค์ประกอบที่สำคัญต่อกระบวนการผลิต เพราะเป็นส่วนที่ทำหน้าที่ติดตั้งหัวอ่านเขียนลงบนแกนจับของหัวอ่านเขียนโดยตรง ซึ่ง Mount head และหัวอ่านเขียนมีขนาดที่เล็กมากระดับไมครอน เพราะฉะนั้นจะต้องมีความถูกต้องและแม่นยำสูง จากปัญหาหัวอ่านเขียนหล่นหายระหว่างการเคลื่อนที่ พบว่าเกิดจากการสูญเสียแรงดันสุญญากาศ ซึ่งมีสาเหตุมาจาก Mount head เกิดความเสียหายหรือเสื่อมอายุขึ้น โดยลักษณะความเสียหายจะไม่มีรูปแบบที่แน่นอน ขึ้นอยู่กับหลาย ๆ ปัจจัย ดังนั้นจึงศึกษาอายุการใช้งานของ Mount head แบบปกติและแบบผิดปกติ เพื่อดูอายุการใช้งาน ระยะเวลา จำนวนวัน รวมทั้งจำนวนอัตราการผลิตหัวอ่านเขียน

4.5.1 อายุใช้งานแบบปกติ


จากการศึกษาอายุการใช้งานของ Mount head ในกระบวนการผลิตจริง โดยทำการเก็บรูปภาพของ Mount head วันและเวลาที่ใช้งาน รวมไปถึงจำนวนอัตราการผลิต จากนั้นนำรูปภาพ Mount head ไปวิเคราะห์หาจำนวนพื้นที่พิกเซลด้านนอก (outer area), จำนวนพื้นที่พิกเซลด้านใน (inner area) และ จำนวนพื้นที่พิกเซลทั้งหมด (Total area) เพื่อจัดกลุ่มตามระดับข้อบกพร่อง พบว่าในช่วงการใช้งาน 1-2 วันแรก Mount head จะมีสถานะแบบ Good คือปกติดีสามารถผลิตได้ โดยไม่มีปัญหาใด ๆ มีจำนวนพื้นที่พิกเซลด้านนอกอยู่ในช่วง 21,564 – 19,493 พิกเซล มีจำนวนพื้นที่พิกเซลด้านในอยู่ในช่วง 5,707 – 5,801 พิกเซล และมีจำนวนพื้นที่พิกเซลทั้งหมดอยู่ในช่วง 27,271 – 25,294 พิกเซล สามารถผลิตหัวอ่านเขียนได้ประมาณ 5,241 ชิ้น จากนั้นการใช้งานวันที่ 3 จะเข้าสู่สภาพ Fault I คือ Mount head เริ่มเกิดความเสียหายขึ้นเล็กน้อย จะมีจำนวนพื้นที่พิกเซลด้านนอกอยู่ในช่วง 18,487 – 16,561 พิกเซล มีจำนวนพื้นที่พิกเซลด้านในอยู่ในช่วง 5,856 – 6,266 พิกเซล และมีจำนวนพื้นที่พิกเซลทั้งหมดอยู่ในช่วง 24,343 – 22,827 พิกเซล สามารถผลิตหัวอ่านเขียนได้ประมาณ 89,206 ชิ้น และสามารถใช้งานในสภาวะนี้ได้ประมาณ 12 วัน หลังจากนั้นจะเข้าสู่สภาพ Fault II คือมีความเสียหายเกิดมากขึ้นอาจจะส่งผลทำให้เกิดการสูญเสียแรงดันสุญญากาศ จากการวิเคราะห์จำนวนพื้นที่พิกเซลพบว่า มีจำนวนพื้นที่พิกเซลด้านนอกอยู่ในช่วง 15,999 – 15,625 พิกเซล มีจำนวนพื้นที่พิกเซลด้านในอยู่ในช่วง 6,269 – 6,469 พิกเซล และมีจำนวนพื้นที่พิกเซลทั้งหมดอยู่ในช่วง 22,268 – 20,987 พิกเซล สามารถผลิตหัวอ่านเขียนได้ประมาณ 130,781 ชิ้น และสามารถใช้งานในสภาวะนี้ได้ถึง 14 วัน สรุปว่าอายุการใช้งานของ Mount head แบบปกติสามารถใช้งานได้ประมาณ 24 วัน แสดงดังตารางที่ 4.2 จากนั้นผู้ปฏิบัติหน้างานจะทำการเปลี่ยน Mount head ใหม่ เนื่องจากเกิดความเสียหายค่อนข้างมากอาจจะทำให้เกิดการสูญเสียแรงดันสุญญากาศที่จะส่งผลกระทบต่อกระบวนการผลิต และการหยุดทำงานของเครื่องจักรได้

ตารางที่ 4.2 แสดงอายุการใช้งานของ Mount head แบบปกติ


Day	Fault Level	Image Mount head	Pixel outer	Pixel inner	Pixel total	HGA (unit)
(1) 15/02/2020 08:20	Good		21,564	5,707	27,271	New
(2) 16/02/2020 08:02	Good		19,493	5,801	25,294	5,241
(3) 16/02/2020 12:00	Fault I		18,487	5,856	24,343	7,303
(14) 28/02/2020 08:24	Fault I		16,561	6,266	22,827	89,206
(15) 29/02/2020 20:09	Fault II		15,999	6,269	22,268	92,905
(24) 01/03/2020 20:09	Fault II		15,625	6,469	20,987	130,781

จากรูป 4.15 – 4.17 จะเห็นได้ว่าในสภาพ Good จะมีอัตราการผลิตหัวอ่านประมาณ 5,241 ชิ้น และเมื่อเข้าสู่สภาพ Fault I สามารถผลิตหัวอ่านเขียนได้ประมาณ 89,206 ชิ้น และสภาพ Fault II มีอัตราการผลิตหัวอ่านเขียนประมาณ 130,781 ชิ้น จากรูป 4.15 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลด้านนอก (outer area) และอัตราการผลิตหัวอ่านเขียน จากกราฟจะเห็นได้ว่าจำนวน


พื้นที่พิกเซลด้านนอกจะมีแนวโน้มที่ลดลงตามอายุการใช้งานและจำนวนอัตราการผลิตหัวอ่านเขียน จากรูป 4.16 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลด้านใน (inner area) และอัตราการผลิตหัวอ่านเขียน จากกราฟจะเห็นได้ว่าจำนวนพื้นที่พิกเซลด้านในจะมีแนวโน้มที่เพิ่มขึ้นตามอายุการใช้งานและจำนวนอัตราการผลิตหัวอ่านเขียน และ จากรูป 4.17 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลทั้งหมด (Total area) และอัตราการผลิตหัวอ่านเขียน จากกราฟจะเห็นได้ว่าจำนวนพื้นที่พิกเซลด้านทั้งหมดจะมีแนวโน้มที่ลดลงตามอายุการใช้งานและจำนวนอัตราการผลิตหัวอ่านเขียน



รูปที่ 4.15 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลด้านนอกและอัตราการผลิตหัวอ่านเขียน



รูปที่ 4.16 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลด้านใน และอัตราการผลิตหัวอ่านเขียน


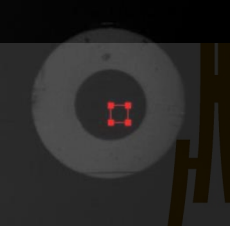
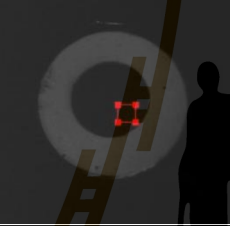

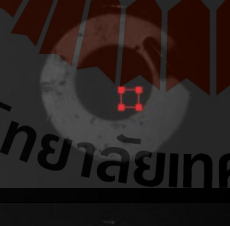
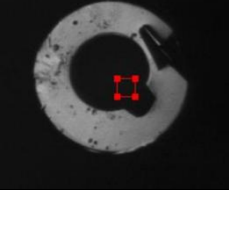


รูปที่ 4.17 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลทั้งหมด และอัตราการผลิตหัวอ่านเขียน

4.5.2 อายุใช้งานแบบผิดปกติ


จากการศึกษาอายุการใช้งานของ Mount head ในกระบวนการผลิตจริง โดยทำการเก็บรูปภาพของ Mount head วันและเวลาที่ใช้งาน รวมไปถึงจำนวนอัตราการผลิต จากนั้นนำรูปภาพ Mount head ไปวิเคราะห์หาจำนวนพื้นที่พิกเซลด้านนอก (outer area), จำนวนพื้นที่พิกเซลด้านใน (inner area) และจำนวนพื้นที่พิกเซลทั้งหมด (Total area) เพื่อจัดกลุ่มตามระดับข้อบกพร่อง พบว่าในช่วงการใช้งาน 1-2 วันแรก Mount head จะมีสภาพแบบ Good คือปกติสามารถผลิตได้ โดยไม่มีปัญหาใด ๆ มีจำนวนพื้นที่พิกเซลด้านนอกอยู่ในช่วง 20,106 – 19,584 พิกเซล มีจำนวนพื้นที่พิกเซลด้านในอยู่ในช่วง 5,497 – 5,556 พิกเซล และมีจำนวนพื้นที่พิกเซลทั้งหมดอยู่ในช่วง 25,603 – 25,140 พิกเซล สามารถผลิตหัวอ่านเขียนได้ประมาณ 11,937 ชิ้น จากนั้นการใช้งานวันที่ 3 จะเข้าสู่สภาพ Fault I คือ Mount head เริ่มเกิดความเสียหายขึ้นเล็กน้อย โดยมีจำนวนพื้นที่พิกเซลด้านนอกอยู่ในช่วง 18,456 – 17,430 พิกเซล มีจำนวนพื้นที่พิกเซลด้านในอยู่ในช่วง 5,568 – 6,167 พิกเซล และมีจำนวนพื้นที่พิกเซลทั้งหมดอยู่ในช่วง 24,024 – 23,597 พิกเซล สามารถผลิตหัวอ่านเขียนได้ประมาณ 30,743 ชิ้น และสามารถใช้งานในสภาพนี้ได้ประมาณ 3 วัน หลังจากนั้นจะเข้าสู่สภาพ Fault II คือมีความเสียหายเกิดมากขึ้นอาจจะส่งผลทำให้เกิดการสูญเสียแรงดันสุญญากาศจากการวิเคราะห์จำนวนพื้นที่พิกเซลพบว่า มีจำนวนพื้นที่พิกเซลด้านนอกอยู่ในช่วง 15,698 – 14,650 พิกเซล มีจำนวนพื้นที่พิกเซลด้านในอยู่ในช่วง 6,170 – 6,763 พิกเซล และมีจำนวนพื้นที่พิกเซลทั้งหมดอยู่ในช่วง 21,868 – 21,413 พิกเซล สามารถผลิตหัวอ่านเขียนได้ประมาณ 47,846 ชิ้น และสามารถใช้งานในสภาวะนี้ได้ถึง 2 วัน สรุปว่าอายุการใช้งานของ Mount head แบบผิดปกติสามารถใช้งานได้ประมาณ 8 วัน แสดงดังตารางที่ 4.3 จากนั้นผู้ปฏิบัติหน้างานจะทำการเปลี่ยน Mount head ใหม่ เนื่องจากเกิดความเสียหายค่อนข้างมาก ซึ่งเกิดจาก Mount head หยิบหัวอ่านเขียนในตำแหน่งที่ไม่ถูกต้องหรือไม่เหมาะสม จึงทำให้เกิดความเสียหายที่เร็วกว่าปกติ

ตารางที่ 4.3 แสดงอายุการใช้งานของ Mount head แบบฝัดปกติ


Day	Fault Level	Image Mount head	Pixel outer	Pixel inner	Pixel total	HGA (unit)
(1) 19/02/2020 00:00	Good		20,106	5,497	25,603	New
(2) 20/02/2020 20:12	Good		19,584	5,556	25,140	11,937
(3) 21/02/2020 20:09	Fault I		18,456	5,568	24,024	13,659
(6) 24/02/2020 04:08	Fault I		17,430	6,167	23,597	30,743
(7) 25/02/2020 00:50	Fault II		15,698	6,170	21,868	33,479
(8) 26/02/2020 00:12	Fault II		14,650	6,763	21,413	47,846

จากรูป 4.18 – 4.20 จะเห็นได้ว่าในสภาพ Good จะมีอัตราการผลิตหัวอ่านประมาณ 11,937 ชิ้น และเมื่อเข้าสู่สภาพ Fault I สามารถผลิตหัวอ่านเขียนได้ประมาณ 30,743 ชิ้น และสภาพ Fault II มีอัตราการผลิตหัวอ่านเขียนประมาณ 47,846 ชิ้น จากรูป 4.18 กราฟแสดงความสัมพันธ์ระหว่างจำนวน


พื้นที่พิกเซลด้านนอก (outer area) และอัตราการผลิตหัวอ่านเขียน จากกราฟจะเห็นได้ว่าจำนวนพื้นที่พิกเซลด้านนอกจะมีแนวโน้มที่ลดลงตามอายุการใช้งานและจำนวนอัตราการผลิตหัวอ่านเขียน จากรูป 4.19 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลด้านใน (inner area) และอัตราการผลิตหัวอ่านเขียน จากกราฟจะเห็นได้ว่าจำนวนพื้นที่พิกเซลด้านในจะมีแนวโน้มที่เพิ่มขึ้นตามอายุการใช้งานและจำนวนอัตราการผลิตหัวอ่านเขียน และ จากรูป 4.20 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลทั้งหมด (Total area) และอัตราการผลิตหัวอ่านเขียน จากกราฟจะเห็นได้ว่าจำนวนพื้นที่พิกเซลทั้งหมดจะมีแนวโน้มที่ลดลงตามอายุการใช้งานและจำนวนอัตราการผลิตหัวอ่านเขียน จากการศึกษายูการใช้งานของ Mount head แบบผิดปกติ จะเห็นได้ว่า Mount head มีอายุการใช้งานที่สั้นกว่าปกติถึง 2 เท่า และทำให้ผลิตหัวอ่านเขียนได้น้อยกว่าปกติ ซึ่งอาจเกิดจากความผิดพลาดขณะที่ Mount head ทำการหยิบหัวอ่าน เช่น หัวอ่านเขียนวางในตำแหน่งที่ไม่เหมาะสม, ระยะหัวอ่านเขียนไม่ถูกต้อง เป็นต้น



รูปที่ 4.18 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลด้านนอกและอัตราการผลิตหัวอ่านเขียน



รูปที่ 4.19 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลด้านใน และอัตราการผลิตหัวอ่านเขียน



รูปที่ 4.20 กราฟแสดงความสัมพันธ์ระหว่างจำนวนพื้นที่พิกเซลทั้งหมด และอัตราการผลิตหัวอ่านเขียน

4.6 สรุป

จากการนำการเรียนรู้ของเครื่องจักร (Machine learning) มาประยุกต์ใช้ โดยการสร้างโมเดลโครงข่ายประสาทเทียม Artificial Neural Network (ANN) ด้วยโปรแกรม MATLAB เพื่อเปรียบเทียบค่าความถูกต้องของโมเดลในแต่ละอินพุตที่แตกต่างกันเพื่อป้อนเข้าให้โมเดลเรียนรู้ ในการทดสอบมีการกำหนดจำนวน 2 Hidden layer เท่ากัน ซึ่งจะแบ่งเป็น 2 กรณี คือ 2 อินพุต (จำนวนพื้นที่พิกเซลด้านนอกและจำนวนพื้นที่พิกเซลด้านใน) และ 3 อินพุต (จำนวนพื้นที่พิกเซลด้านนอก, จำนวนพื้นที่พิกเซลด้านใน และจำนวนพื้นที่พิกเซลทั้งหมด) ผลของวิธีการฝึกสอนแบบ 2 อินพุต พบว่าโมเดลให้ความถูกต้องสูงที่สุดคือ 95.8% และใช้จำนวนรอบของการฝึกสอนทั้งหมด 66 รอบ ส่วนการฝึกสอนแบบ 3 อินพุต ให้ความถูกต้องสูงที่สุดคือ 94.3% และใช้จำนวนรอบของการฝึกสอนทั้งหมด 92 รอบ อาจเนื่องมาจากอินพุตที่เพิ่มเข้าไปคือ จำนวนพื้นที่พิกเซลทั้งหมดไม่มีนัยสำคัญที่มากเพียงพอที่จะทำให้โมเดลมีความถูกต้องและแม่นยำที่เพิ่มมากขึ้นอีกทั้งยังมีเวลาที่ใช้ในการเรียนรู้นานกว่า 2 อินพุต เพราะฉะนั้นจึงไม่จำเป็นที่จะต้องใช้อินพุตทั้งหมดของ Mount head ในการสร้างโมเดล และเมื่อพิจารณาการฝึกสอนโครงข่ายประสาทเทียมคอนโวลูชันพบว่าให้ความถูกต้องสูงที่สุดคือ 87.7% และใช้จำนวนรอบของการสอนทั้งหมด 100 รอบ เนื่องจาก CNN มีการเรียนรู้ที่จดจำรูปแบบจากรูปภาพ ถ้าหากมีข้อมูลที่ใช้ในการฝึกสอนที่มากขึ้น และเพิ่มจำนวนรอบการฝึกสอน อาจจะทำให้มีประสิทธิภาพความถูกต้องในการจำแนกข้อบกพร่องที่เพิ่มมากขึ้นได้ ดังนั้นวิธีการฝึกสอนด้วยโครงข่ายประสาทเทียม Artificial Neural Network (ANN) แบบ 2 อินพุต แสดงให้เห็นว่ามีประสิทธิภาพและให้ความรวดเร็วในการฝึกสอนโดยให้ค่าความถูกต้องสูงสุด ซึ่งในการเลือกใช้งานจริงสำหรับ โมเดลที่จะนำมาประยุกต์ใช้เพื่อแก้ปัญหาดังกล่าว จะต้องคำนึงถึงปัจจัยอื่น ๆ เช่น ระยะเวลาในการฝึกสอน, เวลาในการตัดสินใจ, ความเหมาะสมในการประยุกต์ใช้ เป็นต้น ซึ่งการตรวจจับและจำแนกข้อบกพร่องแบ่งออกเป็น 4 ระดับ คือ Good, Fault I, Fault II และ Fault III เมื่อมีการใช้งานไประยะหนึ่งระบบจะสามารถจำแนกได้ว่าสภาพของ Mount head อยู่ในระดับข้อบกพร่องใด ซึ่งเมื่อ Mount head อยู่ในสภาพ Fault II จะส่งสัญญาณแจ้งเตือนไปยังเครื่องจักรเพื่อแจ้งให้ผู้ปฏิบัติงานทำการเปลี่ยน Mount head เป็นชิ้นใหม่ที่อยู่ในสภาพ Good เพื่อหลีกเลี่ยงที่จะเข้าสู่สภาพ Fault III ที่จะทำให้เกิดการสูญเสียแรงดันสูญญากาศ ส่งผลปัญหาหัวอ่านเขียนหล่นหาย และมีผลกระทบทำให้เครื่องจักรขัดข้องเกิด Alarm71 และเครื่องจักรหยุดทำงานในที่สุด

บทที่ 5

สรุปและข้อเสนอแนะ

5.1 สรุป

แนวทางการสร้างความน่าเชื่อถือ (Reliability) ของระบบอัตโนมัติที่ประยุกต์ใช้ในกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ (Hard Disk Drive) ปัจจุบันมีการติดตามข้อมูลผ่านระบบต่าง ๆ เช่น Internet Of Thing (IOT), Fault Detection and Diagnosis (FDD) และ Fault Tolerant Control (FTC) เป็นต้น งานวิจัยนี้ได้วิเคราะห์หาสาเหตุข้อบกพร่องและสร้างระบบตรวจจับและวินิจฉัยข้อบกพร่อง (FDD) การหยุดทำงานของเครื่องจักร ที่เกิดจากปัญหาเครื่องจักรแสดงสถานะ Alarm71 อยู่ที่ 2% ในกระบวนการติดตั้งหัวอ่านเขียน มีสาเหตุมาจากหัวอ่านเขียนหล่นหายระหว่างการติดตั้ง (SLD) พบว่าแนวโน้มการเปลี่ยนแปลงสภาพของ Mount head เป็นข้อมูลที่สามารถนำไปจำแนกระดับข้อบกพร่องของเครื่องจักรได้ เราจึงได้ประยุกต์ใช้เทคนิค FDD เพื่อตรวจหาความผิดปกติจากสภาพการเปลี่ยนแปลงของ Mount head มาใช้ในการจำแนกระดับข้อบกพร่อง เพื่อประกอบการตัดสินใจในการวางแผนการเปลี่ยน Mount head ได้ทันก่อนที่จะเกิดการหล่นหายของหัวอ่านเขียนในกระบวนการติดตั้งหัวอ่านเขียนและเพื่อลดปัญหาดังกล่าว โดยประยุกต์ใช้โครงข่ายประสาทเทียม Artificial Neural Network (ANN) ที่มีความแตกต่างกันระหว่างสองอินพุตและสามอินพุตในการฝึกสอนเพื่อให้โมเดลเรียนรู้ และโครงข่ายประสาทเทียม Convolution Neural Network (CNN) เพื่อเปรียบเทียบประสิทธิภาพความถูกต้องในตรวจจับและจำแนกระดับข้อบกพร่อง เป็น 4 ระดับ ประกอบด้วย 1. Good 2. Fault I 3. Fault II และ 4. Fault III จากสภาพของ Mount head ขณะทำการติดตั้งหัวอ่านเขียน สามารถสรุปได้ดังนี้

1. ผลการทดสอบโครงข่ายประสาทเทียม Artificial Neural Network (ANN) แบบสองอินพุต (จำนวนพิกเซลด้านนอกและจำนวนพิกเซลด้านใน) พบว่ามีความสามารถในการตรวจจับและจำแนกระดับข้อบกพร่องของหัวอ่านเขียนสูงสุด คือ 95.8% สามารถช่วยลดปัญหา Alarm71 ได้ 1.916% ซึ่งเหลือเพียง 0.084% เท่านั้น ที่จะเกิดขึ้นในกระบวนการติดตั้งหัวอ่านเขียน

2. ผลการทดสอบโครงข่ายประสาทเทียม Artificial Neural Network (ANN) แบบสามอินพุต (จำนวนพิกเซลด้านนอก, จำนวนพิกเซลด้านใน และจำนวนพิกเซลทั้งหมด) มีความสามารถในการตรวจจับและจำแนกระดับข้อบกพร่องของหัวอ่านเขียน 94.3% สามารถช่วยลดปัญหา Alarm71 ที่มี

3. สาเหตุมาจาก SLD ของ Mount head ได้ 1.886% ซึ่งเหลือปัญหาเหลือ Alarm71 ในกระบวนการติดตั้งหัวอ่านเขียนเพียง 0.114%

4. ผลการทดสอบโครงข่ายประสาทเทียมแบบ Convolution Neural Network (CNN) มีสามารถในการตรวจจับและจำแนกข้อบกพร่องเพียง 87.7% สามารถลดปัญหา Alarm71 ได้ 1.756% เหลือ Alarm71 0.244% ในกระบวนการติดตั้งหัวอ่านเขียน ซึ่งโมเดลนี้มีความเหมาะสมที่จะนำไปประยุกต์ใช้ในเครื่องจักร แต่มีค่าความถูกต้องที่น้อยในการจำแนกระดับข้อบกพร่อง เนื่องจากมีข้อมูลไม่มากพอที่จะให้โมเดลเรียนรู้และจดจำรูปแบบในการตรวจจับและวินิจฉัยเพื่อจำแนกระดับข้อบกพร่อง

5. การประยุกต์ใช้การเรียนรู้ของเครื่องจักร (Machine learning) สามารถช่วยตรวจจับและจำแนกระดับข้อบกพร่องได้ เมื่อ Mount head มีการใช้งานจนเข้าสู่สภาพ Fault II ระบบจะทำการแจ้งเตือนไปยังเครื่องจักรเพื่อให้ผู้ปฏิบัติงานทำการเปลี่ยน Mount head ให้อยู่ในสภาพ Good เพื่อหลีกเลี่ยงการเข้าสู่สภาพ Fault III ที่จะทำให้เกิด SLD, Alarm 71 และ Machine downtime ในที่สุด เพราะฉะนั้นจึงสามารถลดปัญหา Alarm 71 ได้เกือบ 100% เพราะ Mount head สภาพ Fault III จะไม่มีทางเกิดสภาพขึ้นในกระบวนการติดตั้งหัวอ่านเขียน

5.2 ข้อเสนอแนะ

1. เก็บข้อมูลเพิ่มเติมเพื่อให้มีข้อมูลที่ใช้สำหรับการฝึกสอนที่มากขึ้น เพื่อที่โมเดลจะสามารถเรียนรู้และจดจำรูปแบบได้ดีขึ้น
2. นำเทคนิคเพิ่มเติมของ Data augmentation มาใช้ในการเพิ่มจำนวนรูปภาพของชุดข้อมูลให้มากขึ้น เพื่อทำให้โมเดลมีการเรียนรู้ที่ดีและมีความแม่นยำมากยิ่งขึ้น
3. เพิ่มจำนวนรอบในการเรียนรู้มากขึ้น จะช่วยให้ข้อมูลมีการเรียนรู้สามารถจดจำรูปแบบได้ดีขึ้น ส่งผลต่อความถูกต้องของการจำแนก

รายการอ้างอิง

- Aghdam, Hamed Habibi, Elnaz Jahani Heravi, and Domenec Puig. "A practical approach for detection and classification of traffic signs using convolutional neural networks." *Robotics and autonomous systems* 84 (2016): 97-112.
- Ahn, Byunghyun, Jeongmin Kim, and Byeongkeun Choi. "Artificial intelligence-based machine learning considering flow and temperature of the pipeline for leak early detection using acoustic emission." *Engineering Fracture Mechanics* 210 (2019): 381-392.
- Bu, Xingyuan, et al. "Deep convolutional network with locality and sparsity constraints for texture classification." *Pattern Recognition* 91 (2019): 34-46.
- Dung, Cao Vu. "Autonomous concrete crack detection using deep fully convolutional neural network." *Automation in Construction* 99 (2019): 52-58.
- Hajihosseini, Payman, Mohammad Mousavi Anzehaee, and Behzad Behnam. "Fault detection and isolation in the challenging Tennessee Eastman process by using image processing techniques." *ISA transactions* 79 (2018): 137-146.
- Heo, Seongmin, and Jay H. Lee. "Fault detection and classification using artificial neural networks." *IFAC-PapersOnLine* 51.18 (2018): 470-475.
- Krysander, Mattias, and Erik Frisk. "Leakage detection in a fuel evaporative system." *Control engineering practice* 17.11 (2009): 1273-1279.
- Litjens, Geert, et al. "A survey on deep learning in medical image analysis." *Medical image analysis* 42 (2017): 60-88.
- Preusche, Robert, et al. "A data-based method for monitoring air in-leakages into the oxyfuel process." *Energy Procedia* 4 (2011): 876-883.
- Puig Cayuela, Vicenç. "Robust FDI/FTC using Set-membership Methods and Application to Real Case Studies." *7th Workshop on Advanced Control and Diagnosis*. 2009.
- Wang, Rui, Wei Li, and Liang Zhang. "Blur image identification with ensemble convolution neural networks." *Signal Processing* 155 (2019): 73-82.

Widyarto, Setyawan, et al. "Wood texture detection with conjugate gradient neural network algorithm." 2017 4th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI). IEEE, 2017.

Yokomichi, Shusei, et al. "Development of diagnostic methods for vacuum leakage from vacuum interrupter by partial discharge detection." 2016 27th International Symposium on Discharges and Electrical Insulation in Vacuum (ISDEIV). Vol. 2. IEEE, 2016

Zhu, Shen-Bin, et al. "Deep belief network-based internal valve leakage rate prediction approach." Measurement 133 (2019): 182-192.






ภาคผนวก ก

การใช้โปรแกรมเพื่อปรับความสว่างของภาพ

- โปรแกรม Visual Studio Code



รูปที่ ก.1 โปรแกรม Visual Studio Code เพื่อปรับความสว่างภาพ

- ขั้นตอนการปรับความสว่างภาพ
 - เปิดโปรแกรมขึ้นมาเพื่อทำการเขียนโค้ด จากนั้น import cv2 เป็นไลบรารีสำหรับเทคนิคทางด้านรูปภาพโดยเฉพาะ
 - การปรับความสว่างของภาพจะเลือกปรับที่ค่าแกมมา มา แสดงดังรูป ก.2

```
C: > Users > asus > Desktop > dffd.py > ...
1  import cv2
2  import numpy as np
3  from PIL import Image
4  import os
5  def adjust_gamma(image, gamma=1):
6
7      invGamma = 1 / gamma
8      table = np.array([(i / 255.0) ** invGamma) * 255
9                      for i in np.arange(0, 256)].astype("uint8")
10
11     return cv2.LUT(image, table)
12
```

รูปที่ ก.2 โค้ดในการปรับความสว่างภาพ


- เมื่อได้โค้ดจากส่วนด้านบนแล้ว จากนั้นจะเป็นการนำเข้ารูปภาพของ original เพื่อทำการปรับความสว่าง ด้วยโค้ด cv2.imread
- เมื่อได้รูปภาพเข้ามาแล้ว ทำการปรับค่าโดย brightness_value = -20 จะได้รูปภาพที่มีความสว่างน้อยลง (decrease brightness), brightness_value = 20 จะได้รูปภาพที่มีความสว่างมากขึ้น (increase brightness) และ Contrast_value = 1
- จากนั้นเซฟชื่อรูปภาพใหม่ที่ได้ทำการปรับความสว่างแล้ว และเป็นนามสกุลรูปจะ .BMP เป็น .PNG เพื่อให้ได้ความคมชัดที่ดีมากขึ้น และเลือกจัดเก็บไว้ในโฟลเดอร์ที่เตรียมไว้ แสดงดังรูปที่ ข.3
- รูปภาพที่ทำการปรับความสว่างจะแสดงขึ้นมา และจะอยู่ในโฟลเดอร์ใหม่ที่เราเลือกไว้
- ผลการลดความสว่างของภาพแสดงดังรูปที่ ข.4
- ผลการเพิ่มความสว่างของภาพ แสดงดังรูปที่ ข.5

```


13
14 for x in range(1,500):
15     image = cv2.imread(r"C:\Users\asus\Desktop\Class_mounthead\Fault II\52.BMP")
16     new_image = np.zeros(image.shape, image.dtype)
17
18     brightness_value = -20
19     contrast_value = 1
20     for y in range(image.shape[0]):
21         for x in range(image.shape[1]):
22             for c in range(image.shape[2]):
23                 new_image[y,x,c] = np.clip(contrast_value*image[y,x,c] + brightness_value, 0, 255)
24
25     cv2.imshow('image', image)
26     cv2.imshow('edited image', new_image)
27     print('Press any key..')
28     path = 'D:\Image_mounthead_Brighness'
29     cv2.imwrite(os.path.join(path, '52.png'), new_image)
30     cv2.waitKey()
31     cv2.destroyAllWindows()

```

รูปที่ ก.3 ขั้นตอนการนำข้อมูลเข้า



รูปที่ ก.4 ผลการลดความสว่างของภาพ



รูปที่ ก.5 ผลการเพิ่มความสว่างของภาพ



ภาคผนวก ข

โปรแกรมสำหรับการถอดตัดส่วนที่สำคัญของภาพ

- การครอบตัดส่วนภาพที่สำคัญเพื่อใช้ในการวิเคราะห์

- ใช้ Google Colab ในการครอบตัดส่วนที่สำคัญของภาพ โดยเขียน โค้ดดังแสดงในรูปแบบที่

ค.1

- โดยรูปที่นำมาใช้สำหรับการครอบตัด คือรูปภาพของ Mount head ที่ได้ทำการเก็บรูปภาพมาจากระบบการผลิต ซึ่งมีขนาด 640x480 พิกเซล แสดงดังรูปที่ ค.2

- ทำการลดขนาดของรูปภาพให้เหลือเพียงส่วนที่สำคัญในการนำไปวิเคราะห์ ซึ่งลดขนาดเหลือ 250x250 พิกเซล แสดงดังรูปที่ ค.3

```
[1] from google.colab import drive
drive.mount('/content/drive')

Go to this URL in a browser: https://accounts.google.com/o/oauth2/auth?client\_id=947318989803-6bn6qk8qdgf4n4g3pfee6491hc0brca

Enter your authorization code:
.....
Mounted at /content/drive

[58] import PIL
from PIL import Image

img = Image.open( '/content/drive/My Drive/Crop/Fault II/4 (1).png' ) # size: 640 x 480
x, y , width , height = 190, 110, 480, 480
#cropped = img.crop( ( x, y, x + width , y + height ) )
cropped = img.crop( ( x, y , 440 , 360 ) )
print ("Crop Finish")
cropped.save('4.png')


Crop Finish

[59] print(cropped)


<PIL.Image.Image image mode=RGB size=250x250 at 0x7F18D4CFC828>
```

ข.1 โค้ดเพื่อใช้ในการทำครอบตัดภาพ

มหาวิทยาลัยเทคโนโลยีสุรนารี



ข.2 ภาพต้นฉบับ



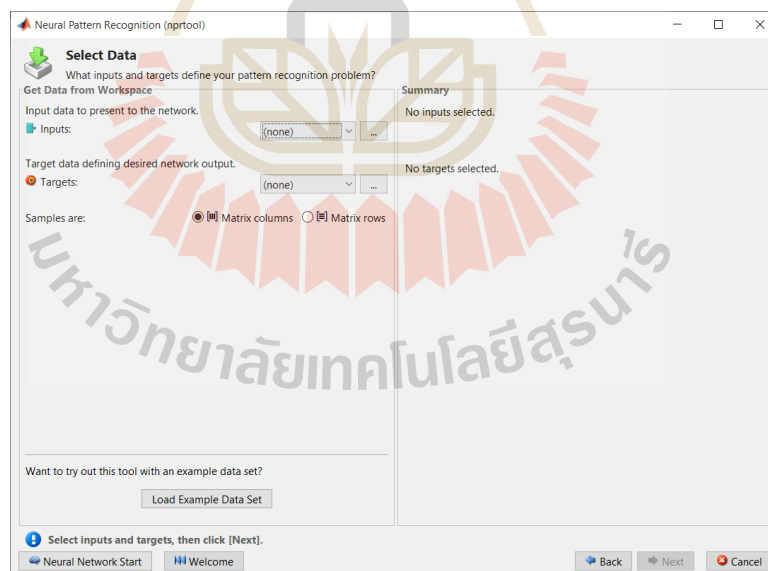
ข.3 ภาพจากการลดขนาด

ภาคผนวก ค


โปรแกรมสำหรับการทำโครงข่ายประสาทเทียมแบบนิวรอลเน็ตเวิร์ก



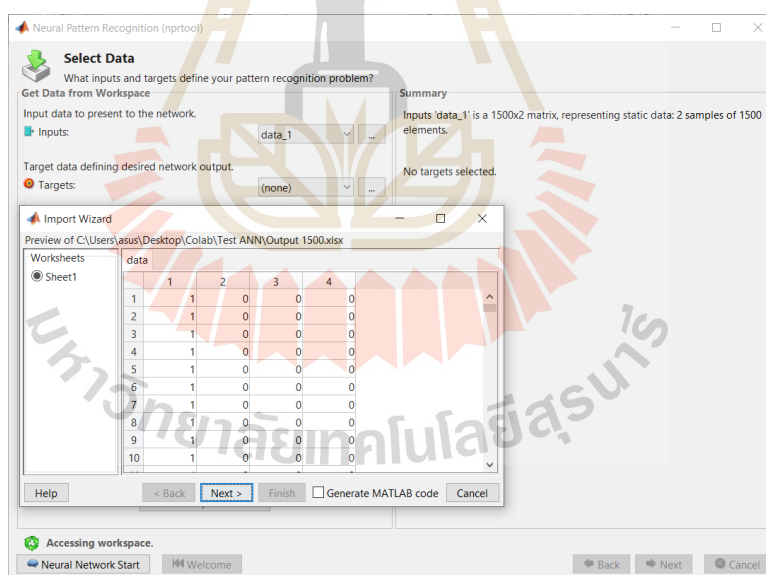
- รายละเอียดของโค้ดสำหรับทำโครงข่ายประสาทเทียมแบบนิวรอลเน็ตเวิร์ก
 - กรณีที่ 1 แบบสองอินพุต
 - ได้มีการนำโปรแกรม MATLAB มาใช้ในการสร้างแบบจำลองโครงข่ายประสาทเทียม Neural Network โดยใช้เครื่องมือที่เรียกว่า Neural Pattern Recognition วิธีการคือ เตรียมข้อมูลอินพุตและข้อมูลเป้าหมายเพื่อให้โมเดลเรียนรู้ดังรูปที่ ก.1
 - ทำการโหลดข้อมูลอินพุตโดยเลือกใช้ 2 คุณลักษณะเด่น คือ พื้นที่พิกเซลด้านนอก (pixel outer area) และพื้นที่พิกเซลด้านใน (pixel inner area) จำนวนข้อมูลอินพุตมีทั้งหมด 1,500 ตัวอย่างจะสามารถเขียนเมทริกซ์ได้แบบ 2×1500 ดังรูปที่ ก.2
 - จากนั้นเลือกข้อมูลเป้าหมาย (Target) โดยแบ่งกลุ่มหรือคลาสของตัวอย่างออกเป็น 4 คลาส กำหนดเป้าหมายเป็นค่า 1 และคลาสที่ไม่ใช่เป้าหมายเป็น 0 สามารถเขียนในรูปของเมทริกซ์ได้เป็น 4×1500 ดังรูปที่ ก.3
 - จากนั้นสามารถแบ่งโครงสร้างการทำงานของโครงข่ายออกได้เป็น Input, Hidden Layer, Output Layer และ Output ซึ่งเครื่องมือนี้สามารถปรับค่าหรือใส่จำนวน Hidden Layer ลงไปให้เหมาะสมได้ ในโมเดลนี้ใช้ 2 hidden layer ดังรูปที่ ก.4




รูปที่ ก.1 แสดงหน้าต่างในการป้อนอินพุตและเอาต์พุต




รูปที่ ค.2 แสดงข้อมูลอินพุตแบบสองอินพุต



รูปที่ ค.3 แสดงการกำหนดคลาสเอาต์พุตของข้อมูล




รูปที่ ค.4 แสดงการแบ่งข้อมูลเพื่อใช้สร้าง โมเดล




รูปที่ ค.5 แสดง โมเดล โครงข่ายประสาทเทียมกรณีสองอินพุต

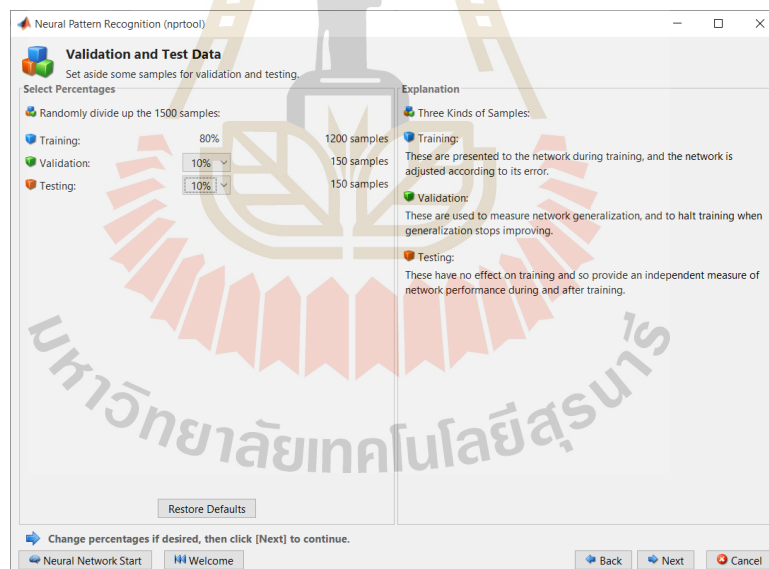
- กรณีที่ 2 แบบสามอินพุต
- ได้มีการนำโปรแกรม MATLAB มาใช้ในการสร้างแบบจำลองโครงข่ายประสาทเทียม Neural Network โดยใช้เครื่องมือที่เรียกว่า Neural Pattern Recognition วิธีการคือ เตรียมข้อมูลอินพุตและข้อมูลเป้าหมายเพื่อให้โมเดลเรียนรู้ดังรูปที่ ค.6
 - ทำการโหลดข้อมูลอินพุตโดยเลือกใช้ 2 คุณลักษณะเด่น คือ พื้นที่พิกเซลด้านนอก (pixel outer area) และพื้นที่พิกเซลด้านใน (pixel inner area) จำนวนข้อมูลอินพุตมีทั้งหมด 1,500 ตัวอย่างจะสามารถเขียนเมทริกซ์ได้แบบ 3×1500 ดังรูปที่ ค.7
 - จากนั้นเลือกข้อมูลเป้าหมาย (Target) โดยแบ่งกลุ่มหรือคลาสของตัวอย่างออกเป็น 4 คลาส กำหนดเป้าหมายเป็นค่า 1 และคลาสที่ไม่ใช่เป้าหมายเป็น 0 สามารถเขียนในรูปของเมทริกซ์ได้เป็น 4×1500 ดังรูปที่ ค.8
 - จากนั้นสามารถแบ่งโครงสร้างการทำงานของโครงข่ายออกได้เป็น Input, Hidden Layer, Output Layer และ Output ซึ่งเครื่องมือนี้สามารถปรับค่าหรือใส่จำนวน Hidden Layer ลงไปให้เหมาะสมได้ ในโมเดลนี้ใช้ 2 hidden layer ดังรูปที่ ค.9



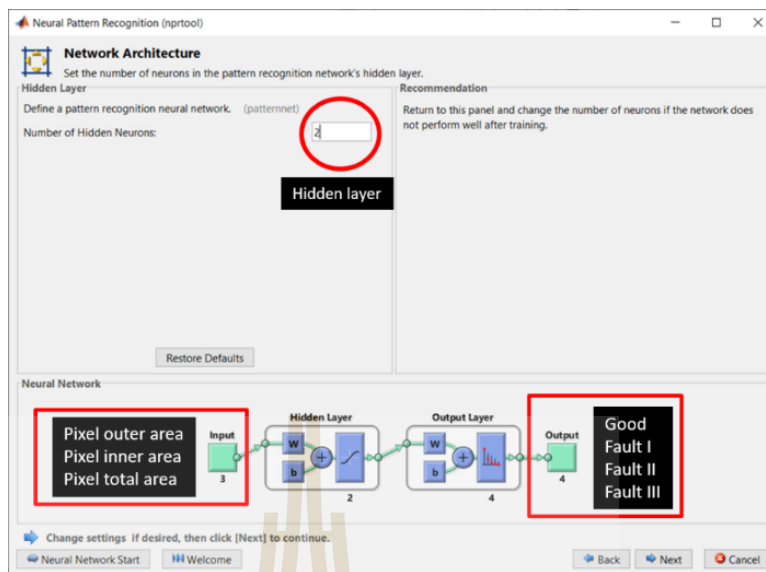
รูปที่ ค.6 แสดงหน้าต่างในการป้อนอินพุตและเอาต์พุต



รูปที่ ค.7 แสดงข้อมูลอินพุตแบบสามอินพุต



รูปที่ ค.8 แสดงการแบ่งข้อมูลเพื่อใช้สร้าง โมเดล



รูปที่ ค.9 แสดงโมเดล โครงข่ายประสาทเทียมสามอินพุต



ภาคผนวก ง

โปรแกรมสำหรับการทำโครงข่ายประสาทเทียมแบบคอนโวลูชัน

- รายละเอียดของโค้ดสำหรับทำโครงข่ายประสาทเทียมแบบคอนโวลูชัน
 - ทำการโหลดข้อมูลรูปภาพมาจาก Google drive จากนั้น Import ไลบารีที่จำเป็นต้องใช้ในการสร้างโมเดล ดังรูปที่ ง.1
 - นำข้อมูลรูปภาพที่เตรียมไว้ใช้สำหรับในการฝึกสอน (Training) 1,200 ภาพ และรูปภาพที่เตรียมไว้สำหรับการตรวจสอบ (validation) 300 ภาพ ดังรูปที่ ง.2
 - สร้างโมเดลตามหลักการทำคอนโวลูชัน โดยทำการปรับค่าต่าง ๆ เพื่อให้ได้ค่าความถูกต้องที่สูงที่สุด แสดงดังรูปที่ ง.3
 - แสดงรายละเอียดการสร้างโมเดล แสดงดังรูปที่ ง.4

```
[1] from google.colab import drive
drive.mount('/content/drive')

Go to this URL in a browser: https://accounts.google.com/o/oauth2/auth?client_id=
Enter your authorization code:
.....
Mounted at /content/drive

# import the necessary packages
import tensorflow as tf
import seaborn as sns
from sklearn.metrics import classification_report
import matplotlib.pyplot as plt
import matplotlib.image as mpimg
import pandas as pd
import numpy as np
import keras
from keras import backend as k
from os import listdir
from os.path import isfile, join
from keras.layers import Dense, GlobalAveragePooling2D
from keras.preprocessing import image
from keras.preprocessing.image import ImageDataGenerator
from keras.models import Model
from keras.optimizers import Adam
from PIL import Image
from keras.models import Sequential
from keras.layers import Dense, Conv2D, Flatten, Dropout, MaxPooling2D
from keras.preprocessing.image import ImageDataGenerator
from sklearn.metrics import confusion_matrix
```

ง.1 Import ไลบารีที่จำเป็นเพื่อสร้างโมเดล

```
[9] #train_datagen = ImageDataGenerator(preprocessing_function=preprocess_input)
train_generator = train_datagen.flow_from_directory('/content/drive/My Drive/Train CNN',
target_size=(240,240),
batch_size=32,
class_mode = 'categorical' )

Found 1200 images belonging to 4 classes.

[ ] # this is a similar generator, for validation data
validation_generator = test_datagen.flow_from_directory(
'/content/drive/My Drive/Test',
target_size=(240, 240),
batch_size=32,
class_mode='categorical')

Found 300 images belonging to 4 classes.
```

ง.2 นำข้อมูลภาพเข้าเพื่อเตรียมสร้างโมเดล

ประวัติผู้เขียน

นางสาวชนาภรณ์ ธรรมเจริญ เกิดเมื่อวันที่ 13 ธันวาคม พ.ศ. 2538 ที่อำเภอบางปะกง จังหวัดฉะเชิงเทรา, ประเทศไทย. เริ่มการศึกษาในระดับอนุบาลศึกษา ตลอดจนสำเร็จการศึกษาในระดับมัธยมศึกษาสายวิทย์คณิต ที่โรงเรียนมารดานฤมล และสำเร็จการศึกษาวิศวกรรมศาสตรบัณฑิต (วิศวกรรมเซรามิก) สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี จังหวัดนครราชสีมา เมื่อ พ.ศ. 2561 และได้ศึกษาต่อระดับวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมเมคคาทรอนิกส์ ขณะศึกษาได้ทำงานอยู่ที่บริษัทเวสเทิร์น ดิจิตอล ประเทศไทย จำกัด ซึ่งเป็นบริษัทที่มอบทุนการศึกษาระดับมหาบัณฑิตให้แก่ข้าพเจ้า

