

เครื่องตรวจความผิดปกติของการหลอมตะกั่วบนแผ่นวงจรพิมพ์ที่มี
ประสิทธิภาพสูงด้วยโมเดลการเรียนรู้เชิงลึก

สุวิกรม อุดรรัตนานุกวัตร

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมข้อมูลขนาดใหญ่
วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์
มหาวิทยาลัยธุรกิจบัณฑิตย์

พ.ศ. 2564

**THE EFFECTIVE DEWETTING DEFECT DETECTION MACHINE
ON PRINTED CIRCUIT BOARD USING DEEP LEARNING MODEL**

SUWIGROM ADULRATTANANUWAT

A Thematic Paper Submitted in Partial Fulfillment of the Requirements

for the Degree of Master of Engineering

Department of Big Data Engineering

College of Innovative Technology and Engineering,

Dhurakij Pundit University

2021




ใบรับรองงานสารนิพนธ์

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิตย์

ปริญญา วิศวกรรมศาสตรมหาบัณฑิต

หัวข้อสารนิพนธ์ เครื่องตรวจความผิดปกติของการหลอมตะกั่วบนแผ่นวงจรพิมพ์ที่มีประสิทธิภาพสูง
ด้วยโมเดลการเรียนรู้เชิงลึก
เสนอโดย สุวิกรม อตุลรัตนานวัตร
สาขาวิชา วิศวกรรมข้อมูลขนาดใหญ่
อาจารย์ที่ปรึกษาสารนิพนธ์ ดร.ธนภัทร ช้างคะจิตร
ได้พิจารณาเห็นชอบโดยคณะกรรมการสอบสารนิพนธ์แล้ว


.....ประธานกรรมการ
(ดร.สรรพฤทธิ์ มฤคทัต)


.....กรรมการและอาจารย์ที่ปรึกษา
(ดร.ธนภัทร ช้างคะจิตร)


.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ดวงใจ จิตคงชื่น)

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์รับรองแล้ว


.....
(ดร.ชัยพร เขมะภาตะพันธ์)

คณบดีวิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์

วันที่ 31 เดือน กรกฎาคม พ.ศ. 2564

หัวข้อสารนิพนธ์	เครื่องตรวจความผิดปกติของการหลอมตะกั่วบนแผ่นวงจรพิมพ์ที่มีประสิทธิภาพสูงด้วยโมเดลการเรียนรู้เชิงลึก
ผู้เขียน	ศุวิกรม อัครรัตนานูวัตร
อาจารย์ที่ปรึกษา	ดร.ธนภัทร นังคะจิตร
สาขาวิชา	วิศวกรรมข้อมูลขนาดใหญ่
ปีการศึกษา	2563

บทคัดย่อ

ในอุตสาหกรรมอิเล็กทรอนิกส์ ปัญหาการตรวจชิ้นงานที่ไม่ได้คุณภาพมาจากทั้งจากคนและเครื่องจักร ถึงแม้ว่าจะมีเครื่องจักรช่วยในการตรวจชิ้นงานโดยใช้สถิติเบื้องต้นของค่าปริมาณสี แต่พนักงานต้องทำการตรวจงานซ้ำทั้งชิ้นงานเนื่องจากเครื่องจักรใช้อัลกอริทึมที่ไม่มีประสิทธิภาพ ในโรงงานกรณีศึกษาพบว่าพนักงานต้องตรวจชิ้นงานซ้ำถึงในอัตรา 10% จากยอดผลิต 2000 ชิ้นต่อวัน ทั้งนี้ปัญหานี้ซึ่งเป็นหนึ่งปัญหาทางด้านคอมพิวเตอร์วิทัศน์สามารถบรรเทาเบาบางได้โดยใช้ความก้าวหน้าของเทคนิคการเรียนรู้เชิงลึก

งานสารนิพนธ์ฉบับนี้จึงได้ออกแบบเครื่องจักรที่นำมาใช้ตรวจต่อจากเครื่องจักรเดิมเพื่อแยกลักษณะงานเสียจากการหลอมเหลวที่ผิดปกติ เริ่มจากค้นหาตำแหน่งที่เสียบ่อยในชิ้นงาน โดยเพิ่มความยืดหยุ่นในการตรวจในกรณีที่ชิ้นงานเอียง หลังจากนั้นจะประยุกต์ใช้อัลกอริทึมการเรียนรู้เชิงลึก (ResNet 101) ในการทำนายว่าเป็นงานเสียหรือไม่ โดยหลังจากทดลองปรับค่า Threshold สำหรับการทำนายชิ้นงานเสียเป็นมากกว่า 80% พบว่าสามารถทำนายชิ้นงานที่มาทดสอบแม่นยำมากโดยทำนายชิ้นงานเสียถูกต้องเพิ่มขึ้นเป็น 98% และทำนายชิ้นงานดีแม่นยำถึง 100% ซึ่งช่วยลดภาระของพนักงานอย่างมีนัยสำคัญในการช่วยระบุตำแหน่งที่เสียในชิ้นงาน

Thematic paper Title	THE EFFECTIVE DEWETTING DEFECT DETECTION MACHINE ON PRINTED CIRCUIT BOARD USING DEEP LEARNING MODEL
Author	Suwigrom Adulrattananuwat
Thematic Paper Advisor	Thanapat Kangkachit, Ph.D.
Department	Big Data Engineering
Academic Year	2020

ABSTRACT


In the electronics industry, the problems in inspecting defective workpieces come from both machine and human errors. Although, the inspection machine can mitigate this problem by using basic statistical data based on colors on the workpieces. The inspectors need to examine the whole workpieces again due to the less efficient algorithms used by the machines. Regarding our reference factory, the inspection rate is about 10% of the 2,000 workpieces per day. Fortunately, this kind of computer vision problem can be alleviated using advanced deep learning techniques.

In this work, we design an additional machine to isolate the defective workpieces from abnormal melting workpieces. Firstly, our machine seeks the most frequent defective positions in the workpieces. With some degrees of rotation, these positions can still be detected by using the cumulative gradient orientation technique. Lastly, these positions would be classified as "defective" or "normal" using a ResNet101 deep learning model. By adjusting the probability threshold of predicting defective workpieces to 80%, the model's accuracy increases to 98%. Meanwhile, the model obtains 100% accuracy while classifying the normal workpieces. As a result, our machine can further significantly reduce the workload of the inspectors by precisely predicting the defective position in the workpieces.

กิตติกรรมประกาศ

สารนิพนธ์นี้สำเร็จได้ด้วยความอนุเคราะห์ของบุคคลหลายท่าน ซึ่งไม่อาจจะนำมากล่าวได้ทั้งหมด ซึ่งผู้มีพระคุณท่านแรกที่ผู้วิจัยใคร่ขอกราบขอบพระคุณคือ ดร. ธนภัทร ชังคะจิตร อาจารย์ที่ปรึกษาสารนิพนธ์ ที่ได้เสียสละเวลาอันมีค่าให้ความรู้และคำแนะนำตรวจทาน และแก้ไขข้อบกพร่องต่าง ๆ ด้วยความเอาใจใส่ทุกขั้นตอน เพื่อให้สารนิพนธ์นี้สมบูรณ์ที่สุด ผู้วิจัยใคร่ขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้ นอกจากนี้ ผู้วิจัยขอขอบพระคุณ เพื่อนร่วมรุ่นที่ให้กำลังใจในการศึกษาทำสารนิพนธ์ตลอดมา

สุวิกรม อตุลรัตนานูวัตร

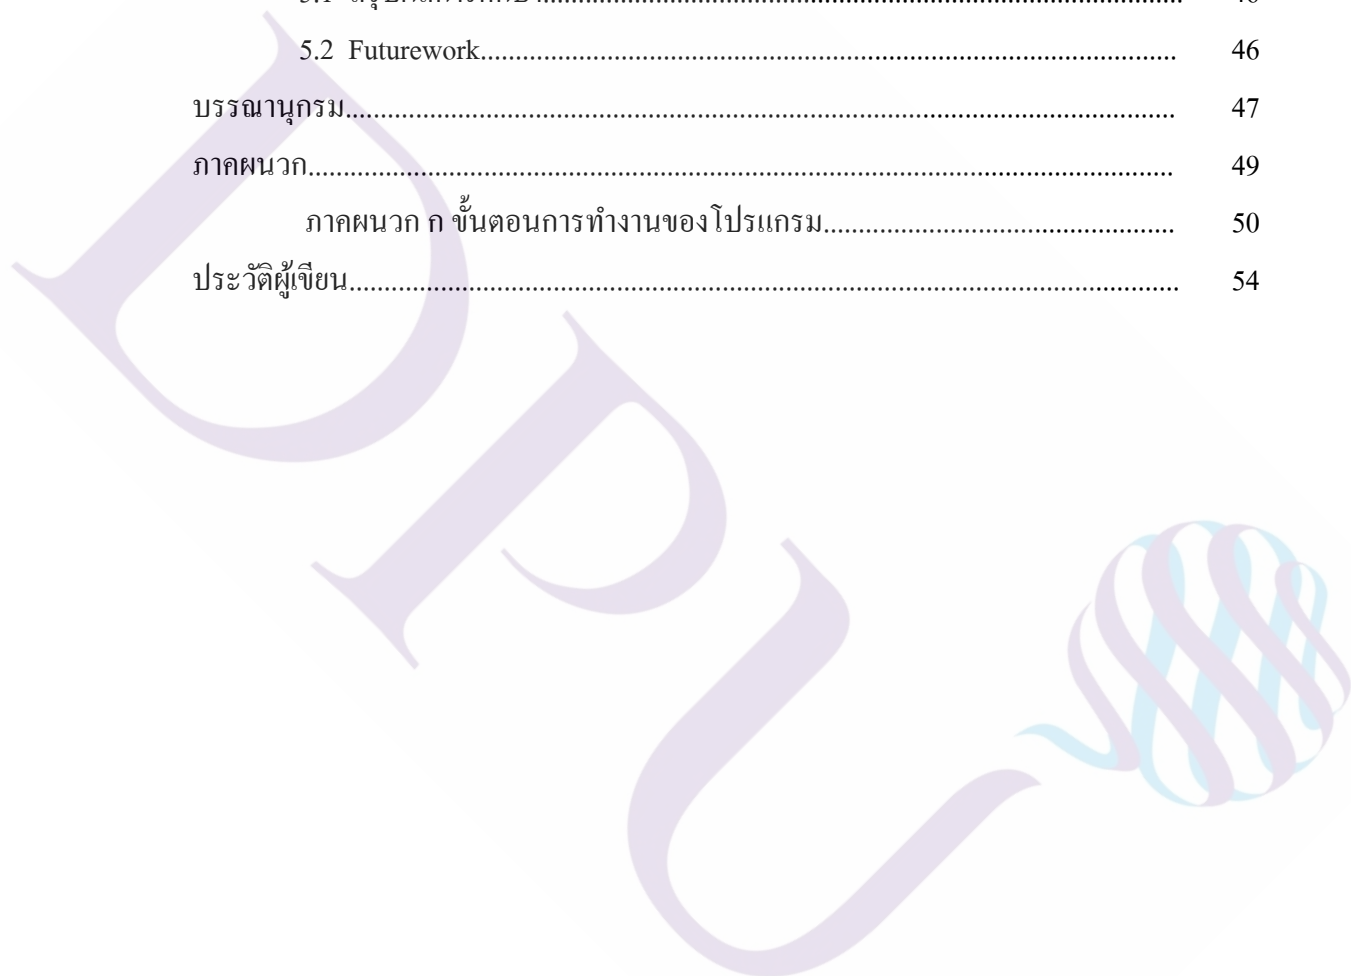


สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	๗
บทคัดย่อภาษาอังกฤษ.....	๙
กิตติกรรมประกาศ.....	๑
สารบัญตาราง.....	๙
สารบัญภาพ.....	๑๑
บทที่	
1. บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์.....	3
1.3 ขอบเขตของการวิจัย.....	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	4
1.5 นิยามศัพท์.....	4
2. ทฤษฎี และงานวิจัยที่เกี่ยวข้อง.....	5
2.1 วิธีการตรวจชิ้นงาน	5
2.2 การเรียนรู้เชิงลึก.....	13
2.3 สถาปัตยกรรม Restnet 101.....	19
2.4 การตรวจจับวัตถุด้วย Image Gradient.....	21
2.5 การเลือกชนิดแสงสำหรับงาน Machine Vision	25
2.6 Desktop Application.....	31
2.6 Web Service.....	31
3. ระเบียบวิธีวิจัย.....	32
3.1 การค้นหาตำแหน่งงานเสียที่พบบ่อย.....	32
3.2 ทำการแยกประเภทงานดีงานเสีย.....	34
3.3 การออกแบบระบบและการนำไปใช้งาน.....	37
4. ผลการศึกษา.....	41
4.1 ผลการทดสอบ Validation Dataset.....	41
4.2 ผลการทดสอบ Test Dataset.....	42

สารบัญ (ต่อ)

บทที่	หน้า
4.3 ผลการทดสอบ Threshold Test Dataset.....	42
5. สรุปผลการศึกษา.....	46
5.1 สรุปผลการศึกษา.....	46
5.2 Futurework.....	46
บรรณานุกรม.....	47
ภาคผนวก.....	49
ภาคผนวก ก ขั้นตอนการทำงานของโปรแกรม.....	50
ประวัติผู้เขียน.....	54



สารบัญตาราง

ตารางที่	หน้า
1.1 แสดงการเปรียบเทียบ Classification error rate ของ Deep learning.....	2
4.1 Validation accuracy	42
4.2 Test dataset accuracy Threshold ในการระบุงานดี >50%.....	42
4.3 Test dataset accuracy Threshold ในการระบุงานดี >80%.....	42
4.4 แสดง Prediction ที่ Threshold >0.5.....	43
4.5 แสดง Prediction ที่ Threshold >0.8.....	44
4.6 ผล Accuracy ที่ Threshold แตกต่างกัน.....	45



สารบัญภาพ

ภาพที่	หน้า
1.1 แสดงงานดี (Correct Wetting) และงานเสีย (Dewetting).....	2
1.2 เครื่องจักรที่ออกแบบและประกอบมาใช้ในระบบการตรวจสอบชิ้นงาน.....	3
2.1 แสดงวิธีในการตรวจชิ้นงาน PCB	6
2.2 ผลลัพธ์จากการลบระหว่างภาพต้นแบบและภาพอ้างอิง.....	7
2.3 แสดง template สำหรับกระบวนการ Feature Matching.....	8
2.4 แสดง Feature Matching ทั้ง Boundary and fine line pattern.....	8
2.5 การกำหนด ข้อมูลของโมเดลต้นแบบด้วยโครงสร้างกราฟ.....	9
2.6 ข้อมูลรูปภาพหลังการทำ Erosion.....	10
2.7 ข้อมูลรูปภาพหลังการทำ Dilation.....	10
2.8 แสดงข้อมูลรูปภาพหลังการทำ Skeleton โดยวิธี Thinning.....	10
2.9 แสดงกระบวนการหา defective pattern.....	11
2.10 ลักษณะงานเสียจากการ Encoding.....	12
2.11 โครงสร้างโครงข่ายประสาทเทียม โดยแบ่งหน้าที่ตาม Layer	12
2.12 Rule ที่ใช้ในการตรวจ Vector ที่เกิดขึ้น เช่น 4Corner, 3 Corner , 2Corner.....	13
2.13 การคำนวณโครงสร้างโครงข่ายประสาทเทียม.....	14
2.14 การเปรียบเทียบระหว่าง Simple neural network และ Deep Learning Neural Network.....	15
2.15 การทำ Convolution Filter.....	16
2.16 การใส่พารามิเตอร์ Stride = 1.....	17
2.17 การใส่พารามิเตอร์ Stride = 2.....	17
2.18 การใส่ Stride 1 กับ Padding.....	17
2.19 การทำ Max pooling ที่ขนาด 2x2 และ Stride =2.....	18
2.20 การใช้ Convolution Neural Network ในการทำ Classification.....	18
2.21 การใช้ Convolution Neural Network ในการทำ Object Detection.....	19
2.22 แสดงสถาปัตยกรรม Restnet 101.....	20
2.23 แสดง Residual Block.....	20
2.24 การทำ Sobel แนวตั้งและแนวนอน และ Image gradient ที่เกิดขึ้น.....	21

สารบัญภาพ (ต่อ)

2.25 การสร้างรูป template.....	22
2.26 อนุภาคของ Gradient ของทั้ง 3 วัตถุ.....	23
2.27 Similarity Score Based ในการสแกนรูป พบว่า Cumulative Orientation มีค่าสูงและความแตกต่างมากขึ้น ซึ่งจะเป็นการเพิ่ม Detection Rate.....	23
2.28 การตรวจจับวัตถุและมีการตรวจจับ Orientation ด้วย.....	24
2.29 Detection Rate เปรียบเทียบในแต่ละวิธี.....	24
2.30 การลดขนาดภาพ โดยวิธี Gaussian Pyramid.....	25
2.31 ประเภทแหล่งกำเนิดแสงแต่ละชนิดและประสิทธิภาพในแต่ละประเภท.....	26
2.32 ชนิดแสงและการใช้งาน.....	27
2.33 ชนิดของภาพกับลักษณะของพื้นผิวในการเลือกชนิดแหล่งกำเนิดแสง.....	28
2.34 ชั้นงานเดียวกัน แต่ใช้แสงต่างชนิดกัน.....	28
2.35 ชั้นงานเดียวกัน แต่ใช้แสงต่างชนิดกัน.....	29
2.36 การใช้ Diffuse Lighting เพื่อตรวจสอบความขรุขระที่ผิว.....	29
2.37 การใช้แสงต่างชนิดกัน.....	30
2.38 ภาพที่ใช้แสง LED แต่ละสีบนชั้นงานที่พิมพ์ด้วยแสงสีแดง.....	30
3.1 แสดงตำแหน่งอ้างอิงที่เกิดจากการขจัดเพียงค่า X และ Y และความคลาดเคลื่อนจากตำแหน่งการตรวจจับงานเสีย.....	33
3.2 แสดง Global and Local coordinate Transformation.....	33
3.3 แสดงตำแหน่งงานเสียที่ตรวจพบบนแต่ละชั้นงาน.....	34
3.4 ตัวอย่างงานดีด้านซ้ายมือและตัวอย่างงานเสียด้านขวามือ.....	34
3.5 Data Flow สำหรับ Deep Learning project	35
3.6 แสดง Customize model ที่ใช้ในการทดสอบการ Classification.....	36
3.7 แสดง Resnet model ที่ใช้ในการทดสอบการ Classification.....	36
3.8 ระบบเครื่องจักรที่พัฒนาเพื่อตรวจชั้นงาน.....	38
3.9 ระบบเครื่องจักรที่พัฒนาเพื่อตรวจชั้นงาน.....	38
3.10 ค่า Setting ต่าง ๆ ที่เครื่องจักรใช้ในการปฏิบัติงาน.....	39
3.11 การเรียก HTTP service เพื่อให้ระบบ Desktop application สามารถเชื่อมต่อกับระบบ AI.....	39

สารบัญภาพ (ต่อ)

3.12 แสดงการติดตั้งเครื่องจักรที่ใช้ในการตรวจชิ้นงาน.....	40
4.1 กราฟการเทรนข้อมูลโมเดล Customized.....	41
4.2 กราฟการเทรนข้อมูลโมเดล Restnet101.....	41



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ลายวงจรอิเล็กทรอนิกส์เป็นอุปกรณ์พื้นฐานที่มีอยู่ในชิ้นส่วนการผลิตและมีการใช้งานอยู่ในทุกภาคอุตสาหกรรมและมีการใช้งานอยู่ในชีวิตประจำวัน ในการผลิตลายวงจรนั้นเพื่อยังคงความสามารถในด้านการแข่งขันได้ จึงจำเป็นต้องมีการปรับปรุงพัฒนา พบว่าแรงงานส่วนใหญ่ที่อยู่ในภาคการผลิตจากโรงงานตัวอย่าง อยู่ในกระบวนการตรวจสอบคุณภาพ หนึ่งในนั้นคือการตรวจสอบชิ้นงาน ซึ่งการตรวจชิ้นงานด้วยคนในชิ้นงานที่มีความซับซ้อนสูงนั้นทำให้มีโอกาสชิ้นงานที่ไม่มีคุณภาพรอดพ้นจากกระบวนการตรวจสอบได้ง่าย จึงมีการลงทุนนำเครื่องจักรอัตโนมัติสำหรับตรวจชิ้นงานเพื่อลดปัญหาที่เกิดจากการตรวจผ่านคน เพื่อลดปัจจัยต่าง ๆ เช่น ความเมื่อยล้า การเพิ่มความแม่นยำในการตรวจชิ้นงาน ในขณะเดียวกันการประยุกต์ใช้งานเครื่องจักรมาตรฐานที่ใช้งานอยู่ในโรงงานตัวอย่างยังคงพบปัญหา False call ที่ 10% ทำให้เป้าหมายในการใช้เครื่องจักรตรวจไม่เต็มประสิทธิภาพเท่าที่ควรจะเป็น และต้องใช้คนมาตรวจสอบซ้ำเฉพาะจุดที่มีปัญหาในอีกขั้นตอนหนึ่ง

ด้วยเครื่องจักรที่ใช้งานยังคงใช้อัลกอริทึมการวัดเชิงปริมาณของค่า พิกเซล จึงมีแนวความคิดที่จะนำอัลกอริทึมของปัญญาประดิษฐ์มาประยุกต์ใช้งานและเปรียบเทียบผลที่เกิดขึ้น โดยปัญหาที่พบในระบบเก่าคือความซับซ้อนในการหา Feature Extraction (Mahony, Campbell, Carvalho, Harapanahalli, Velasco-Hernandez, Krpalkova, Riordan, Walsh, 2019) ซึ่งกระบวนการในปัญญาประดิษฐ์จะทำการหา Feature ให้อัตโนมัติและเปรียบเทียบผลหลังจากการเทรนโมเดลแล้ว โดยการศึกษาจะประยุกต์ใช้ Deep Learning Model ResNet-101 เนื่องจากการศึกษาพบว่า Classification error rate น้อยที่สุดในงานวิจัย (Ding¹, Dai¹, Li², Liu¹, 2019) ที่นำมาศึกษาเปรียบเทียบ



Correct Wetting

Dewetting

ภาพที่ 1.1 แสดงงานดี (Correct Wetting) และงานเสีย (Dewetting)

ตารางที่ 1.1 แสดงการเปรียบเทียบ Classification error rate ของ Deep learning Architecture

ที่มา: Jianlong Fu and Yong Rui (2017)

TABLE II
COMPARISON OF RECOGNITION RESULTS ON COMPCARS DATASET.

Methods	Acc. On Model
AlexNet [6]	81.93%
GoogleNet [6]	92.42%
VGG19 [24]	92.46%
ResNet50 [20]	93.37%
RestNet101 [20]	94.21%

โดยในการศึกษานี้เป็นการทำระบบเพื่อปรับปรุงเปรียบเทียบการตัดสินใจของ ชนิดงานเสียเฉพาะที่สนใจ โดยลด False call จากเดิม 10% โดยเครื่องจักรและระบบนี้จะนำไปติดตั้งกับต่อกับเครื่องจักรเดิมและทำการตรวจเฉพาะชนิดงานเสียให้มีประสิทธิภาพมากขึ้นแล้วทำการทำเครื่องหมายระบุงานเสียในตำแหน่งนั้นทั้งทางกายภาพและในระบบเพื่อทำการทวนสอบต่อไปในระบบฐานข้อมูล



ภาพที่ 1.2 เครื่องจักรที่ออกแบบและประกอบมาใช้ในระบบการตรวจสอบชิ้นงาน

ปัญหาในการศึกษามี 2 ประการคือ

1. มีงาน Over Reject 10% จากงานทั้งหมดที่ทำการผลิต
2. พนักงานต้องตรวจงาน 100% ถึงแม้ว่าจะมีงานที่ต้องตรวจจริง 10% จากการ Over Reject สาเหตุที่มาจาก การไม่รู้ตำแหน่งงานเสียที่แน่นอนจากจำนวนทั้งหมดใน 1 แผ่นชิ้นงาน

1.2 วัตถุประสงค์

ลดการตรวจชิ้นงานเสียที่เกิดขึ้น โดยการเพิ่มความแม่นยำในการทำนายชิ้นงานเสียและระบุตำแหน่งที่เกิดขึ้นลดการ Over Reject ที่เกิดขึ้น โดยการแยกประเภทงานดี งานเสีย ได้อย่างถูกต้อง

1.3 ขอบเขตของการวิจัย

1. การศึกษานี้ มุ่งศึกษาเฉพาะสายการผลิตตัวอย่างที่พบจากโรงงานกรณีศึกษา
2. ผู้วิจัยทำการศึกษาลักษณะงานเสียที่พบได้บ่อยและต้องการปรับปรุง
3. กลุ่มตัวอย่างข้อมูลที่ใช้ในการศึกษา มาจาก 1 โมเดลของสายการผลิต โดยมีภาพงานดีและงานเสีย

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถนำปัญญาประดิษฐ์มาประยุกต์ใช้แก้ปัญหาที่พบเจอในเชิงอุตสาหกรรม
2. เพิ่มประสิทธิภาพของกระบวนการทำงาน โดยการลดการซ้ำซ้อนในการทำงานและใช้เครื่องจักรที่ออกแบบมาปรับปรุงในการทำงาน

1.5 นิยามคำศัพท์

1. AI (Artificial Intelligence) หมายถึงปัญญาประดิษฐ์
2. Supervised Learning หมายถึงการเรียนรู้แบบมีผู้สอน เป็นศาสตร์แขนงหนึ่งในปัญญาประดิษฐ์ ส่วนใหญ่ใช้เพื่อพยากรณ์วิเคราะห์ความถดถอย (Regression) และการจำแนกข้อมูล (Classification)
3. Unsupervised learning หมายถึงหมายถึงการเรียนรู้แบบไม่มีผู้สอน เป็นศาสตร์แขนงหนึ่งในปัญญาประดิษฐ์ ส่วนใหญ่ใช้เพื่อการแบ่งกลุ่มข้อมูล (Clustering)
4. Neural Network หมายถึงโครงข่ายประสาทเทียม
5. Deep Learning หมายถึงการเรียนรู้เชิงลึก เป็นส่วนหนึ่งของวิธีการการเรียนรู้ของเครื่องบนพื้นฐานของโครงข่ายประสาทเทียมและการเรียนเชิงคุณลักษณะ การเรียนรู้สามารถเป็นได้ทั้งแบบการเรียนรู้แบบมีผู้สอน การเรียนรู้แบบกึ่งมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง


ในการศึกษางานวิจัยที่เกี่ยวข้องกับการพัฒนาโปรแกรมตรวจชิ้นงานด้วยปัญญาประดิษฐ์ด้วยตนเอง ผู้วิจัยได้ศึกษาค้นคว้าเกี่ยวกับหลักการ แนวคิดทฤษฎี และกระบวนการในการพัฒนาโปรแกรม โดยมีหัวข้อดังนี้

1. วิธีการการตรวจชิ้นงาน
2. สถาปัตยกรรม Resnet101
3. การเรียนรู้เชิงลึก (Deep Learning)
4. การตรวจจับวัตถุด้วย Image Gradient
5. การเลือกชนิดแสงสำหรับงาน Machine Vision
6. Desktop Application
7. Web Service

2.1. วิธีการตรวจชิ้นงาน

วิธีการตรวจชิ้นงาน ได้แบ่งออกเป็น 3 วิธี (Moganti, Ercal, Dagi, Tsunekawa, 1996)

1. การตรวจโดยอ้างอิงจากภาพต้นแบบ
2. การตรวจโดยไม่อ้างอิงจากภาพต้นแบบ
3. การตรวจแบบผสมผสาน



ภาพที่ 2.1 แสดงวิธีในการตรวจชิ้นงาน PCB

1. การตรวจโดยอ้างอิงจากภาพต้นแบบ

เป็นการเปรียบเทียบระหว่างภาพต้นแบบกับภาพที่ต้องทำการตรวจ เพื่อวัดผลต่างจากภาพทั้งสอง

1.1 Image Comparison

เป็นวิธีการตรวจ โดยการลบค่าผลต่าง พิกเซลในตำแหน่งเดียวกันหลังจากทำการ template matching แล้วการลบค่าผลต่างทำด้วย XOR operator รูปที่ 2.2 ได้จากผลดังกล่าวจะเป็นสัดส่วนของงานเสีย สิ่งสำคัญคือทั้งรูปต้นแบบและรูปอ้างอิงที่นำมาตรวจต้องมีชิ้นงานขนาดเดียวกันในรูปภาพ และตำแหน่งต้องตรงกันด้วย การค้นหาตำแหน่งของรูปอ้างอิงทำการ template matching ซึ่งเป็นการวัด similarity ที่มีข้อมูลปริมาณมาก โดยวิธีการวัด Similarity ทำได้โดย

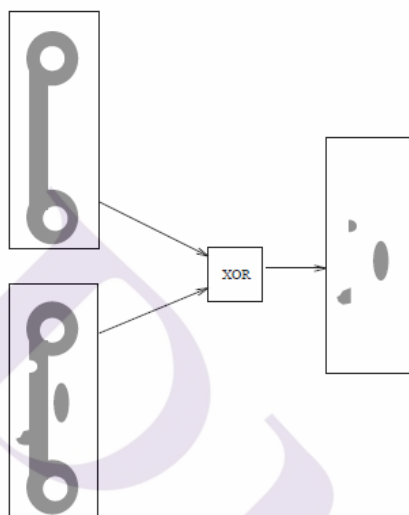
$$s_j(x, y) = \frac{1}{n^m} \sum_{i=1}^j \frac{\langle d_i^m, d^s(x + x_i^m, y + y_i^m) \rangle}{\|d_i^m\| \cdot \|d^s(x + x_i^m, y + y_i^m)\|} .$$

กำหนดให้

n = จำนวน pixel ที่ใช้ในการเปรียบเทียบ

d^m = frame ของ master image ที่เป็นตัวต้นแบบ

d^s = frame ของ sample image ที่นำมาค้นหาต้นแบบ

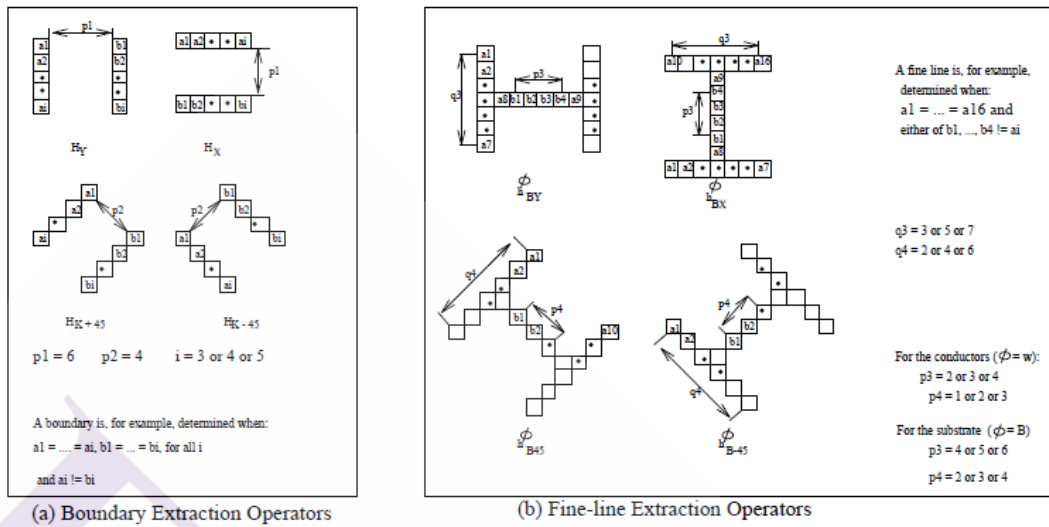


ภาพที่ 2.2 ผลลัพธ์จากการลบระหว่างภาพต้นแบบและภาพอ้างอิง

หลังจากนั้นนำผลที่ไปผ่านกระบวนการ Feature Matching

โดยสร้าง template เป็นสองขนาด สำหรับตรวจสอบ defect ขนาดใหญ่ และ defect ขนาดเล็ก

หลังจากนั้นนำ template แต่ละชนิดทั้งสี่มาผ่าน AND Operator



ภาพที่ 2.3 แสดง template สำหรับกระบวนการ Feature Matching


	Pattern f and its processed image	Pattern g and its processed image	Feature Extraction Operators	Result of comparison of F and G
(1) Detected patterns f, g				
(2) Extracted boundary lined F_K, G_K in the Y direction				
(3) Extracted fine line pattern F_B, G_B in the direction X				

ภาพที่ 2.4 แสดง Feature Matching ทั้ง Boundary and fine line pattern


1.2. Model-Based Inspection

เป็นการสร้าง โมเดลจากต้นแบบ โดยการกำหนดข้อมูลของ model ไว้ก่อน จากภาพต้นแบบเช่นในรูปแบบข้อมูล แล้วอธิบายการเชื่อมต่อแต่ละวงจร โดยลายวงจรแทนการเชื่อมต่อของแต่ละ node แต่ในการใช้งานจริงงานเสียจะมีการกำหนดขนาดงานเสีย และ แบ่งประเภท งาน


เสียจากหน้าที่การทำงาน หรือ รูปลักษณะ ทำให้วิธีนี้ไม่เหมาะสมกับการประยุกต์ใช้งานกรณีที่ต้องการตรวจนอกเหนือจากการเชื่อมต่อลายวงจร



(a) PCB sub-pattern (b) Thinned sub-pattern (c) Pruned sub-pattern with labels



(d) Representation of RAG for segment A in Figure (c)




(e) Graphical representation of PAHG for the sub-image pattern (a)

ภาพที่ 2.5 แสดงการกำหนด ข้อมูลของ โมเดลต้นแบบด้วย โครงสร้างกราฟ

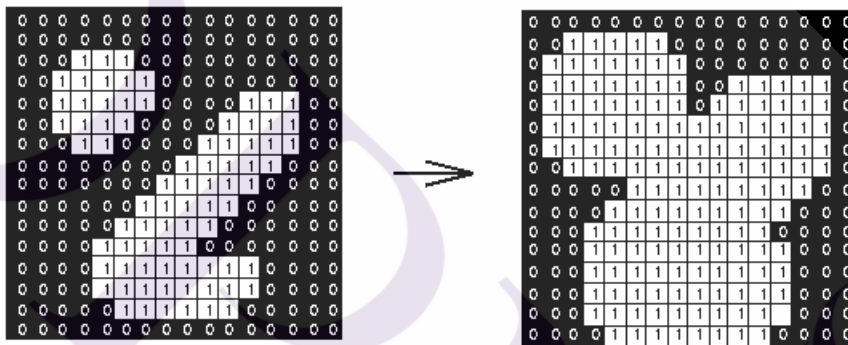
2. การตรวจโดยไม่อ้างอิงจากภาพต้นแบบ

เป็นการตรวจโดยการกำหนดกฎในการตรวจสอบ design rule verification ส่วนมากใช้ในการกำหนดขนาด ค่าต่ำสุดและมากที่สุดของ ความกว้างลายวงจร ขนาดเส้นผ่านศูนย์กลางของ pad ขนาดของรูเจาะ


2.1 Morphological Processing เป็นการประมวลผลภาพโดยการเปลี่ยนรูปร่างลักษณะหรือโครงสร้างของภาพ โดยทั่วไปใช้ออปอเรชั่น พื้นฐานเช่น Dilation Erosion และ Skeleton โดยการ Dilation คือการขยายขนาดในรูปภาพโดยมีสัดส่วนเท่ากันๆทั้งภาพ การ Erosion คือการย่อขนาดในรูปภาพ ส่วนการ Skeleton คือการหาโครงสร้างหลักของวัตถุในภาพ โดยการแปลงภาพเป็นเส้นที่เชื่อมต่อกันเป็นโครงสร้าง



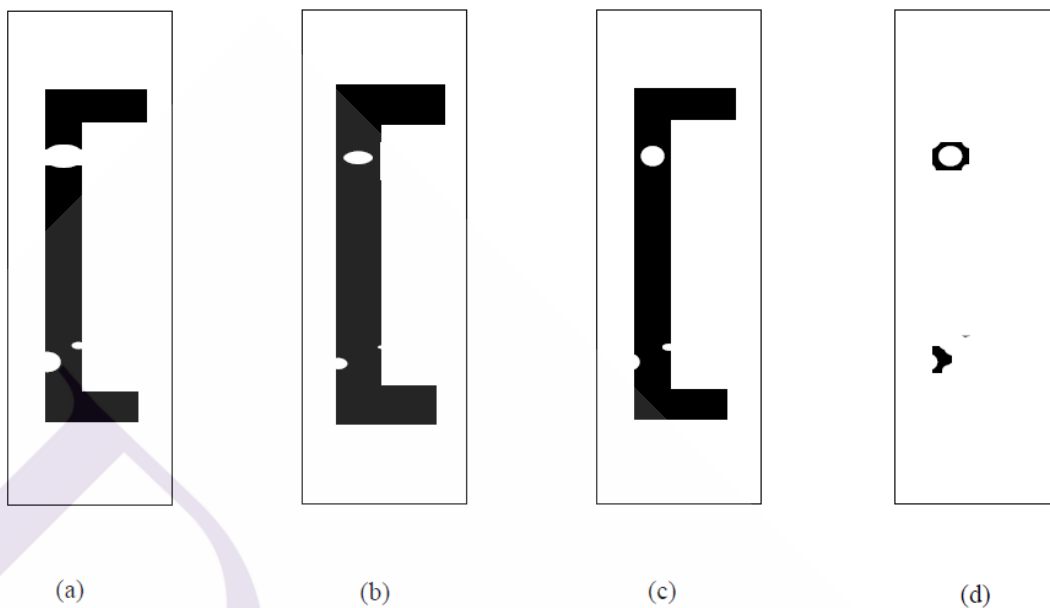
ภาพที่ 2.6 ข้อมูลรูปภาพหลังการทำ Erosion



ภาพที่ 2.7 ข้อมูลรูปภาพหลังการทำ Dilation




ภาพที่ 2.8 ข้อมูลรูปภาพหลังการทำ Skeleton โดยวิธี Thinning



ภาพที่ 2.9 แสดงกระบวนการหา defective pattern (a) แสดงการ ภาพงานเสีย (b) รูปที่ผ่านการ dilation (c) รูปที่ผ่านการ thinning และ prune เพื่อแก้ไขส่วนที่อื่นเกินออกมา (d) จะได้ defective pattern ตามภาพ

2.2 เทคนิคการเข้ารหัส (Encoding Techniques)


สามารถทำได้โดยเทคนิคการวิเคราะห์ขอบเขต (Boundary Analysis Techniques) โดยการกำหนดรูปร่างขอบเขตและขั้นตอนการตรวจสอบ โดยใช้ Freeman chain coding เพื่ออธิบายขอบเขต โดยการแปลงขอบเขตต่าง ๆ ให้อยู่ในรูปการณืประมาณของรูปหลายเหลี่ยม (polygon) การประมาณนี้ส่วนหนึ่งเป็นการตัดข้อมูลรอบกวนออกไป แต่ละเส้นจะแสดงเส้น เวกเตอร์ 8 ทิศทาง




(a) Example of a small fault shape

Chain Code: 7777788118777665567777 (a)
 Curvature code: 0001010-1-100-10-1011000 (b)
 Changes in dir.: 01010-20-10-1020 (c)
 Duration: 3 1 1 1 1 2 2 1 1 1 1 2 3 (d)
 Extracted corners:
 Changes in direction: 2 -2 -2 2 (e)
 Duration: 3 2 3 2 (f)
 Distance from A: 4.5 8.0 12.5 16.0 (g)


(b) Corner extraction on image in Figure (a)




(c) Chain code directions



(1) Nick/Bump



(2) Nick/Bump



(3) Break/Short

ภาพที่ 2.10 ลักษณะงานเสียจากการ Encoding (a) ตัวอย่างการ encoding จากงานเสีย (b) การ encoding แบบ Freeman (c) ทิศทาง Vector ที่นำมาใช้ในการ encoding

(1) Four corner fault model:

- (4.1) Combination + * - - * + or - * + * + * -,
 where (-) is a negative going corner
 (+) is a positive going corner
 (*) is an optional corner of any direction
- (4.2) $a < 10.0$ and $b < 7.0$ and $c < 10.0$
- (4.3) $E < 12.0$
- (4.4) $F - E > \text{THRESHOLD}$.

(2) Three corner fault model:

- (3.1) Detection of corners + * - * + or - * + * -.
- (3.2) $a < 15.0$ and $b < 15.0$
- (3.3) $E < 12.0$
- (3.4) $F - E < \text{THRESHOLD}$.

(3) Two corner fault model:

- (2.1) Detection of corners + * * * * * + or
 - * * * * * -.
- (2.2) $b < 14.0$
- (2.3) $E > 7.0$ and $E < 14.0$
- (2.4) $F - E > 8.0$

ภาพที่ 2.11 Rule ที่ใช้ในการตรวจ Vector ที่เกิดขึ้น เช่น 4Corner, 3 Corner, 2Corner

การตรวจด้วยการเข้ารหัสสามารถใช้วิธีในการตรวจสอบคือการใช้ Run Length Encoding โดยการระบุช่วงความยาวของข้อมูลภาพที่เกิดขึ้น โดยการวิเคราะห์ฮิสโตแกรมทั้งแนวตั้งและแนวนอน โดยการนับความต่อเนื่องในแต่ละแถวและแต่ละคอลัมน์ ของรูป PCB แล้วจึงนำมาสร้างเป็น Histogram โดยค่า threshold ที่ระบุในการตรวจจะเป็นค่า run length ที่เกิดขึ้น

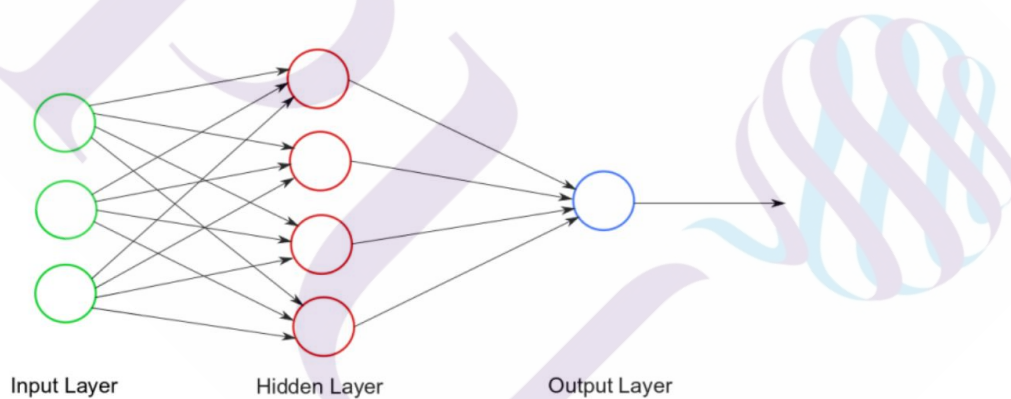
2.3. การตรวจแบบผสมผสาน

เป็นการนำวิธีการตรวจโดยอ้างอิงจากภาพต้นแบบ ไม่อ้างอิง เพื่อนำข้อดีของแต่ละแบบ เพื่อเพิ่มประสิทธิภาพ ของแต่ละวิธี


2.2. การเรียนรู้เชิงลึก (Deep Learning)

1 Deep Neural Network

Deep learning เป็นส่วนหนึ่งของ Machine Learning ที่ลอกเลียนแบบการทำงานของเซลล์ประสาทในสมองมนุษย์ (Neural Network) โดยมีการแบ่งหน่วยย่อยออกเป็น Node ซึ่งแต่ละ Node ประกอบไปด้วย แต่ละชั้นเรียกว่า Layer ที่ทำหน้าที่แตกต่างกัน ตามหน้าที่ เช่น Input Layer, Hidden Layer และ Output Layer แสดงดังภาพ



ภาพที่ 2.12 โครงสร้างโครงข่ายประสาทเทียม โดยแบ่งหน้าที่ตาม Layer



ภาพที่ 2.13 การคำนวณ โครงสร้างโครงข่ายประสาทเทียม

ที่มา: <https://intellipaat.com/community/253/role-of-bias-in-neural-networks>

$$\text{output} = \text{activation_function}(\text{sum}[\text{inputs} * \text{weights}] + \text{bias})$$

เมื่อ output แทนผลลัพธ์ของแบบจำลอง โครงสร้างโครงข่ายประสาทเทียม

activation_function แทนฟังก์ชันที่ใช้ในการแปลงค่าที่ได้จากการคำนวณค่าน้ำหนักของ โครงสร้างโครงข่ายประสาทเทียม

weights แทนค่าน้ำหนักของ Node ใน โครงสร้างข่ายประสาทเทียม

Input แทนค่า Input ของ Node


Bias แทนค่า Bias ของ Node

โครงข่ายประสาทเทียมมีลักษณะเฉพาะอยู่หลายชนิด ขึ้นอยู่กับการนำไปประยุกต์ใช้งาน เช่น

Feedforward Neural Network , Backpropagation Neural Network

การเรียนรู้เชิงลึกเป็นอัลกอริทึมที่ต่อยอดมาจากโครงข่ายประสาทเทียม โดยจะมี Hidden Layer หลายชั้น ทำให้สามารถคำนวณความซับซ้อนได้มากขึ้น โดยแต่ละชั้นมีหน้าที่การทำงานที่ไม่เหมือนกัน โดยการประมวลผลที่ได้นั้นได้ประสิทธิภาพที่สูงขึ้น และยังมีมีการนำการ

เรียนรู้แบบ Backpropagation เพื่อนำมาปรับปรุงอัลกอริทึม โดยมีตัวชี้วัดเพิ่มเติมที่เป็น Loss function และ Optimize function โดยค่าที่ได้จาก loss Function เป็นค่าเปรียบเทียบจากผลจากแบบจำลองกับข้อมูลที่ใช้ train จากนั้นจึงนำค่า Loss ที่ได้มาใช้กับ Optimize Function ซึ่งทำหน้าที่ปรับแบบจำลองที่สร้างขึ้นมา รูปแสดง Deep Learning Neural Network



ภาพที่ 2.14 การเปรียบเทียบระหว่าง Simple neural network และ Deep Learning Neural Network



2 Convolution Neural Network

โดยการประยุกต์ใช้ในระบบ Image Processing มีการประยุกต์ใช้กับ Convolution matrix เมตริกขนาดเล็ก ที่เป็น filter เพื่อประมวลผลสแกนจากภาพต้นแบบ เพื่อประมวลผลผลลัพธ์ที่เกิดขึ้น โดยวัตถุประสงค์ของการทำ filter เพื่อให้ผลลัพธ์ของรูปภาพเป็นไปตามที่ต้องการ เช่น Edge detection, Sharpen, Gaussian blur โดยวิธีการคำนวณ Convolution matrix และผลลัพธ์ แสดงดังภาพ

$$g(x, y) = \omega * f(x, y) = \sum_{dx=-a}^a \sum_{dy=-b}^b \omega(dx, dy) f(x + dx, y + dy),$$

แสดงสมการของการ Convolution Matrix

$$2*1 + 4*0 + 1*1 + 1*1 + 1*0 + 6*1 + 7*1 + 6*0 + 4*1 = -1$$




ภาพที่ 2.15 การทำ Convolution Filter

ที่มา: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>


ส่วนพารามิเตอร์ใน Convolution Neural Network

1. Stride

เป็นตัวกำหนดว่าจะเลื่อน filter ไปด้วย step เท่าไร การใส่ Stride มากขึ้นทำให้มีการคำนวณหาพื้นที่ทับซ้อนกันน้อยขึ้น และผลลัพธ์ที่ได้คือ ฟังก์ชันลักษณะ (Feature Map) มีขนาดเล็กลง




ภาพที่ 2.16 การใส่พารามิเตอร์ Stride = 1



ภาพที่ 2.17 การใส่พารามิเตอร์ Stride = 2

2. Padding


ในบางปัญหาพบว่า พื้นที่ขอบของภาพส่งผลต่อการตัดสินใจบางอย่าง จึงจำเป็นต้องเก็บคุณลักษณะตามขอบภาพไว้ด้วย



ภาพที่ 2.18 การใส่ Stride 1 กับ Padding

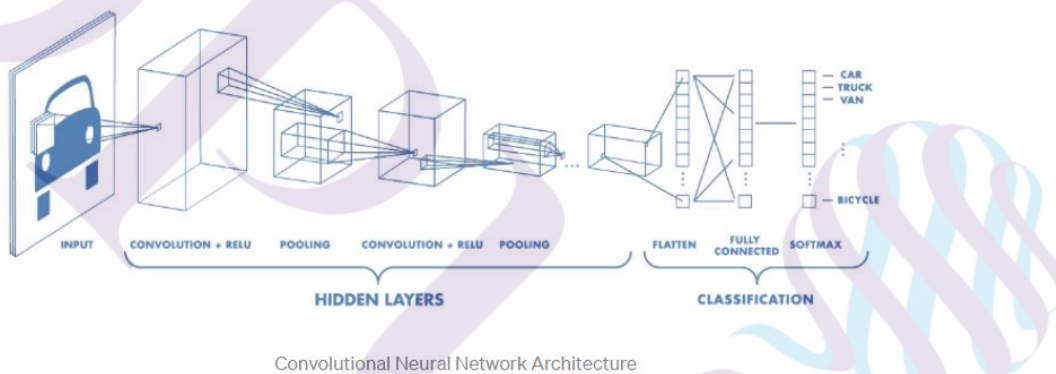
3. Pooling

ในบางปัญหาพบว่า การตัดสินใจว่าภาพดังกล่าว เป็นอะไร มีลักษณะอย่างไร บางลักษณะต้องการการลดขนาดภาพเพื่อให้เห็นภาพรวมของภาพนั้น ๆ แล้วจึงสามารถตัดสินใจได้ Pooling เป็นการลดขนาดรูปภาพมีหลายวิธีในการทำ pooling แต่ทั่วไปจะมี Max pooling, Min Pooling, Average Pooling




ภาพที่ 2.19 การทำ Max pooling ที่ขนาด 2x2 และ Stride =2

การประยุกต์ Convolution Neural network สามารถนำมาประยุกต์ใช้ในการ Classification โดยผลลัพธ์ที่ออกมาจะเป็น Label ที่บอกชนิดของรูปภาพนั้น ส่วน Object detection จะมีผลลัพธ์ที่ออกมาเป็น Label และตำแหน่ง ขนาดของ Box region Segmentation



ภาพที่ 2.20 การใช้ Convolution Neural Network ในการทำ Classification




ภาพที่ 2.21 การใช้ Convolution Neural Network ในการทำ Object Detection

ที่มา: Auepanwiriyakul, Harston, Orlov, Shafti, Aldo Faisal, (2019)



2.3 สถาปัตยกรรม Restnet 101

RestNet คือ Deep Residual Network โดยมีการนำเสนอการแก้ปัญหาเรื่อง Vanishing Gradient ซึ่งเกิดขึ้นกรณีที่มี Layer จำนวนมาก โดยการใส่ทางลัด (Shortcut) ลงในสถาปัตยกรรม เพื่อให้ผลของ input ของ layer ก่อนหน้าไม่ได้ถูกลดทอนข้อมูล จนหายไป จึงมี shortcut เพื่อนำข้อมูล Input ก่อนหน้า มารวมกับ output ที่ออกมาใน layer ถัดไป ดังแสดงในรูป Residual Block ในสารนิพนธ์นี้ พิจารณาใช้สถาปัตยกรรม Restnet101 เพื่อนำมา Classification Defective เนื่องจาก ผลการ Classification เมื่อเทียบกับ โมเดล AlexNet , VGG-16, VGG-19, GoogleNet, ResNet-50, RestNet-152 พบว่ามี error ในการ Classification น้อยที่สุด ตามรูปที่ 2.22 ส่วนที่แตกต่างกันของ Restnet-152 เมื่อเทียบกับสถาปัตยกรรมอื่น ๆ พบว่า มีจำนวน Layer m มากกว่าอยู่ที่ 152 Layer และมี Residual Block โดย Layer ที่นำมาต้องมีขนาดเท่ากัน กรณีที่มีขนาดไม่เท่ากันต้องมีการปรับขนาดของ Feature Map การปรับขนาดไปมาแบบนี้ เรียกว่า Bottleneck Building Block



ภาพที่ 2.22 แสดงสถาปัตยกรรม Resnet 101

ที่มา: Qingsheng, Dapeng, Yanbiao, Shiming, Chaopeng, Qimming, (2020)



ภาพที่ 2.23 แสดง Residual Block

2.4 การตรวจจับวัตถุด้วย Image Gradient

การจับภาพชิ้นงานด้วยกล้อง ภาพที่ได้จะมีตำแหน่งที่สนใจ ROI (Region of Interest) อยู่หลายตำแหน่ง และมีขนาดเล็กเมื่อเทียบกับขนาดภาพที่ต้องตรวจชิ้นงาน เพื่อแก้ไขปัญหาดังกล่าวจึงต้องตรวจจับชิ้นงานในตำแหน่งที่สามารถตรวจจับได้อย่างแม่นยำและรู้ตำแหน่งที่แน่นอน แล้วจึงตรวจอ้างอิงตำแหน่งนั้น ๆ มาที่ตำแหน่งที่สนใจ วิธีตรวจจับวัตถุ จะทำโดยการหา Gradient ของ Image ก่อน

$$\nabla f = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix},$$

สมการแสดง การคำนวณหา Image Gradient โดย G_x

G_x เป็น การทำ Convolution Filter โดยผ่าน Sobel แนวนอน

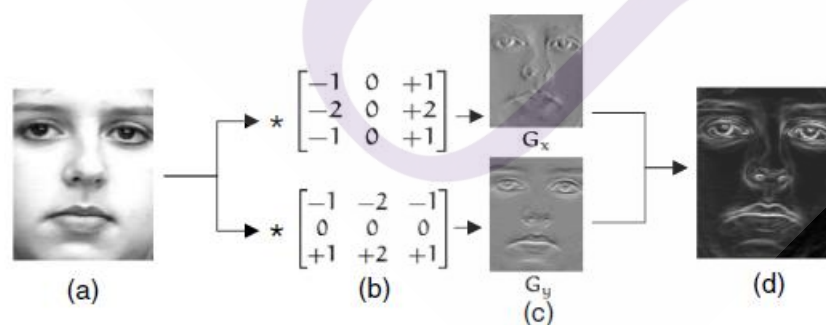
G_y เป็น การทำ Convolution Filter โดยผ่าน Sobel แนวตั้ง

$$\theta = \tan^{-1} \left[\frac{g_y}{g_x} \right],$$

สมการแสดงการคำนวณหา ทิศทางของ Gradient ของ Image

$$\sqrt{g_y^2 + g_x^2}$$

สมการแสดงการคำนวณหา ปริมาณการกระจัด (Amplitude)



ภาพที่ 2.24 การทำ Sobel แนวตั้งและแนวนอน และ Image gradient ที่เกิดขึ้น

ที่มา: Holder, Tapamo, (2017)

หลังจากหา Image gradient และ ทิศทางของ Gradient ได้แล้ว ในหนึ่งทิศทาง หลังจากนั้นทำการหมุน ทิศทาง Gradient ในที่นี้จะเรียก Template Image ตามความละเอียดที่ต้องการโดยกำหนดเป็นค่าองศา เช่น 1 องศา

ก็จะต้องทำการหมุน 360 ตัวอย่าง หรือ 45 องศา จะต้องทำ 8 ตัวอย่าง เพื่อตรวจจับชิ้นงานที่หมุนที่มีการหมุนอยู่ โดยพื้นฐาน สามารถนำแต่ละ Template Image ไป สแกนหาตำแหน่งของวัตถุได้เลย โดยมีการกำหนดค่า Threshold ว่าภาพที่สแกนต้องเหมือนกับต้นแบบ (Template) เท่าไร จึงจะแสดงว่าภาพดังกล่าวคือวัตถุที่ต้องการตรวจจับ

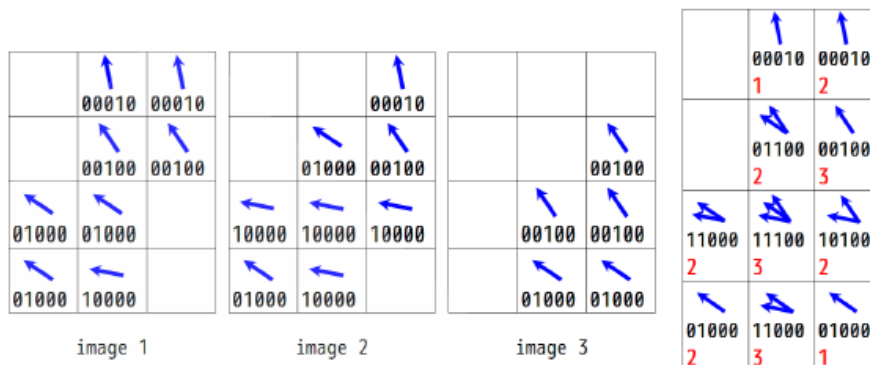
ปัญหาประการแรก ในการใช้ Template Image ในแต่ละรูปในการสแกนทั้งรูปที่ต้องการค้นหาพบว่าต้องใช้เวลาในการประมวลผล เช่น จำนวน Template Image 360 ตัวอย่าง ต้องใช้เวลาสแกน 360 ในแต่ละรูป เพื่อลดเวลาในการสแกนดังกล่าว จึงมีการสร้าง Template Image ที่เป็น Template Image ที่ผ่านการ OR operation (Cumulative Orientation) โดยตำแหน่งที่สแกนไปแล้วจะไม่มีสแกนซ้ำ

ปัญหาประการที่สอง Yoshinori Konishi, Yoshihisa Ijiri, Masaki Suwa, Masato Kawade (2015) ได้พัฒนา Detection Rate ให้สูงขึ้นจากอัลกอริทึมแบบเดิมโดยเพิ่มและลดขนาดของ Template Image 5% จาก Master Template Image และองศา 5 ในแต่ละ Step ในการทำ Template Image +/-180 องศา พบว่า Detection Rate อยู่ที่ 85.8% เมื่อเทียบกับอัลกอริทึม Halcon , LINE2D, BOLD อยู่ที่ 45.8% , 51.0%, 85.1%




ภาพที่ 2.25 การสร้างรูป template ภาพต้นแบบ (ซ้าย) Gradient Image (กลาง) การสร้าง Gradient Image ในหลายทิศทาง

ที่มา: Yoshinori Konishi, Yoshihisa Ijiri, Masaki Suwa, Masato Kawade (2015)



ภาพที่ 2.26 องศาของ Gradient ของทั้ง 3 วัตถุ (เก้าอี้) แสดงการทำองศาสะสมในแต่ละทิศทางของชิ้นงาน โดยใช้ OR operation โดย ตัวอักษรสีแดงคือความถี่ของแต่ละทิศทาง


ที่มา: Yoshinori Konishi, Yoshihisa Ijiri, Masaki Suwa, Masato Kawade (2015)



ภาพที่ 2.27 Similarity Score Based ในการสแกนรูป พบว่า Cumulative Orientation มีค่าสูงและความแตกต่างมากขึ้น ซึ่งจะเป็นการเพิ่ม Detection Rate

ที่มา: Yoshinori Konishi, Yoshihisa Ijiri, Masaki Suwa, Masato Kawade (2015)

เพื่อเพิ่มประสิทธิภาพในการค้นหาวัตถุ มีการประยุกต์ใช้อัลกอริทึม Gaussian Pyramid เพื่อลดขนาดภาพและค้นหาภาพจากภาพที่มีขนาดเล็กแล้วจึงนำตำแหน่งที่ค้นหาเจอมาค้นหาใน Layer ที่สูงขึ้นเรื่อยๆ เพื่อเพิ่มความแม่นยำมากขึ้น ซึ่งการสแกนหลังจากมีการเลื่อนชั้น Layer จะมีการสแกนไปยังพิกเซลก่อนหน้า และพิกเซลที่อยู่หลังถัดไปอีกฟหลังจากมีการสแกนที่ใหญ่ขึ้น

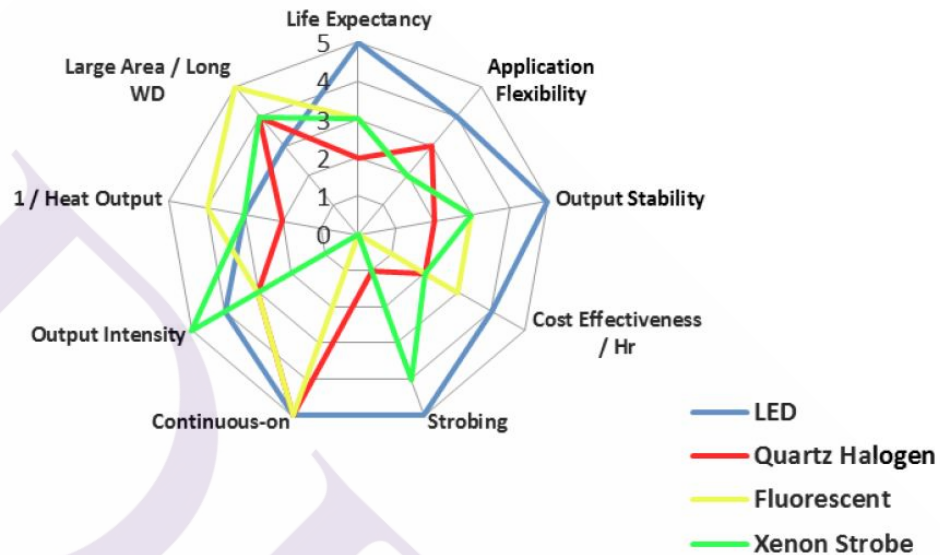


ภาพที่ 2.30 การลดขนาดภาพโดยวิธี Gaussian Pyramid ที่มา: Carlos Spitzer

2.5 การเลือกชนิดแสงสำหรับงาน Machine Vision

ใน Machine Vision แสงเป็นองค์ประกอบหนึ่งที่ต้องทำการเลือกและทดสอบ เพราะถ้าแสงไม่มีความเหมาะสม ข้อมูลภาพที่ได้ไม่สามารถนำมาใช้ประโยชน์ได้ จากรูปที่ 2.31 จะพบว่างาน Machine Vision ส่วนมากจะเลือกการใช้ไฟ LED สาเหตุเพราะว่า มีอายุการใช้งานดีที่สุด สามารถปรับแต่ตำแหน่งตามความเหมาะสม มีความเสถียร ความสม่ำเสมอด้านความเข้มแสง การกระพริบของแสง ต้นทุนของการประยุกต์ใช้ต่อหน่วยชั่วโมงเนื่องจากกินไฟน้อย ความสามารถ


ในการปรับความเข้มแสง การใช้งานต่อเนื่องอยู่ในเกณฑ์โดยรวมที่ดีกว่าแหล่งกำเนิดแสงชนิดอื่น ๆ ค่อนข้างมาก



ภาพที่ 2.31 ประเภทแหล่งกำเนิดแสงแต่ละชนิดและประสิทธิภาพในแต่ละประเภท (5 คือดีที่สุด 0 คือแย่ที่สุด)


ที่มา: Martin, (2013)

การเลือกทิศทางของแหล่งกำเนิดแสงก็ส่งผลกระทบต่อข้อมูลภาพที่ได้โดย ภาพที่ 2.32 แสดงการติดตั้งตำแหน่งแสงที่แตกต่างกัน



ภาพที่ 2.32 ชนิดแสงและการใช้งาน (a) Backlight (b) Direction Light field(Bright field) (c,d) Diffuse on Axis (e) Bright field or Dark field (f) Diffusion ที่มา: Daryl Martin(2013)

ที่มา: Martin, (2013)




ภาพที่ 2.33 ชนิดของภาพกับลักษณะของพื้นผิวในการเลือกชนิดแหล่งกำเนิดแสง ผิวเรียบ(Flat) ผิวไม่สม่ำเสมอ (Topography) ผิวโค้ง (Curved) และ ลักษณะการสะท้อนแสง ผิวด้าน(Matte) ผิวผสม (Mixed) ผิวสะท้อน (Mirror Specular)

ที่มา: Martin, (2013)




ภาพที่ 2.34 ชิ้นงานเดียวกัน แต่ใช้แสงต่างชนิดกัน Bright Field (ซ้าย) Diffuse Light (ขวา)

ที่มา: Martin, (2013)




ภาพที่ 2.35 ชิ้นงานเดียวกัน แต่ใช้แสงต่างชนิดกัน Bright Field (ซ้าย) Diffuse Light (ขวา)

ที่มา: Martin, (2013)



ภาพที่ 2.36 การใช้ Diffuse Lighting เพื่อตรวจสอบความขรุขระที่ผิว
ชิ้นงานปกติ (ซ้าย) ชิ้นงานที่เสียหายที่ผิว(ขวา)

ที่มา: Martin, (2013)



ภาพที่ 2.37 การใช้แสงต่างชนิดกัน LED สีแดง (ซ้าย) UV Fluorescence (ขวา)

ที่มา: Martin, (2013)



ภาพที่ 2.38 ภาพที่ใช้แสง LED แต่ละสีบนชิ้นงานที่พิมพ์ด้วยแสงสีแดง

ที่มา: Martin, (2013)

2.5 Desktop Application

หลังจากออกแบบ เครื่องจักรและประกอบเสร็จเรียบร้อย ระบบที่ใช้กับเครื่องจักรที่เหมาะสมจะเป็น Desktop Application พัฒนาด้วยภาษา C# โดยหน้าที่ของ โปรแกรมมีหน้าที่ในการกำหนดตำแหน่งการตรวจชิ้นงาน ตำแหน่งในการ Marking ด้วยหมึกสีของงานเสีย รองรับการเปลี่ยนการเปลี่ยนหลายๆ โมเดล และเป็นการเชื่อมต่อผ่าน Web Service Interface กับ AI Module ของ Python โดยการเชื่อมต่อระหว่าง Module สามารถติดตั้ง Webservice ใน localhost หรือ server ส่วนกลางก็ได้

2.6 Web Service


Web Service ในระบบนี้ใช้ Framework RESTful API โดยเป็น Webservice ที่รันอยู่บน HTTP protocol โดยฝั่ง Client สามารถทำการ Request ตาม Method ที่ต้องการและ การรับส่งข้อมูลพารามิเตอร์ ทำให้ระบบโดยรวมรองรับการสื่อสารผ่านหลากหลายอุปกรณ์ ไม่ว่าจะเป็น PC หรือ Mobile Application

บทที่ 3

ระเบียบวิธีวิจัย

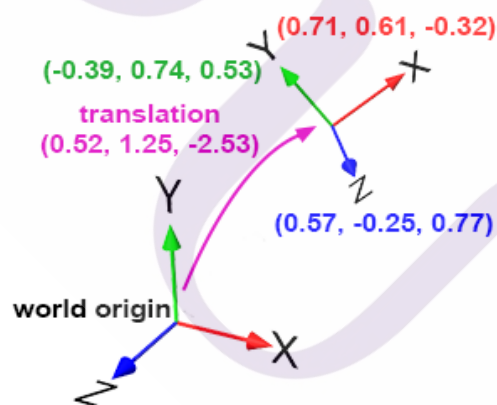
3.1. การค้นหาตำแหน่งงานเสียที่พบบ่อย

ตำแหน่งงานเสียที่พบจะอยู่ตำแหน่งเฉพาะของบนชิ้นงานในแต่ละแผ่นงาน ที่มีจำนวนงาน 20-100 ชิ้นในแต่ละแผ่นงาน และชิ้นงานดังกล่าวเป็นแผงวงจรยึดหุ่นที่มีความบางและสามารถให้ตัวได้ในแต่ละตำแหน่ง การบันทึกภาพเพื่อนำมาวิเคราะห์ จึงต้องทำการชดเชยตำแหน่งที่เกิดจากการคลาดเคลื่อนดังกล่าว การค้นหาตำแหน่งสามารถทำได้ด้วยวิธีการ ในการศึกษาใช้วิธีค้นหามุมของ Image Gradient ของภาพต้นแบบหลังจากนั้นจึงทำการสแกนค้นหาทั่วทั้งภาพที่ต้องการตรวจ ด้วยการเปรียบเทียบค่า Similarity ของภาพต้นแบบและ พื้นที่ในการค้นหา หลังจากนั้น นำค่า Similarity มาเปรียบเทียบกับค่า Threshold ในการตั้งขอบเขต เพื่อกำหนดว่าถ้าค่า Similarity มากกว่าค่าดังกล่าวแล้ว ผลลัพธ์ที่ได้จะเป็นตำแหน่งของค่าอิง ซึ่งจะได้พิกัดมาเป็นตำแหน่ง X และ Y ของวัตถุที่ค้นพบ พบว่าตำแหน่งงานที่ห่างออกไปจากตำแหน่งอ้างอิง มีผลกระทบจากองศา ของชิ้นงานด้วย จึงจำเป็นต้องทำการหาค่าองศาของตำแหน่งอ้างอิงดังกล่าว โดยการสแกนจะกำหนดค่าความละเอียดในการสแกนหามุมดังกล่าว เช่น 0.1 ถึง 10 องศาแล้วแต่ความต้องการ โดยค่าที่มีค่า Similarity มากที่สุดจะเป็นมุมของชิ้นงานนั้น ๆ จะได้ตำแหน่ง X Y Theta ของแต่ละชิ้นงาน




ภาพที่ 3.1 แสดงตำแหน่งอ้างอิงที่เกิดจากการชดเชยเพียงค่า X และ Y และความคลาดเคลื่อนจากตำแหน่งการตรวจจับงานเสีย

จะพบว่าตำแหน่งงานเสียบกับตำแหน่งอ้างอิงอยู่ใน Local Coordinate จึงต้องทำการ Transform ตำแหน่งงานเสีย ให้อยู่ในพิกัด Global Coordinate โดยการนำค่า X Y Theta ที่เกิดขึ้นมาหาตำแหน่งงานเสียดังกล่าว หลังจากที่ได้ตำแหน่งงานเสียแล้วระบบจะบันทึกภาพตำแหน่งนั้น ๆ และ ผูกกับตำแหน่งตัวงานดังกล่าวเพื่อระบุว่าตัวงานชิ้นไหนที่เสียต่อไป



ภาพที่ 3.2 แสดง Global and Local coordinate Transformation

ที่มา: <https://www.scratchapixel.com/lessons/3d-basic-rendering/computing-pixel-coordinates-of-3d-point/mathematics-computing-2d-coordinates-of-3d-points>)




ภาพที่ 3.3 แสดงตำแหน่งงานเสียที่ตรวจพบบนแต่ละชิ้นงาน

3.2. ทำการแยกประเภทงานดีงานเสีย

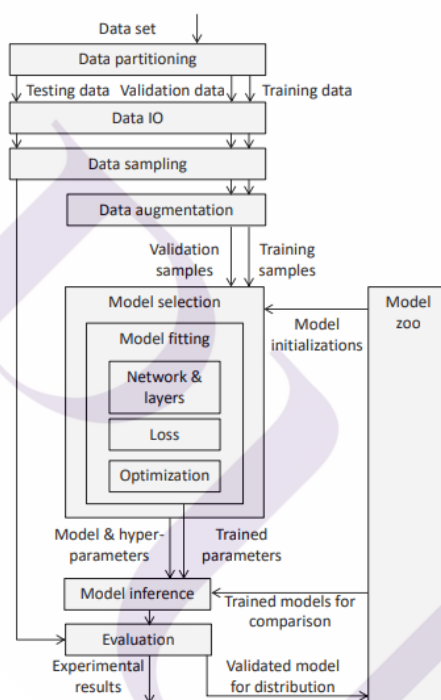
หลังจากทำการบันทึกภาพและตำแหน่งงานเสียไว้ในหน่วยความจำแล้ว จึงนำภาพตำแหน่งดังกล่าว มาแยกประเภทงานดี งานเสีย (Classification) โดยนำตัวอย่างข้อมูลประมวลประกอบไปด้วย 2 กลุ่ม โดยแบ่งเป็น

1. งานดี 150 ตัวอย่าง แบ่งข้อมูลเป็น 2 ส่วน Train 100 ตัวอย่าง Test 50 ตัวอย่าง
2. งานเสีย 150 ตัวอย่าง แบ่งข้อมูลเป็น 2 ส่วน Train 100 ตัวอย่าง Test 50 ตัวอย่าง



ภาพที่ 3.4 ตัวอย่างงานดีด้านซ้ายมือและตัวอย่างงานเสียด้านขวามือ

หลังจากนั้นนำไปภาพที่ได้ไปผ่านกระบวนการในการประยุกต์ใช้ Deep Learning project ซึ่งประกอบไปด้วยสามส่วน 1) การเลือก model เป็นการนำ model ที่เลือกมา train บน train data 2) การประเมิน model เป็นการวัดประสิทธิภาพของ model ด้วย test data 3) การนำ model ที่ได้นำไปใช้งาน โดย Data set ที่ได้มาจะถูกแบ่งเป็น 3 ส่วนสำหรับ Train, Validation, Test หลังจากนั้นจึงผ่านกระบวนการ Data Augmentation เป็นการแปลงข้อมูลให้มีความหลากหลายมากขึ้น ในกรณีที่ข้อมูลภาพจะทำการแปลงข้อมูลภาพ เช่นย่อ ขยาย หมุนซ้าย หมุนขวา Flip ซ้าย Flip ขวา ปรับสี เพิ่ม หรือ ลด noise ทำให้ model ที่เกิดจากการ train ลดปัญหา overfitting และมีความหลากหลายมากขึ้น จึงทำให้ model ที่เกิดขึ้น สามารถนำไปใช้ได้มีความเสถียรมากขึ้น หลังจากนั้นจึงโมเดลดังกล่าวไปพัฒนาระบบต่อไป




ภาพที่ 3.5 Data Flow สำหรับ Deep Learning project

ที่มา: Gibsons, Wenqi, Carole, NiftyNet, (2017)


โมเดลที่ใช้ในการทดสอบมี 2 โมเดล

1. Customized Model โดยการสร้างโมเดล



ภาพที่ 3.6 แสดง Customize model ที่ใช้ในการทดสอบการ Classification

2. Resnet Model โดยการสร้างโมเดล



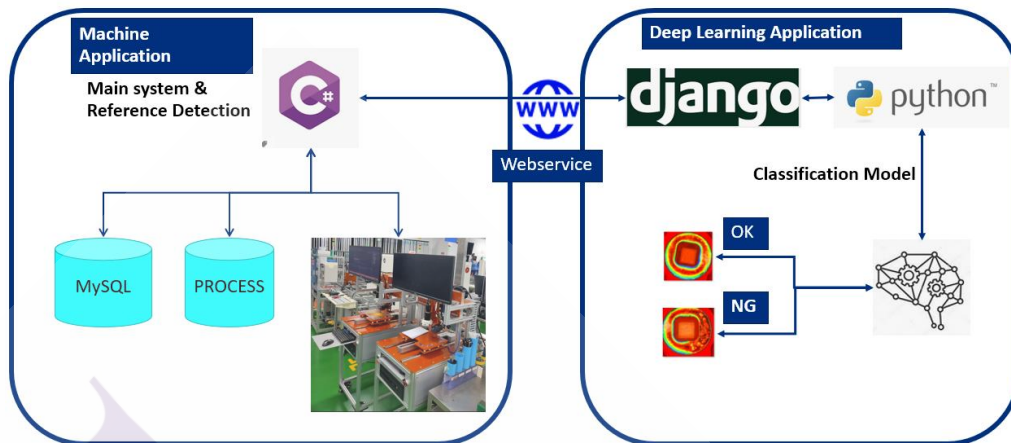
ภาพที่ 3.7 แสดง Resnet model ที่ใช้ในการทดสอบการ Classification

3.3 การออกแบบระบบและการนำไปใช้งาน


การศึกษาเรื่อง เครื่องตรวจสอบสภาพการหลอมละลายด้วยปัญญาประดิษฐ์ เครื่องดังกล่าวต้องมีหน้าที่ดังนี้

1. เครื่องจักรต้องการเป็น Stand alone โดยแยกออกมาจากเครื่อง inline
2. เมื่อชิ้นงานออกมาจากเครื่อง AOI พนักงานจะหยิบชิ้นงานมาวางไว้บนเครื่องจักรที่จะทำการประกอบขึ้นมา
3. พนักงานกดปุ่มเพื่อเริ่มการตรวจ ระบบจะทำการอ่าน 2D Datamatrix barcode แล้วจึงเรียก service ของหน่วยงาน IT เพื่อรับค่าตำแหน่งงานเสียจาก เครื่อง อ่าน AOI ก่อนหน้านี้
4. เครื่องจักรจะทำการค้นหาตำแหน่งงานเสียที่ต้องการตรวจ แล้วจึงทำการถ่ายภาพและเก็บตัวอย่างภาพ หลังจากนั้นระบบจะทำการเรียก web service เพื่อทำการรับผลการประเมินการตรวจผ่าน
5. ระบบทำการตัดสินใจแล้วจึงส่งผลการตัดสินใจเข้า service ของ หน่วยงาน IT
6. เป็นการเสร็จสิ้นกระบวนการทำงานและรอรับชิ้นงานใหม่ต่อไป

ระบบที่ทำการพัฒนาประกอบไปด้วยสามส่วน หลัก ส่วนแรกเป็นการเก็บข้อมูลกระบวนการเครื่องจักรทั้งองค์กร และการรับส่งข้อมูลกระทำผ่าน service ที่เรียกโดย dll library ส่วนที่สองส่วนระบบ Desktop Application ที่ใช้ในการควบคุมเครื่องจักรและกลไกต่าง ๆ การ setting parameter ของเครื่อง และอื่น ๆ ที่เกี่ยวข้องกับเครื่องจักร ส่วนที่สาม HTTP webservice ที่พัฒนาผ่าน Restful framework และติดตั้งบน Django ที่รองรับการใช้งานภาษา python ในการประมวลผลด้าน AI Deep learning โดย ระบบ Desktop application จะทำการถ่ายรูปและส่งข้อมูลให้ HTTP webservice ประมวลผลข้อมูลดังกล่าวและทำการตัดสินใจข้อมูลนั้นกลับมายัง Desktop application



ภาพที่ 3.8 ระบบเครื่องจักรที่พัฒนาเพื่อตรวจชิ้นงาน



ภาพที่ 3.9 ระบบเครื่องจักรที่พัฒนาเพื่อตรวจชิ้นงาน



ภาพที่ 3.10 ค่า Setting ต่าง ๆ ที่เครื่องจักรใช้ในการปฏิบัติงาน



ภาพที่ 3.11 การเรียก HTTP service เพื่อให้ระบบ Desktop application สามารถเชื่อมต่อกับระบบ AI




ภาพที่ 3.12 แสดงการติดตั้งเครื่องจักรที่ใช้ในการตรวจชิ้นงาน


บทที่ 4 ผลการศึกษา

4.1 ผลการทดสอบ Validation Dataset

การสร้างโมเดลในการตรวจชิ้นงาน พบว่า Customized Model validation accuracy อยู่ที่ 86% และ Restnet101 อยู่ที่ 82%



ภาพที่ 4.1 กราฟการเทรนข้อมูลโมเดล Customized



ภาพที่ 4.2 กราฟการเทรนข้อมูลโมเดล Restnet101

ตารางที่ 4.1 Validation accuracy

Accuracy	
Customized	Restnet 101
86%	82%

จากตารางพบว่าเมื่อนำโมเดลไปทดสอบการใช้งาน พบว่าการตัดสินใจโดยใช้

4.2 ผลการทดสอบ Test Dataset

พบว่าการใช้ Threshold > 0.5 ในส่วนของคลาสงานดี (OK) พบว่า Customized Model accuracy อยู่ที่ 92% และ Restnet101 อยู่ที่ 97%

ตารางที่ 4.2 Test dataset accuracy Threshold ในการระบุงานดี >50%

Accuracy	
Customized	Restnet 101
92%	97%

4.3 ผลการทดสอบ Threshold Test Dataset

เนื่องจากผล Test Model Restnet101 ได้ผลค่อนข้างดีกว่า Customized Model ระบบจึงตัดสินใจใช้ Restnet101 มาใช้ในการปรับ Threshold พบว่าการตัดสินใจโดยใช้ Threshold > 0.8 Accuracy Restnet101 อยู่ที่ 99%

ตารางที่ 4.3 Test dataset accuracy Threshold ในการระบุงานดี >80%

Accuracy	
Customized	Restnet 101
N/A	99%

ตารางที่ 4.4 แสดง Prediction ที่ Threshold >0.5

Threshold 0.5 for judgement			Threshold 0.5 for judgement		
Class	OK		Class	DEWET	
Predict	Dewet	OK	Predict	Dewet	OK
1	0.30	0.70	1	0.97	0.03
2	0.25	0.75	2	0.98	0.02
3	0.14	0.86	3	0.97	0.03
4	0.29	0.71	4	0.95	0.05
5	0.75	0.25	5	0.97	0.03
6	0.11	0.89	6	0.97	0.03
7	0.50	0.50	7	0.95	0.05
8	0.16	0.84	8	0.97	0.03
9	0.09	0.91	9	0.95	0.05
10	0.25	0.75	10	0.97	0.03
11	0.44	0.56	11	0.95	0.05
12	0.16	0.84	12	0.97	0.03
13	0.39	0.61	13	0.94	0.06
14	0.06	0.94	14	0.97	0.03
15	0.05	0.95	15	0.97	0.03
16	0.14	0.86	16	0.96	0.04
17	0.14	0.86	17	0.97	0.03
18	0.07	0.93	18	0.95	0.05
19	0.10	0.90	19	0.98	0.02
20	0.16	0.84	20	0.90	0.10
21	0.29	0.71	21	0.97	0.03
22	0.22	0.78	22	0.95	0.05
23	0.62	0.38	23	0.97	0.03
24	0.36	0.64	24	0.94	0.06
25	0.27	0.73	25	0.98	0.02
26	0.20	0.80	26	0.94	0.06
27	0.07	0.93	27	0.97	0.03
28	0.20	0.80	28	0.96	0.04
29	0.69	0.31	29	0.95	0.05
30	0.09	0.91	30	0.06	0.94
31	0.09	0.91	31	0.95	0.05
32	0.35	0.65	32	0.95	0.05
33	0.17	0.83	33	0.97	0.03
34	0.28	0.72	34	0.95	0.05
35	0.61	0.39	35	0.95	0.05
36	0.10	0.90	36	0.97	0.03
37	0.39	0.61	37	0.95	0.05
38	0.10	0.90	38	0.97	0.03
39	0.14	0.86	39	0.95	0.05
40	0.15	0.85	40	0.97	0.03
41	0.68	0.32	41	0.95	0.05
42	0.30	0.70	42	0.97	0.03
43	0.20	0.80	43	0.95	0.05
44	0.16	0.84	44	0.97	0.03
45	0.08	0.92	45	0.95	0.05
46	0.27	0.73	46	0.97	0.03
47	0.34	0.66	47	0.97	0.03
48	0.44	0.56	48	0.95	0.05
49	0.05	0.95	49	0.97	0.03
50	0.07	0.93	50	0.95	0.05
MAX	0.75	0.95	MAX	0.98	0.94
MIN	0.05	0.25	MIN	0.06	0.02
ACCURACY	88%		ACCURACY	98%	

ตารางที่ 4.5 แสดง Prediction ที่ Threshold >0.8

Threshold 0.8 for judgement

Class	OK	
	Dewet	OK
1	0.30	0.70
2	0.25	0.75
3	0.14	0.86
4	0.29	0.71
5	0.75	0.25
6	0.11	0.89
7	0.50	0.50
8	0.16	0.84
9	0.09	0.91
10	0.25	0.75
11	0.44	0.56
12	0.16	0.84
13	0.39	0.61
14	0.06	0.94
15	0.05	0.95
16	0.14	0.86
17	0.14	0.86
18	0.07	0.93
19	0.10	0.90
20	0.16	0.84
21	0.29	0.71
22	0.22	0.78
23	0.62	0.38
24	0.36	0.64
25	0.27	0.73
26	0.20	0.80
27	0.07	0.93
28	0.20	0.80
29	0.69	0.31
30	0.09	0.91
31	0.09	0.91
32	0.35	0.65
33	0.17	0.83
34	0.28	0.72
35	0.61	0.39
36	0.10	0.90
37	0.39	0.61
38	0.10	0.90
39	0.14	0.86
40	0.15	0.85
41	0.68	0.32
42	0.30	0.70
43	0.20	0.80
44	0.16	0.84
45	0.08	0.92
46	0.27	0.73
47	0.34	0.66
48	0.44	0.56
49	0.05	0.95
50	0.07	0.93
MAX	0.75	0.95
MIN	0.05	0.25
ACCURACY	100%	

Threshold 0.8 for judgement

Class	DEWET	
	Dewet	OK
1	0.97	0.03
2	0.98	0.02
3	0.97	0.03
4	0.95	0.05
5	0.97	0.03
6	0.97	0.03
7	0.95	0.05
8	0.97	0.03
9	0.95	0.05
10	0.97	0.03
11	0.95	0.05
12	0.97	0.03
13	0.94	0.06
14	0.97	0.03
15	0.97	0.03
16	0.96	0.04
17	0.97	0.03
18	0.95	0.05
19	0.98	0.02
20	0.90	0.10
21	0.97	0.03
22	0.95	0.05
23	0.97	0.03
24	0.94	0.06
25	0.98	0.02
26	0.94	0.06
27	0.97	0.03
28	0.96	0.04
29	0.95	0.05
30	0.06	0.94
31	0.95	0.05
32	0.95	0.05
33	0.97	0.03
34	0.95	0.05
35	0.95	0.05
36	0.97	0.03
37	0.95	0.05
38	0.97	0.03
39	0.95	0.05
40	0.97	0.03
41	0.95	0.05
42	0.97	0.03
43	0.95	0.05
44	0.97	0.03
45	0.95	0.05
46	0.97	0.03
47	0.97	0.03
48	0.95	0.05
49	0.97	0.03
50	0.95	0.05
MAX	0.98	0.94
MIN	0.06	0.02
ACCURACY	98%	

ตารางที่ 4.6 ผล Accuracy ที่ Threshold แตกต่างกัน

Threshold > 0.5 for judgement

	Predict:OK	Predict:Dewet
Actual:OK	44	6
Actual:Dewet	1	49

Threshold > 0.8 for judgement

	Predict:OK	Predict:Dewet
Actual:OK	50	0
Actual:Dewet	1	49

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การสร้างโมเดลด้วยการเรียนรู้เชิงลึก ในโมเดล Customized มี accuracy ที่ 92% ส่วนโมเดล RestNet101 ที่ 97% โดยมีค่า Threshold ที่ใช้ในการตัดสินใจในของคลาสงานเสียอยู่ที่ >50% และหลังจากการเปลี่ยนค่า Threshold และเพิ่มกฎโดยให้การตัดสินใจในของคลาสงานเสียอยู่ที่ > 80% พบว่า RestNet101 มี accuracy ที่ 99% ซึ่งจากผลการศึกษาระบบที่พัฒนาสามารถลดการตัดสินใจคลาดเคลื่อนได้จาก 10% เหลือเพียง 1% เมื่อมีการประยุกต์ใช้เครื่องจักรและระบบที่ออกแบบในการศึกษานี้ ร่วมกับเครื่องจักรตรวจชิ้นงานที่ใช้อยู่ในโรงงานกรณีศึกษา

5.2 Futurework

แนวทางที่ผู้วิจัยจะนำไปพัฒนาต่อมีดังนี้

1. ระบบที่พัฒนาควรจะสามารถขึ้นตอนการเทรนเข้าไปในระบบด้วย เพื่อรองรับงานหลายๆโมเดล โดยไม่ต้องไปรัน Python script
2. เพื่อเพิ่มความยืดหยุ่นระบบควรจะสามารถเพิ่ม คลาสในการตัดสินใจเพิ่มเติมตามจำนวนที่ระบุ กรณีที่นำเครื่องไปใช้กับสายการผลิตอื่น ๆ
3. นำระบบที่พัฒนาในส่วนการตรวจจับวัตถุ ไประบุตำแหน่งชิ้นงาน ที่ต้องการให้หุ่นยนต์จับ โดยใช้ระบบวิชั่น
4. นำระบบที่พัฒนาไปประยุกต์ใช้งานที่หลากหลายมากขึ้น



บรรณานุกรม

บรรณานุกรม


- Baohua Qiang, Ruidong Chen, Mingliang Zhou, Yuanchao Pang, Yijie Zhai, Minghao Yang (2020). Convolutional Neural Networks-Based Object Detection Algorithm by Jointing Semantic Segmentation for Images. www.mdpi.com/journal/sensors
- Daryl Martin(2013). Practical Guide to Machine Vision Lighting. Advanced illumination.
- Jianlong fu, Yong rui (2017). Advances in deep learning approaches for image tagging. Industrial Technology Advances.
- Madhav Moganti, Fikret Ercal, Cihan H. Dagli, Shou Tsunekawa. Automatic PCB Inspection Algorithms: A Survey
- Qingsheng Jiang , Dapeng Tan , Yanbiao Li, Shiming Ji *, Chaopeng Cai and Qiming Zheng : “Object Detection and Classification of Metal Polishing Shaft Surface Defects Based on Convolutional Neural Network Deep Learning” applied sciences Article, 20 Dec 2019
- Stjepan Ložnjak, Tin Kramberger, Ivan Cesar, Renata Kramberger (2020). Automobile Classification Using Transfer Learning on ResNet Neural Network Architecture’ Polytechnic & Design 8(1),58-64
- Ross P. Holder and Jules R. Tapamo* (2017). Improved gradient local ternary patterns for facial expression recognition. EURASIP Journal on Image and Video Processing , 42-57
- Yoshinori Konishi, Yoshihisa Ijiri, Masaki Suwa, Masato Kawade (2015). Textureless object detection using cumulative orientation feature. ResearchGate



ภาคผนวก


ภาคผนวก ก
ขั้นตอนการทำงานของโปรแกรม





1. การใช้แบ่งเป็นสองเมนูหลัก เมนูสำหรับใช้งาน และ เมนูสำหรับติดตั้ง
2. เมนูสำหรับใช้งาน
 - 2.1 ทำการเลือกโมเดลใน combobox
 - 2.2 ทำการ กดปุ่ม Load
 - 2.3 กดปุ่ม Start เพื่อเริ่มใช้งาน หลังจากนั้นทำการวางชิ้นงานแล้วกดปุ่มสวิทช์ RUN เมื่อทำงานจนเสร็จ นำชิ้นงานออก และวางชิ้นงานใหม่ และกด RUN ได้อย่างต่อเนื่อง
 - 2.4 ปุ่ม Capture ไว้สำหรับถ่ายภาพชิ้นงาน
 - 2.5 ปุ่ม HOME ไว้สำหรับ Origin แกนไฟฟ้าก่อนเริ่มงานครั้งแรก
 - 2.6 ปุ่ม Reset ไว้สำหรับ reset ขอดการผลิต
 - 2.7 ปุ่ม Judgement ไว้สำหรับตรวจสอบชิ้นงานที่ละตำแหน่ง
 - 2.8 ปุ่ม L1 ON L2 ON ไว้สำหรับเปิดไฟตรวจชิ้นงาน
 - 2.9 ปุ่ม VAC ON OFF ไว้สำหรับเปิด ปิด Vacuum สำหรับยึดจับชิ้นงาน

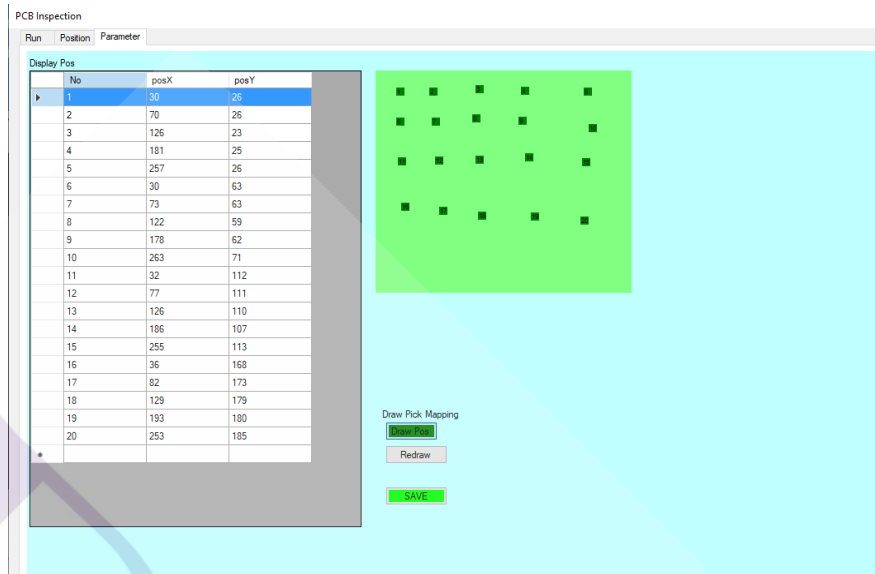
3. เมนูสำหรับติดตั้ง



3.1 ทำการระบุตำแหน่งที่ต้องการเคลื่อนที่ไปในช่องพิกัด X และ Y หลังจากนั้นกดปุ่ม MOVE หรือจะทำการกด Servo Off แล้วใช้มือเลื่อนหาตำแหน่งก็ได้ เมื่อได้ตำแหน่งที่ต้องการแล้วกดปุ่ม Capture เพื่อตรวจสอบตำแหน่งภาพที่เกิดขึ้นว่าอยู่ใน Field of View (FOV) ของกล้องหรือไม่ เมื่อตรวจสอบว่าตำแหน่งที่แกนไฟฟ้าเคลื่อนนั้นถูกต้องแล้ว จึงทำการกดปุ่ม Current Position เพื่ออ่านตำแหน่งปัจจุบันของแกนไฟฟ้า เพื่อนำไปใส่ในตาราง Capture Pos

3.2 ทำลักษณะเดียวกัน แต่ตำแหน่งที่ Stamp ให้ตรงกับปากกาที่ติดไว้กับกระบอบอกสูบ แล้วจึงระบุในตาราง Mark Pos โดยการเลื่อนกระบอบอกสูบขึ้นลง ให้กดที่ปุ่ม DOWN และ UP

3.3 เพื่อลดระยะเวลาการเคลื่อนที่และตำแหน่งที่เหมาะสมของ XY ในการ Load และ Unload ชิ้นงาน สามารถระบุที่ตำแหน่ง Position Home และตำแหน่งที่ใช้ในการอ่าน 2D barcode เพื่อดึงข้อมูลจากเครื่องจักรก่อนหน้า ให้ระบุที่ตำแหน่ง Position Read barcode ถ้าต้องการทดสอบการอ่าน Barcode สามารถทดสอบการอ่านที่ปุ่ม Read Barcode



3.4 ผู้ใช้สามารถกดปุ่ม Draw Position เพื่อระบุตำแหน่งในการแสดงงานดึงงานเสียตามตำแหน่งของชิ้นงานและตำแหน่งการตรวจได้ตามภาพ กรณีที่ต้องการแก้ไขให้กดปุ่ม Redraw เพื่อ Reset ค่าเก่า เมื่อทำการใส่ Parameter ครบแล้วจึงกดปุ่ม SAVE เพื่อทำการบันทึกค่า

ประวัติผู้เขียน

ชื่อ-นามสกุล

ประวัติการศึกษา

นายสุวิกรม อุดรรัตนานวัตร

พ.ศ. 2544

สำเร็จการศึกษาวิทยาศาสตร์บัณฑิต

สาขาฟิสิกส์

มหาวิทยาลัยสงขลานครินทร์ วิทยาเขต หาดใหญ่

พ.ศ. 2551

สำเร็จการศึกษาวิทยาศาสตรมหาบัณฑิต

สาขาเทคโนโลยีสารสนเทศ

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

พ.ศ. 2555

สำเร็จการศึกษาวิทยาศาสตรมหาบัณฑิต

สาขาการจัดการ ใ้ช้อุปทานแบบบูรณาการณั้

มหาวิทยาลัยธุรกิจบัณฑิตย์

