

การพัฒนาการประเมินความหลวมของสลักเกลียวจากภาพโครงสร้างเหล็กสำเร็จรูปโดยใช้โครงข่าย  
ประสาทเชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต  
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2565  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Bolt Looseness Assessment Development of Modular Steel Construction Image using  
Deep Learning



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Science in Computer Science  
Department of Computer Engineering  
FACULTY OF ENGINEERING  
Chulalongkorn University  
Academic Year 2022  
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพัฒนาการประเมินความหลวมของสลักเกลียวจากภาพ โครงสร้างเหล็กสำเร็จรูปโดยใช้โครงข่ายประสาทเชิงลึก
โดย	นายณัชพล พันธุ์เมธาฤทธิ์
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	อาจารย์ ดร.พรรณราย ศิริเจริญ
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ผู้ช่วยศาสตราจารย์ ดร.ยุทธพงษ์ จิรรัชโยธิน รองศาสตราจารย์เอนก ศิริพานิชกร

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัยเป็นส่วนหนึ่ง  
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... (ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	คณบดีคณะวิศวกรรมศาสตร์
คณะกรรมการสอบวิทยานิพนธ์	ประธานกรรมการ
..... (รองศาสตราจารย์ ดร.ธนารัตน์ ชลิตาพงศ์)	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
..... (อาจารย์ ดร.พรรณราย ศิริเจริญ)	อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม
..... (ผู้ช่วยศาสตราจารย์ ดร.ยุทธพงษ์ จิรรัชโยธิน)	อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม
..... (รองศาสตราจารย์เอนก ศิริพานิชกร)	กรรมการ
..... (อาจารย์ ดร.พิตติพล คັນธวัชน์)	กรรมการภายนอกมหาวิทยาลัย
..... (ผู้ช่วยศาสตราจารย์ ดร.วีรพล จิรจรัส)	

ณัชพล พันธุ์เมธาฤทธิ์ : การพัฒนาการประเมินความหลวมของสลักเกลียวจากภาพโครงสร้างเหล็กสำเร็จรูปโดยใช้โครงข่ายประสาทเชิงลึก. ( Bolt Looseness Assessment Development of Modular Steel Construction Image using Deep Learning) อ.ที่ปรึกษาหลัก : อ. ดร.พรรณราย ศิริเจริญ, อ.ที่ปรึกษาร่วม : ผศ. ดร.ยุทธพงษ์ จิรรัชโยธิน, รศ.เอนก ศิริพานิชกร

คุณภาพของการเชื่อมต่อแบบสลักเกลียวมีความสำคัญต่อความปลอดภัยและความมั่นใจในการทำงาน โครงสร้างเหล็กแบบสำเร็จรูป งานวิจัยนี้พัฒนาการตรวจหาความหลวมของรอยต่อสลักเกลียวแบบอัตโนมัติโดยใช้เทคนิค Faster R- CNN (faster region-based convolutional neural networks) ร่วมกับเทคนิคเพิ่มความหลากหลายให้กับข้อมูลแบบ Grid Mask ซึ่ง Faster R-CNN มีความสามารถในการตรวจหาวัตถุ และระบุชนิดของวัตถุอย่างแม่นยำ โดยมีการพิจารณาใช้โมเดล backbone ประเภท ResNeXt-101 จะให้ผลลัพธ์ที่ดีที่สุด เนื่องจาก ResNeXt-101 มีการเพิ่มประสิทธิภาพของแบบจำลองโดยการเพิ่มพารามิเตอร์แบบคาร์ดินาลิตี้ เราได้นำความสามารถนี้ไปใช้ในการแยกประเภทระดับของการขันแบบแน่น หลวม และไม่สามารถระบุได้ โดยใช้การวิเคราะห์ทั้งด้วยการแบ่งความหลวมจากการขันสลักเกลียวที่บ่งชี้โดยช่างผู้เชี่ยวชาญ (ชุดข้อมูลที่ 1) และการแบ่งความหลวมโดยใช้มาตรฐานตามขนาดของแรงบิดสำหรับสลักเกลียวแต่ละประเภท (ชุดข้อมูลที่ 2) โดยในงานวิจัยนี้ได้ศึกษาสลักเกลียวสำหรับการแบ่งความหลวมโดยใช้มาตรฐานตามขนาดของแรงบิดแบบ M16 และ M22 โดยเฉพาะอย่างยิ่ง M16 ถูกใช้เป็นหลักในโครงสร้างเหล็กสำเร็จรูป ประกอบกับการเพิ่มความหลากหลายให้กับข้อมูลแบบ Grid Mask และการพลิกภาพทำให้ผลลัพธ์ค่า mAP และความแม่นยำในการตรวจจับความหลวมของสลักเกลียวในกรณีเฉพาะรอยต่อแบบแน่นและหลวม ในชุดข้อมูลแรกเป็น 65.51% และ 95.40% ตามลำดับ ในชุดข้อมูลที่สองสำหรับสลักเกลียวแบบ M16 เป็น 77.50% และ 91.30% ตามลำดับ และสลักเกลียวแบบ M22 เป็น 57.50% และ 84.29% การวิเคราะห์ความสามารถในการตรวจจับที่มุมระดับสายตาต่าง ๆ พบว่าถ้ามีการทำมุมระหว่างกล้องและรอยต่อที่ 0 – 15 องศาจะได้ผลลัพธ์ความแม่นยำสูงสุดเมื่อเทียบกับมุมระหว่างกล้องและรอยต่อที่มากขึ้น โดยจากผลการวิเคราะห์ภาพโดยใช้เทคนิค Grad-CAM พบว่าโมเดลจะพิจารณาความหลวมจากสายตาเช่นเดียวกับมนุษย์ ในชุดข้อมูลแรกและจากความยาวตั้งแต่ปลายเกลียวถึงน็อตในชุดข้อมูลที่ 2

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์  
ปีการศึกษา 2565

ลายมือชื่อนิสิต .....  
ลายมือชื่อ อ.ที่ปรึกษาหลัก .....  
ลายมือชื่อ อ.ที่ปรึกษาร่วม .....  
ลายมือชื่อ อ.ที่ปรึกษาร่วม .....

# # 6370085321 : MAJOR COMPUTER SCIENCE

KEYWORD: Grid Mask, Faster R-CNN, bolt looseness, Object detection, bolted joint, Grad-CAM

Natchapon Panmatharit : Bolt Looseness Assessment Development of Modular Steel Construction Image using Deep Learning. Advisor: PUNNARAI SIRICHAROEN Co-advisor: Yuttapong Jiraraksoyakun, Anek Siripanichgorn

The quality of bolted connections is important for safety and customer confidence of using modular steel structure. This study develops an automated looseness detection of bolted joints using faster region-based convolutional neural networks (Faster R-CNN) with grid mask augmentation. Faster R-CNN has an ability to accurately detect an object and identify the object class, especially with ResNeXt backbone having cardinality module which provide aggregated transformations for improve model efficiency. Our application leverages this ability for distinguishing the looseness levels into tight, loose, and unidentified bolted connections using labels identified by bolted-connection experts (dataset #1) and tightening torque (dataset #2). We studied bolt looseness using tightening torque for M16 and M22 bolts, particularly M16 is a commonly used bolt in modular steel construction. Grid mask and flipping augmentation is used for Faster R-CNN (ResNeXt-101 backbone) with mAP and detection accuracy at 65.51% and 95.40% for the first dataset, respectively, 77.50% and 91.30% for M16-bolt dataset, and 57.50% and 84.29% for M22 dataset. The capturing angle between camera and bolt joint is analyzed and we found that 0-15 degree reveals the most accurate bolt looseness detection. The results are further analyzed and visualized using Grad-CAM and the consideration of the model on bolt looseness is visual like human eyes for the former dataset and the length from the end of the thread to the nut for the latter dataset.

Field of Study: Computer Science

Academic Year: 2022

Student's Signature .....

Advisor's Signature .....

Co-advisor's Signature .....

Co-advisor's Signature .....

## กิตติกรรมประกาศ

วิทยานิพนธ์เรื่องการพัฒนาการประเมินความหลวมของสลักเกลียวจากภาพโครงสร้างเหล็กสำเร็จรูปโดยใช้โครงข่ายประสาทเชิงลึก สำเร็จลุล่วงด้วยดีเนื่องจากผู้วิจัยได้รับความอนุเคราะห์และช่วยเหลืออย่างสูงจากบุคคลหลายท่าน จึงขอขอบคุณไว้ ณ โอกาสนี้

ขอขอบพระคุณ อาจารย์ ดร. พรรณราย ศิริเจริญ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ผู้ช่วยศาสตราจารย์ ดร. ยุทธพงษ์ จิรรักษ์โสภาค และ รองศาสตราจารย์ เอนก ศิริพานิชกร อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม ที่ได้กรุณาให้ คำปรึกษา ชี้แนะแนวทางในการทำการทํางานวิจัย และ ข้อเสนอแนะที่เกี่ยวข้องกับการแก้ไขปรับปรุงงานวิจัย เพื่อให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

ขอขอบพระคุณ รองศาสตราจารย์ ดร. ธนารัตน์ ชลิตาพงศ์ ประธานกรรมการสอบวิทยานิพนธ์ อ. ดร. พิตติพล คັນธวัฒน์ และ ผู้ช่วยศาสตราจารย์ ดร. วีรพล จิรจิต กรรมการสอบวิทยานิพนธ์ที่ให้ความอนุเคราะห์เป็นกรรมการสอบ และให้คำแนะนำ ข้อเสนอแนะและความคิดเห็นที่เป็นประโยชน์ต่อวิทยานิพนธ์

ขอขอบพระคุณ คณาจารย์ และ เจ้าหน้าที่ทุกท่านในภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ที่ได้ให้คำแนะนำและช่วยเหลือในการทำงานวิจัยนี้และอำนวยความสะดวก ในการวิจัย และขอขอบคุณ ตลอดจน พี่ ๆ เพื่อน ๆ และน้อง ๆ ที่เป็นกำลังใจให้แก่ผู้วิจัยเสมอมา

สุดท้ายนี้ขอกราบขอบพระคุณบิดา มารดา รวมถึงผู้มีพระคุณทุกท่านที่อยู่เบื้องหลังและได้ให้กำลังใจ คำปรึกษา และสนับสนุนในด้านต่าง ๆ แก่ผู้ทำวิจัยเสมอมา จนสำเร็จการศึกษา

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

ณัชพล พันธุ์เมธาฤทธิ์

## สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฉ
สารบัญรูปภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์.....	4
1.3 ขอบเขตการวิจัย.....	4
1.4 ประโยชน์ที่ได้รับ.....	4
1.5 ขั้นตอนการดำเนินงานวิทยานิพนธ์.....	5
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	6
2.1 Convolutional Neural Network.....	8
2.2 Faster R-CNN.....	9
2.3 YOLOF.....	10
2.3.1 Backbone.....	10
2.3.2 ตัวเข้ารหัส (Encoder).....	11
2.3.3 ตัวถอดรหัส (Decoder).....	11

2.4 ResNeXt .....	11
2.5 Feature Pyramid Network (FPN).....	12
2.6 GridMask Augmentation .....	13
บทที่ 3 วิธีดำเนินการวิจัย.....	14
3.1 ชุดข้อมูล (Dataset).....	15
3.1.1 ชุดข้อมูลที่ 1.....	15
3.1.2 ชุดข้อมูลที่ 2.....	16
3.2 Image augmentation.....	18
3.3 แบบจำลอง (Model).....	19
3.3.1 Faster R-CNN .....	19
3.3.2 YOLOF.....	19
3.4 การวัดผล (Evaluation) .....	20
บทที่ 4 การทดลอง และผลการทดลอง.....	21
4.1 ผลการทดสอบในข้อมูลชุดที่ 1.....	21
4.1.1 ผลการทดสอบการเปรียบเทียบแบบจำลอง .....	21
4.1.2 ผลการทดสอบความแม่นยำจากการใช้ Image Augmentation .....	22
4.1.3 ผลลัพธ์การวิเคราะห์ .....	22
4.1.3.1 วิเคราะห์ความผิดพลาดการตรวจจับ.....	22
4.1.3.2 วิเคราะห์ความแม่นยำในการจำแนกประเภท .....	25
4.2 ผลการทดสอบในข้อมูลชุดที่ 2.....	26
4.2.1 สลักเกลียว M16.....	26
4.2.1.1 ผลการทดสอบการเปรียบเทียบแบบจำลอง .....	26
4.2.1.2 ผลลัพธ์การวิเคราะห์.....	27
4.2.1.2.1 วิเคราะห์ความแม่นยำการจำแนกประเภทโดยรวม .....	27



4.2.1.2.2 วิเคราะห์ความผิดพลาดการจำแนกประเภทเชิงมุม .....	29
4.2.1.2.3 การปรับลดค่าผลลบเทียมของจำแนกประเภทแบบหลวม.....	31
4.2.2 สลักเกลียว M22.....	33
4.3 การแสดงผลจากจุดที่แบบจำลองสนใจ.....	35
บทที่ 5 สรุปผลการทดลอง และข้อเสนอแนะ .....	38
บรรณานุกรม .....	40
ประวัติผู้เขียน .....	43



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

## สารบัญตาราง

	หน้า
ตารางที่ 1 แผนภูมิแกนต์แสดงขั้นตอนการดำเนินงาน.....	5
ตารางที่ 2 สรุปรงานวิจัยก่อนหน้า .....	7
ตารางที่ 3 ตารางเปรียบเทียบแบบจำลองที่ใช้และผลลัพธ์ของข้อมูลชุดที่ 1 .....	21
ตารางที่ 4 ค่าความแม่นยำโดยแตกแต่ละประเภท เปรียบเทียบระหว่างก่อนและหลังเพิ่มจำนวนข้อมูล.....	22
ตารางที่ 5 ตารางวิเคราะห์ความผิดพลาดในการตรวจจับของ Faster R-CNN ด้วย ResNet-50 .....	24
ตารางที่ 6 ตารางวิเคราะห์ความผิดพลาดในการตรวจจับของ Faster R-CNN ด้วย ResNet-101 .....	24
ตารางที่ 7 ตารางวิเคราะห์ความผิดพลาดในการตรวจจับของ YOLOF .....	25
ตารางที่ 8 ตาราง Confusion matrix ของ Faster R-CNN ด้วย ResNeXt-101 .....	25
ตารางที่ 9 ตารางเปรียบเทียบแบบจำลองที่ใช้ และผลลัพธ์ที่เพิ่มข้อมูลทั้งหมดแล้ว (M16).....	26
ตารางที่ 10 ตาราง Confusion matrix ของ Faster R-CNN ด้วย ResNet-50 (M16) .....	27
ตารางที่ 11 ตาราง Confusion matrix ของ Faster R-CNN ด้วย ResNeXt-101 (M16) .....	28
ตารางที่ 12 ตาราง Confusion matrix ของ YOLOF (M16) .....	28
ตารางที่ 13 ตาราง Confusion matrix ที่มุม 0-15 องศา .....	30
ตารางที่ 14 ตาราง Confusion matrix ที่มุม 16-30 องศา.....	30
ตารางที่ 15 ตาราง Confusion matrix ที่มุม 31-45 องศา.....	31
ตารางที่ 16 ตาราง Confusion matrix ที่ปรับลดค่าผลลบเทียมของจำแนกประเภทแบบหลวมแล้ว .....	32
ตารางที่ 17 ตารางเปรียบเทียบผลลัพธ์การทำนายแบ่งตามวิธีการตัดแยกประเภท (M22).....	34
ตารางที่ 18 ตาราง Confusion matrix แบบจำลองที่ใช้วิธีการตัดแยกตามแรงบิดมาตรฐาน (M22) .....	34

ตารางที่ 19 ตาราง Confusion matrix แบบจำลองที่ใช้วิธีการคัดแยกแบบประเภทชั้นแน่น (M22)

.....35



## สารบัญรูปภาพ

	หน้า
รูปที่ 1 อาคารหลักสำเร็จรูป .....	2
รูปที่ 2 รอยต่อที่ยังไม่ถูกตรวจสอบ .....	3
รูปที่ 3 การเชื่อมต่อประเภทแรงเสียดทาน.....	3
รูปที่ 4 การเชื่อมต่อประเภทการค้ำ.....	3
รูปที่ 5 สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน.....	8
รูปที่ 6 สถาปัตยกรรม Faster R-CNN.....	9
รูปที่ 7 สถาปัตยกรรม YOLOF .....	10
รูปที่ 8 การใช้ ResNet101 กับ Feature Pyramid Network.....	10
รูปที่ 9 สถาปัตยกรรม ResNeXt.....	12
รูปที่ 10 Feature Pyramid Network.....	12
รูปที่ 11 ตัวอย่าง GridMask.....	13
รูปที่ 12 ส่วนประกอบ GridMask.....	13
รูปที่ 13 แผนผังลำดับงานของการตรวจจับคุณภาพรอยต่อของสลักเกลียวและน็อตโดยใช้การเรียนรู้เชิงลึกที่งานวิจัยนี้นำเสนอ .....	14
รูปที่ 14 ดูแล้วแน่น .....	15
รูปที่ 15 ไม่แน่ใจ .....	15
รูปที่ 16 ดูแล้วหลวม .....	15
รูปที่ 17 การขันสลักเกลียว M16 ที่ระดับแรงบิดต่าง ๆ.....	16
รูปที่ 18 การขันสลักเกลียว M22 ที่ระดับแรงบิดต่าง ๆ.....	17
รูปที่ 19 การ Augmentation ด้วย flip และ gridmask.....	18
รูปที่ 20 การใช้ GridMask ในชุดข้อมูล .....	18

รูปที่ 21 รูปตัวอย่าง ImageNet.....19

รูปที่ 22 Exact match ฝั่งซ้ายผลเฉลย ฝั่งขวาผลทำนาย.....23

รูปที่ 23 Falsely classified ฝั่งซ้ายผลเฉลย ฝั่งขวาผลทำนาย.....23

รูปที่ 24 Falsely localized ฝั่งซ้ายผลเฉลย ฝั่งขวาผลทำนาย.....23

รูปที่ 25 Falsely localized and falsely classified ฝั่งซ้ายผลเฉลย ฝั่งขวาผลทำนาย.....24

รูปที่ 26 วิธีคัดแยกสลักเกลียว M16 แบบประเภทขั้นแน่น .....26

รูปที่ 27 ตัวอย่างภาพถ่ายในมุมต่าง ๆ (ก.) 0-15 องศา (ข.) 16-30 องศา (ค.) 31-45 องศา .....29

รูปที่ 28 ROC ระหว่างการจำแนกประเภทขั้นแน่น (Positive) และหลวม (Negative).....32

รูปที่ 29 วิธีคัดแยกสลักเกลียว M22 ตามพิกัดแรงบิดมาตรฐาน.....33

รูปที่ 30 วิธีคัดแยกสลักเกลียว M22 แบบประเภทขั้นแน่น .....33

รูปที่ 31 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 1 นี้อตแนวดิ่ง .....36

รูปที่ 32 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 2 นี้อตแนวดิ่ง .....36

รูปที่ 33 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 1 นี้อตแนวระดับ .....36

รูปที่ 34 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 2 นี้อตแนวระดับ .....37

# บทที่ 1

## บทนำ

### 1.1 ที่มาและความสำคัญ

ในปัจจุบันการก่อสร้างมีบทบาทสำคัญในการเติบโตทางเศรษฐกิจของประเทศ ในบรรดา รูปแบบต่าง ๆ ของการก่อสร้าง โครงสร้างเหล็กสำเร็จรูป (Modular Steel Construction) มีข้อดี หลายประการไม่ว่าจะเป็นความรวดเร็วในการประกอบและติดตั้ง คุณภาพของวัสดุ รวมไปถึงการ สอดคล้องกับหลักการพื้นฐานของระบบเศรษฐกิจหมุนเวียน (Circular Economy) จากการนำวัสดุ ก่อสร้างมาใช้ซ้ำได้ วัสดุมีน้ำหนักเบาเหมาะสำหรับทั้งอาคารที่พักอาศัยและที่ไม่ใช่ที่อยู่อาศัย [1-3]

การก่อสร้างด้วยระบบโครงสร้างเหล็กสำเร็จรูป เป็นระบบการผลิตที่ใช้ประโยชน์จากการ ผลิตและประกอบโครงสร้างในโรงงาน เพื่อการก่อสร้างอาคารเฉพาะที่อยู่อาศัยแนวราบ ซึ่งการ ก่อสร้างในรูปแบบนี้จะกล่าวถึงรูปแบบวิธีการก่อสร้างที่มีการใช้โครงสร้างรูปแบบกล่อง (module) แบบเดี่ยวหรือนำมาประกอบเข้าด้วยกันจนเป็นโครงสร้างขนาดใหญ่ที่พร้อมใช้งานหลังจากประกอบ ติดตั้งเสร็จ ดังรูปที่ 1 โดยหากเปรียบเทียบการก่อสร้างด้วยระบบโครงสร้างสำเร็จรูป (Modular Steel Construction Method) กับการก่อสร้างแบบเดิม (Conventional Construction Method) พบว่า การก่อสร้างด้วยระบบโครงสร้างเหล็กสำเร็จรูปจะมีข้อดีที่มากกว่า ทั้งด้านสิ่งแวดล้อม ที่ลด กระบวนการสำหรับการประกอบที่หน้างาน สามารถนำวัสดุเหลือใช้ เช่น เศษเหล็ก (scrap) กลับมา ใช้งานได้ และด้านต้นทุนของงานก่อสร้างที่ลดขั้นตอนของการก่อสร้างลง หลีกเลี่ยงสภาพอากาศ ที่ไม่สามารถควบคุมได้และอาจทำให้เกิดความเสียหายต่อโครงสร้าง เวลาในการก่อสร้างที่รวดเร็วขึ้น เนื่องจากการประกอบโครงสร้างในโรงงานสามารถทำคู่ขนานกับการเตรียมพื้นที่หน้างาน



รูปที่ 1 อาคารเหล็กสำเร็จรูป

[<https://www.theuknewspaper.co.uk/wp-content/uploads/2019/12/Modular-Building-System-1.png>]


ในปัจจุบัน มาตรฐานการตรวจสอบคุณภาพของงานโครงสร้างเหล็กต้องอาศัยเครื่องมือเฉพาะทาง ความชำนาญในการตรวจสอบและการแปลผล หรืออาจจำเป็นต้องมีการส่งชิ้นงานเข้าห้องทดสอบ ด้วยแนวคิดการตรวจสอบคุณภาพโดยใช้เทคโนโลยีการประมวลผลภาพ โดยไม่ต้องมีผู้เชี่ยวชาญในการใช้ หรืออุปกรณ์เสริมที่นำเสนอ จะช่วยในการตรวจสอบเบื้องต้นที่เข้าถึงผู้ใช้งาน และลดความจำเป็นในการส่งชิ้นงานกลับเพื่อตรวจสอบตามมาตรฐานทุกครั้ง

ปัจจุบันรอยต่อโครงสร้างเหล็กสำเร็จรูปใช้สลักเกลียวในการเชื่อมต่อ (Bolted Connection) ตัวอย่างดังรูปที่ 2 ซึ่งความเสียหายของสลักเกลียว (bolt) อาจส่งผลเสียต่อความปลอดภัยและประสิทธิภาพของโครงสร้างได้ โดยเฉพาะความหลวมของรอยต่อสลักเกลียว ที่เป็นปัจจัยสำคัญในการยึดชิ้นงานเข้าด้วยกัน ปัจจุบันการติดตั้งสลักเกลียวแบ่งออกตามการใช้งานเป็น 3 ประเภท คือ ประเภทขันแน่น (Snug-tightened) สัญลักษณ์ S เป็นสลักเกลียวการใช้ประแจขันแน่น พอตีมือ ประเภทแรงเสียดทาน (Friction type) สัญลักษณ์ TF เป็นสลักเกลียวที่เชื่อมชิ้นงานโดยด้านทานแรงตั้งฉากมากกระทำ เพื่อป้องกันการไหลของชิ้นงาน ดังรูปที่ 3 ประเภทการค้ำ (Bearing type) สัญลักษณ์ TB เป็นสลักเกลียวอยู่ในแนวแรงเฉือน เพื่อค้ำชิ้นงาน เพราะแรงเสียดทานค่อนข้างมีผลน้อยกับการเชื่อมต่อ ดังรูปที่ 4 ซึ่งการติดตั้งประเภทแรงเสียดทานและประเภทการค้ำโดยทั่วไป จะใช้ในงานโครงสร้างขนาดใหญ่ ต้องมีมาตรฐานแรงบิด (torque) ซึ่งเป็นมาตรฐานที่ใช้ในการวัดความแน่นหรือหลวมของสลักเกลียว โดยจะใช้เครื่องมือวัดเพื่ออ้างอิงแรงบิดให้ถึงพิกัดที่กำหนดไว้ตามมาตรฐาน โดยการนิยามว่าแน่นจะใช้ 70% ของพิกัดแรงบิดทำลาย (breaking torque) ถ้าต่ำกว่านี้จะถือว่าหลวม และไม่ผ่านเกณฑ์ที่กำหนด [4] ในส่วนของงานก่อสร้างขนาดเล็ก หรือโครงสร้าง

แบบเหล็กสำเร็จรูปนั้นโดยทั่วไปนิยมใช้การติดตั้งประเภทขันแน่น ที่ไม่ได้กำหนดพิกัดแรงบิดไว้ แต่อ้างอิงจากการบิดให้แน่นจากการขันด้วยมือ




รูปที่ 2 รอยต่อที่ยังไม่ถูกตรวจสอบ



รูปที่ 3 การเชื่อมต่อประเภทแรงเสียดทาน

[<http://fgg-web.fgg.uni-lj.si/~pmoze/ESDEP/master/wg11/l0320.htm>]

CHULALONGKORN UNIVERSITY



รูปที่ 4 การเชื่อมต่อประเภทการค้ำ

[[https://www.steelconstruction.info/images/thumb/a/ae/R20\\_Fig1.png/500px-R20\\_Fig1.png](https://www.steelconstruction.info/images/thumb/a/ae/R20_Fig1.png/500px-R20_Fig1.png)]



ปัจจุบันงานวิจัยก่อนหน้าได้มีการใช้การเรียนรู้ของเครื่องเพื่อศึกษาปัญหาความเสียหายในรูปแบบของการคล้ายคลึงกัน เพื่อแก้ไขปัญหาเหล่านี้ จึงทำให้มีการสร้างงานวิจัยออกมามากมาย เช่น การวัดความกลมด้วยแรงสัมผัส การใช้ระบบวิทัศน์ (Vision System) เพื่อตรวจจับสลักเกลียวที่คลายออก โดยงานวิจัยนี้จึงได้นำเสนอการตรวจสอบรอยต่อโครงสร้างเหล็กสำเร็จรูป โดยใช้ระบบวิทัศน์เพื่อเป็นต้นแบบให้ใช้งานเพื่อยืนยันคุณภาพของรอยต่อสลักเกลียวประเภทชั้นแน่น (S) มีเป้าหมายเพื่อพัฒนาระบบตรวจสอบคุณภาพโครงสร้างเหล็กสำเร็จรูปจากภาพถ่ายโครงสร้างของอาคารตัวอย่างประเภทต่าง ๆ ด้วยการมุ่งเน้นไปที่การประเมินคุณภาพรอยต่อของโครงสร้างอาคารตัวอย่าง จากการถ่ายภาพด้วยอุปกรณ์ที่ไม่ซับซ้อน โดยจะลดความต้องการของความรู้ดั้งเดิมที่ใช้งานกับภาพ เช่น มุมที่ถ่ายได้ การถ่ายจากชิ้นงานที่ถูกติดตั้งเรียบร้อยแล้ว และภาพที่ใช้ไม่จำเป็นต้องถ่ายให้เห็นหัวสลักเกลียวทั้งหมด

งานวิจัยนี้จึงมีบทบาทสำคัญในการส่งเสริมให้เกิด ความน่าเชื่อถือในการใช้งานและเพิ่มความมั่นใจให้กับผู้มีส่วนได้ส่วนเสียต่าง ๆ ตลอดจนยกระดับการใช้งานการก่อสร้างอาคารเหล็กสำเร็จรูป อีกทั้งยังช่วยลดกระบวนการเกิดของเสีย เกิดการหมุนเวียน วัสดุที่ได้คุณภาพแพร่หลายในวงกว้างมากขึ้นและทำให้กระบวนการใช้ทรัพยากรมีประสิทธิภาพ สูงสุดรวมทั้งอายุการใช้งาน ในเชิงของระบบเศรษฐกิจหมุนเวียนด้วย

## 1.2 วัตถุประสงค์

เพื่อพัฒนาการประเมินความกลมของสลักเกลียวจากภาพโครงสร้างเหล็กสำเร็จรูปโดยใช้โครงข่ายประสาทเชิงลึก โดยใช้ภาพถ่ายจากกล้องที่ใช้งานทั่วไป

## 1.3 ขอบเขตการวิจัย

1. แบบจำลองสามารถทำนายได้เฉพาะสลักเกลียวประเภทชั้นแน่นเท่านั้น
2. ภาพที่ใช้เป็นภาพถ่ายจากโทรศัพท์มือถือ ซึ่งความละเอียดไม่ต่ำกว่า 720 x 1600 พิกเซล

## 1.4 ประโยชน์ที่ได้รับ

ผู้ใช้งานสามารถใช้ภาพถ่ายจากกล้องที่ใช้งานทั่วไปวัดคุณภาพรอยต่อสลักเกลียวและน็อตได้ในขั้นต้น ทำให้ช่วยในการตรวจสอบคุณภาพเบื้องต้นและลดความจำเป็นที่จะต้องส่งชิ้นงานกลับเพื่อตรวจสอบตามมาตรฐานทุกครั้ง

### 1.5 ขั้นตอนการดำเนินงานวิทยานิพนธ์

ตารางที่ 1 แผนภูมิแกนต์แสดงขั้นตอนการดำเนินงาน

การดำเนินงาน	ปี 2564			ปี 2565											
	10	11	12	1	2	3	4	5	6	7	8	9	10	11	12
ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง															
เก็บข้อมูลชุดที่ 1															
พัฒนาและเพิ่มประสิทธิภาพแบบจำลอง ของชุดที่ 1															
เก็บข้อมูลชุดที่ 2															
เขียนบทความเพื่อตีพิมพ์ผลงานทางวิชาการ															
พัฒนาและเพิ่มประสิทธิภาพแบบจำลอง ของชุดที่ 2															
สรุปผลและเรียบเรียงวิทยานิพนธ์															
สอบหัวข้อวิทยานิพนธ์															

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในการวิจัยที่ผ่านมา การพัฒนาอัลกอริทึมการเรียนรู้เชิงลึก (deep learning) ได้มีการเติบโตอย่างรวดเร็วเพื่อทำความเข้าใจและจำแนกลักษณะของวัตถุได้อย่างแม่นยำ การเรียนรู้เชิงลึกมีการใช้กันอย่างแพร่หลายในหลากหลายสาขาวิชา เช่น การแพทย์ [5] นักช็อตโนมิติ [6] การแปลวรรณกรรม [7] รวมถึงการใช้การตรวจสอบการก่อสร้าง เช่น การตรวจจับข้อบกพร่องในการเชื่อม [8] การตรวจจับการคลายของสลักเกลียว [9] ซึ่งองค์ประกอบที่สำคัญที่สุดอย่างหนึ่งในงานโครงสร้างคือการเชื่อมต่อโดยใช้สลักเกลียว ปัญหาสลักเกลียวหลวมอาจทำให้ส่งผลเสียต่อภัยพิบัติหรือการบาดเจ็บตามมาได้ จึงทำให้มีการสร้างงานวิจัยออกมามากมายเช่น งานวิจัยก่อนหน้านี้ได้มีการใช้แรงสั่นสะเทือนผ่าน การตั้งค่าเครื่องเขย่าเพื่อจับการสั่นสะเทือนของแผ่นเชื่อมต่อแบบสลัก เมื่อแผ่นเชื่อมต่อสลักเกลียวสั่นแล้ว กล้องจะจับภาพลำดับภาพ ฟังก์ชัน autocorrelation เฉลี่ยของสัญญาณใช้เพื่อระบุดัชนีความหลวมของการเชื่อมต่อด้วยสลัก [10] นอกจากนี้ มีงานวิจัยเป็นจำนวนมากใช้ระบบวิทัศน์ (Vision System) เพื่อตรวจจับสลักเกลียวที่คลายออก ตัวอย่างเช่น การแปลง Hough ใช้เพื่อกำหนดตำแหน่งของขอบสลักเกลียวและความยาวของปลายสลักเกลียวที่ยื่นออกมาจากฐานหรือน็อต จากนั้น ใช้ Support Vector Machines (SVM) เพื่อจำแนกข้อต่อแบบเกลียวออกเป็นสองประเภทคือ แน่นหรือหลวม อย่างไรก็ตาม ผู้ใช้จำเป็นต้องถ่ายภาพภายใต้สภาวะควบคุม โดยจะต้องมองเห็นหัวสลักได้ชัดเจน ผลลัพธ์ยังสามารถเปลี่ยนแปลงได้ง่ายต่อมุมมองที่แตกต่างกัน [11] Zhang Y. และคณะ [12] ได้ปรับใช้ Faster R-CNN เพื่อระบุข้อต่อสลักเกลียวแนวตั้งอย่างแม่นยำในการแยกประเภทโดยแน่นหรือหลวม Pham H.C และคณะ [13] ใช้การตรวจจับวัตถุเพื่อตรวจจับข้อต่อสลักและระบุการคลายสลักตามมุมการหมุนของหัวสลักเกลียวโดยใช้การแปลง Hough โดยสรุปดังตาราง

ที่ 2


ตารางที่ 2 สรุปงานวิจัยก่อนหน้า

งานวิจัย	วิธีที่ใช้	ผลลัพธ์	ข้อจำกัด
Detection of Bolt Looseness Based on Average Autocorrelation Function (2020) [10]	ใช้เครื่องสัน สันชิ้นงานที่ต่อด้วยสลักเกลียวที่หลวมและไม่หลวมเพื่อเปรียบเทียบ แล้ววัดการขยับด้วยกล้อง	สามารถวัดสลักเกลียวที่หลวม เมื่อแรงบิดสลักเกลียวถูกคลายจากแรงบิดพิกัดที่ 40%	ชิ้นงานที่ต่อด้วยสลักเกลียว ต้องสามารถขยับได้ด้วยการสัน จึงจะสามารถใช้งานได้
Bolt-Loosening Monitoring Framework Using an Image-Based Deep Learning and Graphical Model (2020) [13]	R-CNN ในการตรวจจับสลักเกลียวแล้วใช้ Hough Transform ในการหามุมที่เปลี่ยนไปเพื่อทำนายความหลวม	มีความผิดพลาด $0.45^\circ \pm 0.4^\circ$ จากมุมเอียง $0^\circ$ และ $1.25^\circ \pm 0.8^\circ$ จากมุมเอียง $40^\circ$	ภาพที่ใช้จำเป็นต้องเป็นภาพที่คมชัด (ไม่น้อยกว่า 22900 pixels) ต้องใช้ภาพจากความรู้ตั้งต้น เช่น การกำหนดจุดเริ่มต้นของสลักเกลียว
Vision-based detection of loosened bolts using the Hough transform and support vector machine (2016) [11]	Hough Transform ในการหา key feature หาความยาวสลักเกลียวที่ยื่นออกมาจากชิ้นงานในแนวตั้ง แล้วทำนายด้วย LSVM	สามารถวัดได้แม่นยำสูงถึง 95.45%	ภาพที่ใช้จำเป็นต้องคมและเห็นหัวของสลักเกลียวอย่างชัดเจน และวิธีประมวลผลและการแยกคุณลักษณะที่เสนอจะใช้ได้เฉพาะกับความรู้เดิมเท่านั้น เช่น แผนผังการต่อสลักเกลียว
Autonomous bolt loosening detection using deep learning (2020) [12]	Faster R-CNN ในการตรวจจับและทำนายความหลวมจากภาพสลักเกลียว	ความแม่นยำในการตรวจจับสูงถึง 95.03%	การตรวจจับแม่นยำก็ต่อเมื่อภาพถ่ายสลักเกลียว เอียงไม่เกิน 45 องศา และวิธีประมวลผลและการแยกคุณลักษณะที่เสนอจะใช้ได้เฉพาะกับความรู้เดิมเท่านั้น เช่น แผนผังการต่อสลักเกลียว

งานวิจัยนี้ได้ใช้ Faster R-CNN ที่นำ Convolutional Neural Network มาสกัดหาคุณลักษณะสำคัญจากภาพสลักเกลียว แบ่งออกเป็น 3 หมวดหมู่ ได้แก่ การเชื่อมต่อแบบแน่น หลวม และไม่แน่น โดยปรับเปลี่ยนโครงสร้างภายในของแบบจำลอง ทำการเพิ่มข้อมูล (Augmentation) และนำไปเปรียบเทียบกับแบบจำลองอื่น ๆ ซึ่งทฤษฎีที่ใช้ประกอบสิ่งที่กล่าวมาข้างต้น

## 2.1 Convolutional Neural Network

Convolutional Neural Network (CNN) เป็นโครงข่ายประสาทประภทหนึ่งที่มีความสามารถในการแยกคุณลักษณะเฉพาะออกจากข้อมูลภาพ สถาปัตยกรรมของ CNN แบ่งชั้น (Layer) ออกเป็นสามประเภท ได้แก่ ชั้นคอนโวลูชัน (Convolution layer) ชั้น pooling และชั้นที่เชื่อมต่ออย่างสมบูรณ์ (fully-connected) ดังตัวอย่างรูปที่ 5 ชั้นคอนโวลูชัน มีหน้าที่ในการจดจำและแยกคุณลักษณะในพิกเซลของรูปภาพด้วยน้ำหนัก (weight) และอคติ (bias) ที่เรียนรู้ได้ ชั้น pooling มีหน้าที่ในการรวมคุณลักษณะที่นำเสนอในพื้นที่ของแผนผังคุณลักษณะที่สร้างโดยชั้นคอนโวลูชัน เพื่อลดจำนวนพารามิเตอร์ที่ต้องสอนและต้นทุนในการคำนวณ ชั้นที่เชื่อมต่ออย่างสมบูรณ์มีหน้าที่ในการเรียนรู้การรวมกันของชั้นก่อนหน้าและเชื่อมต่อพารามิเตอร์สำหรับการทำนาย



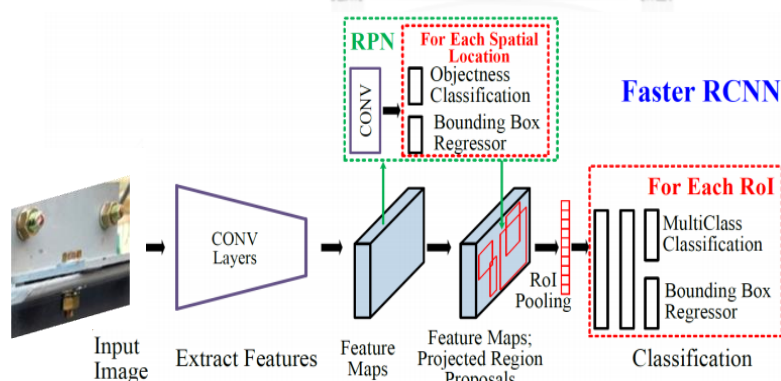
รูปที่ 5 สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน

[<https://saturncloud.io/blog/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way/>]

## 2.2 Faster R-CNN

การตรวจจับวัตถุใช้เทคนิคการเรียนรู้ด้วยเครื่อง ซึ่งทำการจำแนกและแปลวัตถุในภาพหรือวิดีโอ ก่อนหน้านี้ วิธีการแยกคุณลักษณะ เช่น Scale-Invariant Feature Transform (SIFT) [14] และ Histogram of Oriented Gradients (HOG) [15] Convolutional Neural Network (CNNs) ได้ถูกพัฒนาสำหรับการจำแนกประเภทภาพและการตรวจจับวัตถุ ในงานของเรา Region-Convolutional Neural Network (R-CNN) ใช้สำหรับแยกความแตกต่างระหว่างคุณภาพของการเชื่อมต่อแบบสลับเกลียว การตรวจจับวัตถุตามการเรียนรู้เชิงลึกแบ่งออกเป็น 2 ประเภท ได้แก่ เครือข่ายชั้นตอนเดียวและเครือข่ายสองชั้นตอน Faster R-CNN [16] ซึ่งเป็นเครือข่ายแบบสองชั้นตอนต้องมีการนำเสนอตำแหน่งของพื้นที่ ที่น่าจะเป็นวัตถุที่ต้องการในขั้นต้นเพื่อรับกรอบที่อาจมีวัตถุและทำการจัดประเภทวัตถุภายในตำแหน่งพื้นที่ที่น่าเสนอจากภายในโมเดล Faster R-CNN มีโครงข่ายการนำเสนอพื้นที่ (Region Proposal Network หรือ RPN) สำหรับสร้างตำแหน่งพื้นที่ที่น่าเสนอและเครือข่ายที่ใช้ตำแหน่งพื้นที่ที่น่าเสนอเหล่านี้เพื่อตรวจจับวัตถุ RPN ใช้การคำนวณร่วมกับเครือข่ายการตรวจจับวัตถุ RPN จัดอันดับกล่องสมอ (Anchor Box) และเสนอกรอบที่น่าจะเป็นวัตถุเป้าหมายมากที่สุด

เครือข่ายข้อเสนอภูมิภาค (RPN) กำหนดว่าพื้นที่ใดมีแนวโน้มที่จะมีวัตถุหรือเป็นเพียงส่วนของพื้นหลัง จากนั้น RPN จะแสดงผลพื้นที่ที่น่าจะเป็นวัตถุและค่าความมั่นใจสำหรับการเลือกพื้นที่ที่น่าจะเป็นวัตถุ โดยแบ่งจากเกณฑ์ค่าความมั่นใจ (confidence threshold) ที่กำหนด




รูปที่ 6 สถาปัตยกรรม Faster R-CNN

[[https://miro.medium.com/max/1400/1\\*IZi\\_Jiv9l0cx4u2jji\\_4vw.png](https://miro.medium.com/max/1400/1*IZi_Jiv9l0cx4u2jji_4vw.png)]

## 2.3 YOLOF

YOLOF [17] ใช้เฟรมเวิร์คที่ตรงไปตรงมาและมีประสิทธิภาพพร้อมพีเจอร์ระดับเดียว (single level feature) สามารถแบ่งออกเป็นสามส่วน ได้แก่ Backbone, Encoder และ Decoder ดังแสดงในรูปที่ 7

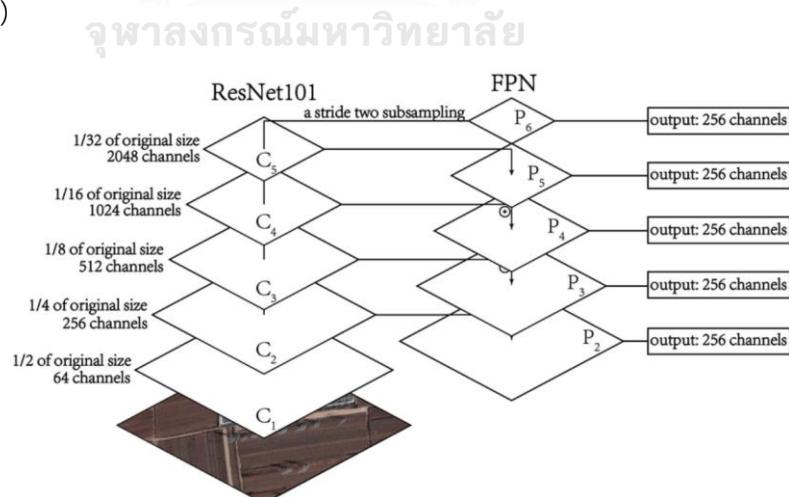


รูปที่ 7 สถาปัตยกรรม YOLOF

[<https://raw.githubusercontent.com/megvii-model/YOLOF/master/images/yolof.png>]

### 2.3.1 Backbone

YOLOF ใช้ชุด ResNet และ ResNeXt ที่ได้รับการฝึกฝนล่วงหน้าบน ImageNet เป็นแกนหลักที่จะแสดงผลแผนที่คุณลักษณะแบบ C5 ที่มีช่องสัญญาณ 2048 ช่องและอัตราการลดขนาดที่ 32 ดังแสดงในรูปที่ 8 เพื่อทำการเปรียบเทียบกับโมเดลตรวจจับอื่นๆ ผู้พัฒนา YOLOF ได้ตั้งค่าชั้น batch norm ไว้เพื่อลดการรบกวน (noise) จากพารามิเตอร์ เมื่อนำไปปรับแต่งให้เข้ากับชุดข้อมูลใหม่ (fine tuning)



รูปที่ 8 การใช้ ResNet101 กับ Feature Pyramid Network

[[https://www.researchgate.net/figure/Structure-of-ResNet101-42-FPN-43-The-left-part-shows-the-structure-of-ResNet101\\_fig2\\_342044874](https://www.researchgate.net/figure/Structure-of-ResNet101-42-FPN-43-The-left-part-shows-the-structure-of-ResNet101_fig2_342044874)]

### 2.3.2 ตัวเข้ารหัส (Encoder)

ตัวเข้ารหัส YOLOF ถูกพัฒนาจากหลักการของโครงข่ายพีระมิดแบบพีระมิด (Feature Pyramid Network หรือ FPN) ที่เป็นการเชื่อมต่อเส้นทางจากล่างขึ้นบนและบนลงล่าง โดย YOLOF ได้เพิ่มชั้นคอนโวลูชันที่มี kernel ขนาด  $1 \times 1$  และ  $3 \times 3$  ต่อจาก backbone ซึ่งจะสร้างแผนผังคุณลักษณะที่มีช่องสัญญาณ 512 ช่อง นอกจากนี้ บล็อกที่เหลือจะถูกเพิ่มเพื่อให้คุณสมบัติเอาต์พุตของตัวเข้ารหัสครอบคลุมวัตถุในขนาดต่างๆ

บล็อกที่เหลือเหล่านี้ประกอบด้วย 3 ชั้นคอนโวลูชัน ได้แก่ ชั้นคอนโวลูชัน  $1 \times 1$  ที่มีอัตราการลดช่อง 4 จากนั้นชั้นคอนโวลูชัน  $3 \times 3$  เพื่อขยายภาพให้กว้างขึ้น และสุดท้าย ชั้นคอนโวลูชัน  $1 \times 1$  ถูกใช้เพื่อคืนผังคุณลักษณะ


### 2.3.3 ตัวถอดรหัส (Decoder)

ตัวถอดรหัสใช้การออกแบบ RetinaNet [18] ที่ปรับเปลี่ยนเล็กน้อยซึ่งประกอบด้วยส่วนหัวที่ทำหน้าที่เฉพาะมีการต่อแบบขนานกันแยกออกเป็น 2 หัว ได้แก่ หัวการจำแนก (classification head) มีไว้เพื่อจำแนกประเภทของวัตถุ และหัวการถดถอย (regression head) มีไว้เพื่อบอกถึงตำแหน่งกรอบของวัตถุ โดยที่ทั้งสองหัวมีจำนวนชั้นที่ต่างกัน หัวการถดถอยมีสี่ชั้นคอนโวลูชัน ตามด้วยชั้น batch normalization และชั้น ReLU ในขณะที่ส่วนหัวการจำแนกมีเพียงสองชั้น สุดท้ายเชื่อมต่อฝั่งการถดถอยเข้ากับฝั่งการจำแนก

## 2.4 ResNeXt

ResNeXt [19] เป็นตัวแยกคุณลักษณะซึ่งขยายจาก Residual network (ResNet) โดยใช้วิธีการแยก-แปลง-รวม อินพุตในเครือข่ายถูกแบ่งออกเป็นหลายบล็อกแล้วรวมเข้าด้วยกันเพื่อเพิ่มความถูกต้องของแบบจำลองและมีการใช้พารามิเตอร์ ร่วมกับจำนวนเส้นทางในเครือข่ายที่ถูกแบ่งออกภายในบล็อก ResNeXt เรียกว่าคาร์ดินาลิตี้ (Cardinality) ซึ่งหมายถึงขนาดของชุดของการแปลง คาร์ดินาลิตี้มีความสำคัญในการลดข้อผิดพลาดในการตรวจจับวัตถุ






รูปที่ 9 สถาปัตยกรรม ResNeXt

[[https://production-media.paperswithcode.com/methods/Screen\\_Shot\\_2020-06-06\\_at\\_4.32.52\\_PM.png](https://production-media.paperswithcode.com/methods/Screen_Shot_2020-06-06_at_4.32.52_PM.png)]

## 2.5 Feature Pyramid Network (FPN)

Feature Pyramid Network (FPN) [20] ประกอบด้วยเส้นทางจากล่างขึ้นบนและบนลงล่าง ส่วนจากล่างขึ้นบนคือการคำนวณแบบ feedforward ของ CNN ซึ่งคำนวณแผนผังคุณลักษณะ (feature map) แบบลำดับชั้นในระดับหลายขนาด โดยมีการเชื่อมต่อระหว่างผัง เพื่อรักษาความถูกต้องจากการขยายขนาดของชั้น




รูปที่ 10 Feature Pyramid Network

[[https://production-media.paperswithcode.com/methods/new\\_teaser\\_TMZID2J.jpg](https://production-media.paperswithcode.com/methods/new_teaser_TMZID2J.jpg)]

## 2.6 GridMask Augmentation

GridMask Augmentation [21] คือการเพิ่มจำนวนและความหลากหลายของข้อมูลด้วยการปิดภาพบางส่วนให้เป็นสีดำ เพื่อให้แบบจำลองหาจุดสนใจในภาพได้ดีขึ้น โดยได้พัฒนามาจากเทคนิคซ่อนหา หรือ Hide-and-Seek (HaS) [22] ที่แบ่งภาพออกเป็นสี่เหลี่ยมเล็ก ๆ อย่างสม่ำเสมอและลบออกโดยใช้การลบออกแบบโครงสร้างตามพื้นที่สี่เหลี่ยมอย่างเท่าเทียมกัน สามารถควบคุมความหนาแน่นและขนาดของพื้นที่ที่ถูกลบเพื่อโอกาสที่สูงกว่าในการเพิ่มความแม่นยำที่ดีกว่า HaS ตัวอย่างการเพิ่มข้อมูลด้วย GridMask แสดงในรูปที่ 12



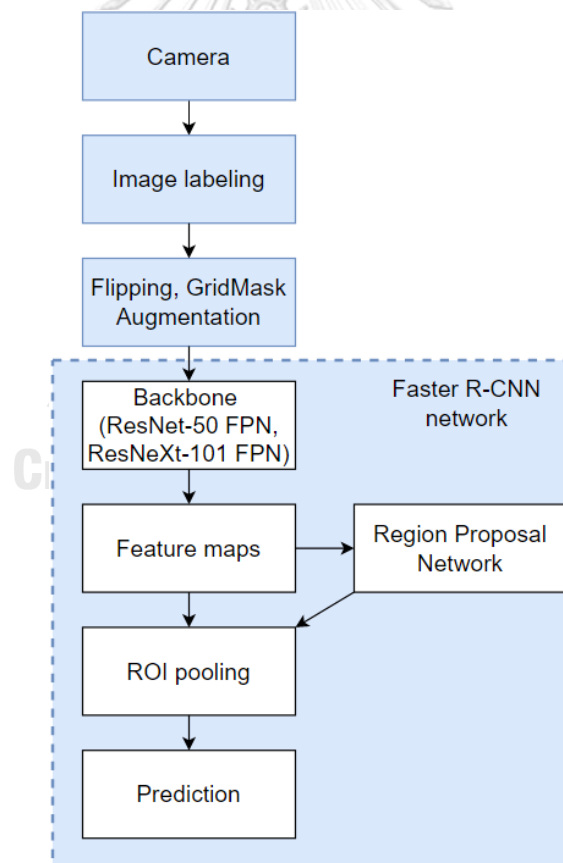
โดยที่  $r$  คืออัตราส่วนของขอบสี่เหลี่ยมที่ด้านที่สั้นกว่าในหนึ่งหน่วย  $d$  คือ ความยาวหนึ่งหน่วย  $\delta_x$  และ  $\delta_y$  คือระยะห่างระหว่างขอบหน่วยที่ไม่เสียหายส่วนแรกและขอบของภาพ

งานวิจัยก่อนหน้าที่ใช้วิธีต่าง ๆ ในการตรวจสอบความหลวมของสลักเกลียว เช่น การสั่น การหมุน การใช้การประมวลผลรูปภาพ และการใช้โครงข่ายประสาทเชิงลึก มาใช้ในการตรวจสอบความหลวม พบว่างานวิจัยที่ผ่านมาให้ค่าความแม่นยำที่สูง แต่ยังสามารถเพิ่มประสิทธิภาพในการตรวจจับวัตถุที่หลากหลายมากขึ้นโดยใช้จำนวนข้อมูลตั้งต้นเท่าเดิม เช่น มุมที่ถ่ายได้ การถ่ายจากชิ้นงานที่ถูกติดตั้งเรียบร้อยแล้ว และภาพที่ใช้ไม่จำเป็นต้องถ่ายให้เห็นหัวสลักเกลียวทั้งหมด โดยงานวิจัยนี้มุ่งเน้นไปที่การลดความต้องการของความรู้ตั้งต้นที่ใช้ร่วมกับภาพ

### บทที่ 3

#### วิธีดำเนินการวิจัย

การตรวจจับคุณภาพรอยต่อของสลักเกลียวและน็อตโดยใช้การเรียนรู้เชิงลึกที่นำเสนอในงานวิจัย แสดงไว้ในรูปที่ 13 ซึ่งมีขั้นตอนดังต่อไปนี้ รูปภาพถูกถ่ายโดยกล้องดิจิทัล จากนั้นรูปภาพจะมีการจำแนกด้วยป้ายกำกับ (label) 3 หมวดหมู่ ได้แก่ การเชื่อมต่อแบบแน่น (Snug-tight) หลวม (Loose) และไม่สามารถบอกได้ (Unidentified) สุดท้าย ชุดข้อมูลรูปภาพของเราได้รับการเสริมโดยใช้เทคนิค Grid Mask และจะได้รับการฝึกอบรมในโดยใช้โมเดล Faster R-CNN ซึ่งจะใช้สำหรับการตรวจจับและตัดแยกคุณภาพความหลวมแน่นของสลักเกลียวและน็อตต่อไป โดยในส่วนนี้ เราจะอธิบายส่วนประกอบของแบบจำลองรวมถึงโครงข่ายประสาทเทียม การตรวจจับวัตถุ R-CNN ที่เร็วขึ้น ResNeXt และโครงข่ายพีเจอร์แบบพีระมิด



รูปที่ 13 แผนผังลำดับงานของการตรวจจับคุณภาพรอยต่อของสลักเกลียวและน็อตโดยใช้การเรียนรู้เชิงลึกที่งานวิจัยนี้นำเสนอ

### 3.1 ชุดข้อมูล (Dataset)


#### 3.1.1 ชุดข้อมูลที่ 1

ข้อมูลรูปภาพที่ใช้ในการสอนแบบจำลองถูกเก็บจากสถานที่ก่อสร้างที่จอดรถยนต์อัตโนมัติ ที่ถนนลาดพร้าว 54 ในวันที่ 15 ม.ค. 2565 เก็บรูปปรอยต่อของสลักเกลียวทั้งในส่วนที่มีการตรวจสอบแรงบิดที่เหมาะสมแล้ว จะถูกทาสีเทาทับ แต่ถ้ายังไม่ได้ตรวจเพราะต้องรอตรวจสอบจากภาพรวมจะขึ้นสลักแบบหลวมเอาไว้ เพื่อมาตรวจสอบแรงบิดในภายหลัง

ภาพที่นำมาสอนให้กับแบบจำลอง แบ่งออกเป็น 3 ประเภท คือ ดูแล้วแน่น (Snug-tight) ดูแล้วหลวม (Loose) และไม่แน่ใจ (Unidentified) โดยที่แต่ละประเภทสามารถถูกแบ่งตามคำจำกัดความ ในกรณีดูแล้วแน่นเป็นภาพของรอยต่อที่มองด้วยสายตาแล้วดูแน่น ไม่จำเป็นต้องถูกทาสีก็ได้ สามารถบอกได้ว่าแน่นอย่างชัดเจน ไม่กำกวม ถูกตีกรอบด้วยกรอบสีเขียว ดังรูปที่ 14 ในกรณีดูแล้วหลวมเป็นภาพของรอยต่อที่มองด้วยสายตาแล้วดูหลวมอย่างชัดเจน ถูกตีกรอบด้วยกรอบสีแดง ดังรูปที่ 16 และในกรณีไม่แน่ใจเป็นภาพของน็อตหรือสลักเกลียวที่ไม่เห็นรอยต่อ ทำให้ไม่สามารถจำแนกประเภทของความแน่นหรือหลวมได้ ถูกตีกรอบด้วยกรอบสีน้ำเงิน ดังรูปที่ 15



รูปที่ 14 ดูแล้วแน่น



รูปที่ 16 ดูแล้วหลวม



รูปที่ 15 ไม่แน่ใจ

จำนวนภาพที่นำไปสอนให้กับแบบจำลองเริ่มต้นมีทั้งหมด 74 รูป ทั้งหมดถูกทำผลเฉลยไว้จำนวน 193 กรอบ แบ่งประเภทได้เป็น ดูแล้วแน่น 78 กรอบ ดูแล้วหลวม 48 กรอบ ไม่แน่ใจ 67 กรอบ


การสอนแบบจำลอง ข้อมูลจะถูกแบ่งออกเป็นทั้งหมด 3 ส่วน คือ ชุดสอน (train set) 60% ชุดตรวจสอบ (validation set) 20% ชุดทดสอบ (test set) 20% ชุดสอนมีหน้าที่สอนผลเฉลยให้กับแบบจำลอง ชุดตรวจสอบมีหน้าที่ยืนยันความถูกต้องของการสอนแบบจำลอง ในขณะที่สอนอยู่ ค่าความถูกต้องของการสอนต้องมีค่ามากขึ้น ชุดทดสอบเป็นชุดข้อมูลที่แบบจำลองไม่เคยเรียนรู้มาก่อน มีหน้าที่ทดสอบ ความถูกต้องของแบบจำลองขณะนำไปใช้งานจริง

### 3.1.2 ชุดข้อมูลที่ 2

ข้อมูลรูปภาพที่ใช้ในการสอนแบบจำลองถูกเก็บจาก โรงงานผลิตเหล็ก บริษัทอิตาเลียนไทย ต่าบลวิหารแดง จังหวัดสระบุรี เมื่อวันที่ 4 มิ.ย. 2565 เก็บภาพรอยต่อของสลักเกลียวจากโทรศัพท์มือถือหลากหลายรุ่น ขนาดของสลักเกลียวที่ใช้ M16 และ M22 แบ่งตามเปอร์เซ็นต์แรงบิด อ้างอิงตามมาตรฐาน JIS B 1083 ขนาดของสลักเกลียวอ้างอิงตามมาตรฐาน JIS B 1181 วัดค่าและปรับแรงบิด โดยประแจวัดแรงบิดดิจิทัล ซึ่งมีความผิดพลาดของการวัดอยู่ที่  $\pm 3\%$  โดยแบ่งการวัดเป็น เกลียวหลวม (ไม่ได้ขัน) ขันด้วยมือจนรู้สึกแน่น ขันด้วยประแจจนรู้สึกแน่น ขันด้วยประแจ 50% ของพิกัดแรงบิด ขันด้วยประแจ 70% ของพิกัดแรงบิด และขันด้วยประแจ 100% ของพิกัดแรงบิด ตามตัวอย่างดังรูปที่ 17 และ 18



รูปที่ 17 การขันสลักเกลียว M16 ที่ระดับแรงบิดต่าง ๆ



รูปที่ 18 การขันสลักเกลียว M22 ที่ระดับแรงบิดต่าง ๆ

ภาพที่นำมาสอนให้กับแบบจำลอง ถูกแบ่งออกเป็น 3 ประเภท คือ แน่น หลวม และไม่แน่ใจ โดยที่แต่ละประเภทจะถูกแบ่งตามค่าจำกัดความโดยแบ่งจากขนาดของสลักเกลียว ดังนี้

#### 3.1.2.1 สลักเกลียว M16


- a. แน่น เป็นภาพของสลักเกลียวที่ถูกขัน ที่สามารถมองเห็นรอยต่อขอบสลักเกลียว ต้องติดกับแหวน จากภาพที่ขันแน่นด้วยมือ เป็นต้นไป
- b. หลวม เป็นภาพของสลักเกลียวที่ถูกขัน ที่สามารถมองเห็นรอยต่อขอบสลักเกลียวไม่ติดกับแหวน
- c. ไม่แน่ใจ เป็นภาพของน็อตหรือสลักเกลียวที่ไม่เห็นรอยต่อ ทำให้ไม่สามารถจำแนกประเภทของความแน่นหรือหลวมได้

#### 3.1.2.2 สลักเกลียว M22

- d. แน่น เป็นภาพของสลักเกลียวที่ถูกขัน ที่สามารถมองเห็นรอยต่อเมื่อวัดขนาดแรงบิด แล้วจะมีค่ามากกว่าหรือเท่ากับ 70% ของพิกัดแรงบิด
- e. หลวม เป็นภาพของสลักเกลียวที่ถูกขัน ที่สามารถมองเห็นรอยต่อเมื่อวัดขนาด แรงบิดแล้วจะมีค่าน้อยกว่า 70% ของพิกัดแรงบิด รวมถึงการที่ไม่ได้ขันด้วย
- f. ไม่แน่ใจ เป็นภาพของน็อตหรือสลักเกลียวที่ไม่เห็นรอยต่อ ทำให้ไม่สามารถจำแนกประเภทของความแน่นหรือหลวมได้


### 3.2 Image augmentation

เนื่องจากชุดข้อมูลมีจำนวนรูปภาพจำกัด จึงจำเป็นต้องมีการเพิ่มข้อมูล โดยที่ชุดข้อมูลเหล่านี้ได้ถูกนำไปเพิ่มจำนวน (Augmentation) โดยพลิกภาพเป็นอีกด้าน (flip) และการทำ GridMask ซึ่งเป็นการตีกรอบสี่เหลี่ยมสีดำในชุดสอน ทำให้แบบจำลองสามารถหาจุดที่ใช้ตัดสินใจว่าเป็นวัตถุที่ต้องการใหม่ ๆ ได้ ดังรูปที่ 19



รูปที่ 19 การ Augmentation ด้วย flip และ gridmask

โดยผู้วิจัยได้ใช้ library albumentations [7] ถูกใช้ในการทำ GridMask ซึ่งมีการตั้งค่าที่ไม่ซับซ้อน สามารถเปลี่ยนเป็นปรับจำนวนช่องสี่เหลี่ยมที่อยู่ในรูปโดยจำนวนขนาดแถวและหลักอยู่ที่ตำแหน่งต่าง ๆ ได้ เช่น กรณีจำนวนแถวและหลักอยู่ที่ 3x3 มีการค่าพารามิเตอร์ แล้วตั้งค่าให้อัตโนมัติได้ ตัวอย่างการทำ GridMask ดังรูปที่ 20



รูปที่ 20 การใช้ GridMask ในชุดข้อมูล

### 3.3 แบบจำลอง (Model)

#### 3.3.1 Faster R-CNN

แบบจำลอง Faster R-CNN ที่มี backbone เป็น Resnet-50, ResNeXt-101 มีโมเดล pretrain จากชุดข้อมูล ImageNet [23] ซึ่งเป็นฐานข้อมูลที่ใหญ่ที่สุดในโลกสำหรับการจดจำรูปภาพ ซึ่งประกอบด้วยรูปภาพ 15 ล้านภาพ ภาพบางภาพในฐานข้อมูล ImageNet ได้รับการคัดเลือก ซึ่งประกอบด้วย 1,000 ประเภทที่แตกต่างกัน เช่น รอยขีดข่วนและข้อบกพร่องบนพื้นผิวของสัตว์ พืช อาคาร และวัตถุต่างๆ ซึ่งเป็นภาพประเภททั่วไป ตัวอย่างดังรูปที่ 21 โดยแบ่งอัตราส่วนของชุดข้อมูลการฝึกต่อชุดข้อมูลทดสอบคือ 8:2



รูปที่ 21 รูปตัวอย่าง ImageNet

[A snapshot of two root-to-leaf branches of ImageNet: mammal sub-tree and vehicle sub-tree. Source: Ye 2018, fig. A1-A.]

ในการตั้งค่าโมเดลได้ใช้ optimizer เป็น stochastic gradient descent (SGD) ด้วยค่า momentum เท่ากับ 0.9 และค่า weight decay เท่ากับ 0.0001 ค่า learning rate ตั้งต้นและ epochs ทั้งหมดอยู่ที่ 0.0001 และ 50 ตามลำดับ

#### 3.3.2 YOLOF

แบบจำลองที่ใช้เป็น YOLOF ด้วย Resnet-50 ที่ถูก pretrain จาก ImageNet เช่นเดียวกัน และนำทั้งแบบจำลองมาสอนกับ COCO object detection dataset เพื่อให้แบบจำลองสามารถตรวจจับวัตถุได้ถูกต้องมากขึ้น โดยแบ่งอัตราส่วนของชุดข้อมูลการฝึกต่อชุดข้อมูลทดสอบคือ 8:2

ในการตั้งค่าโมเดลได้ใช้ optimizer เป็น stochastic gradient descent (SGD) ด้วยค่า momentum เท่ากับ 0.9 และค่า weight decay เท่ากับ 0.0001 ค่า learning rate ตั้งต้นและ epochs ทั้งหมดอยู่ที่ 0.0001 และ 50 ตามลำดับ



### 3.4 การวัดผล (Evaluation)

ในการวัดผลการทดลอง ผู้ทดลองได้ใช้ความแม่นยำเฉลี่ย (Average Precision) หรือ AP จากการทำนายแบบจำลองของชุดทดสอบ โดยใช้อัตราส่วนซ้อนทับของพื้นที่ (Intersection over Union) หรือ IoU เป็นตัวจำแนกความถูกต้องของการทำนายกรอบในแต่ละกรอบจากเกณฑ์ (threshold) ที่มีค่าอยู่ระหว่าง 0-1 วัดค่า AP เป็น 2 ประเภท คือ ค่าเกณฑ์ที่ 0.5 (AP50) และค่าเฉลี่ยของ AP หรือเรียกว่า mAP ซึ่งเฉลี่ยค่าเกณฑ์ตั้งแต่ 0.5 ไปจนถึง 0.95 เป็นจำนวน 10 ค่า แต่ละเกณฑ์ห่างกัน 0.05 (mAP)



## บทที่ 4

### การทดลอง และผลการทดลอง

ผลการทดลองจะแบ่งออกเป็นผลการทดสอบชุดข้อมูลที่ 1 และ 2 และเปรียบเทียบระหว่างชุดข้อมูลที่ 1 และ 2 โดยชุดข้อมูลที่ 1 เป็นชุดข้อมูลที่ถูกสอนด้วยข้อมูลที่ประเมินด้วยสายตา และชุดข้อมูลที่ 2 เป็นชุดข้อมูลที่ถูกสอนด้วยข้อมูลที่ประเมินด้วยแรงบิดตามอัตราส่วนต่าง ๆ โดยเทียบกับแรงบิดพิกัด

#### 4.1 ผลการทดสอบในข้อมูลชุดที่ 1

##### 4.1.1 ผลการทดสอบการเปรียบเทียบแบบจำลอง

ผู้ทดลองได้เปรียบเทียบ ความแม่นยำของแบบจำลองและ backbone โดยใช้เกณฑ์ AP50 และ mAP ทุกแบบจำลองได้ทำการเพิ่มข้อมูล (augmentation) เมื่อนำมาทดสอบกับข้อมูลชุดทดสอบ พบว่า แบบจำลอง Faster R-CNN ที่ใช้ backbone เป็น ResNeXt-101 ให้ผลลัพธ์ที่แม่นยำมากที่สุด ดังตารางที่ 3 โดยมีการตั้งค่าดังนี้

ทุกแบบจำลองได้ตั้งค่า optimizer เป็น stochastic gradient descent (SGD) ด้วยค่า momentum เท่ากับ 0.9 และค่า weight decay เท่ากับ 0.0001 ค่า learning rate ตั้งต้นและ epochs ทั้งหมดอยู่ที่ 0.0001 และ 50 ตามลำดับ

ตารางที่ 3 ตารางเปรียบเทียบแบบจำลองที่ใช้และผลลัพธ์ของข้อมูลชุดที่ 1

Methods	Backbone	AP50 (%)	mAP (%)
Faster R-CNN	ResNet-50	80.95	62.69
	ResNeXt-101	<b>88.53</b>	<b>65.51</b>
YOLOF	ResNet-50	85.92	64.57

#### 4.1.2 ผลการทดสอบความแม่นยำจากการใช้ Image Augmentation

ผู้ทดลองได้ทำการเปรียบเทียบความแม่นยำตั้งแต่ก่อนทำการเพิ่มข้อมูล ไปจนถึงได้ทำการเพิ่มข้อมูลจนครบทุกรูปแบบ ได้แก่ Flip และ GridMask บนชุดทดสอบของข้อมูลที่ 1 ที่แบบจำลอง Faster R-CNN ด้วย backbone เป็น ResNeXt-101 ได้ผลลัพธ์ตารางที่ 4 พบว่าการเพิ่มข้อมูลด้วยวิธีต่าง ๆ ทำให้แบบจำลองทำนายได้ความแม่นยำเฉลี่ย (mAP) เพิ่มขึ้นตามลำดับ

ตารางที่ 4 ค่าความแม่นยำโดยแตกแต่ละประเภท เปรียบเทียบระหว่างก่อนและหลังเพิ่มจำนวนข้อมูล

Augmentation	mAP (%)			
	ไม่แน่ใจ (Unidentified)	ดูแล้วแน่น (Visually tight)	ดูแล้วหลวม (Visually loose)	รวม (Overall)
No augment	40.00	58.38	69.35	55.91
flip	46.95	68.63	74.23	63.27
flip, GridMask	<b>52.02</b>	<b>69.14</b>	<b>75.36</b>	<b>65.51</b>

#### 4.1.3 ผลลัพธ์การวิเคราะห์


##### 4.1.3.1 วิเคราะห์ความผิดพลาดการตรวจจับ

จากผลการทดลอง ผู้ทดลองได้ทดสอบกับแบบจำลอง Faster R-CNN ด้วย ResNet-50, ResNeXt-101 และแบบจำลอง YOLOF สามารถแบ่งประเภทของการวิเคราะห์ความผิดพลาดการตรวจจับเป็น 4 ประเภท คือ exact match, falsely classified, falsely localized และ falsely localized and falsely classified แต่ละประเภทสามารถ ถูกแบ่งตามคำจำกัดความ ดังนี้ exact match คือภาพที่แบบจำลอง ตีกรอบออกมาได้ถูกต้องทั้งหมด และจำแนกประเภทได้ถูกต้อง ดังตัวอย่างรูปที่ 22 falsely classified คือภาพที่แบบจำลองตีกรอบออกมาได้ถูกต้องทั้งหมดแต่จำแนกประเภทได้ไม่ถูกต้องในบางกรอบ ดังรูปที่ 23 falsely localized คือภาพที่แบบจำลองตีกรอบออกมาได้ขาดหรือเกินจำนวนที่ต้องการ แต่กรอบที่ครอบคลุมวัตถุไว้สามารถแยกประเภทได้ถูกต้องทั้งหมด ดังรูปที่ 24 falsely localize and falsely classified คือภาพที่แบบจำลองตีกรอบออกมา


ได้ขาดหรือเกินจำนวนที่ต้องการ และกรอบที่ครอบวัตถุ ไว้จำแนกประเภทได้ไม่ถูกต้องในบางกรอบ  
 ดังรูปที่ 25




รูปที่ 22 Exact match ผังซ้ายผลเฉลย ผังขวาผลทำนาย



รูปที่ 23 Falsely classified ผังซ้ายผลเฉลย ผังขวาผลทำนาย



รูปที่ 24 Falsely localized ผังซ้ายผลเฉลย ผังขวาผลทำนาย



รูปที่ 25 Falsely localized and falsely classified ฝั่งซั้ยผลเฉลย ฝั่งขวผลทำนายน

จากผลการทดลอง ผู้ทดลองได้แบ่งความผิดพลาดของการตรวจจับของแต่ละแบบจำลองในตารางที่ 5 - ตารางที่ 7 พบว่าแบบจำลอง Faster R-CNN สามารถทำนาย Truly classified และ Truly localized หรือ Exact match ได้มากที่สุด และให้ผลลัพธ์ Falsely classified โดยรวมที่น้อยที่สุด

ตารางที่ 5 ตารางวิเคราะห์ความผิดพลาดในการตรวจจับของ Faster R-CNN ด้วย ResNet-50

(%)	Truly classified	Falsely classified
Truly localized	43.33	30
Falsely localized	20	<b>6.67</b>

ตารางที่ 6 ตารางวิเคราะห์ความผิดพลาดในการตรวจจับของ Faster R-CNN ด้วย ResNet-101

(%)	Truly classified	Falsely classified
Truly localized	<b>61.67</b>	<b>6.66</b>
Falsely localized	21.67	10

ตารางที่ 7 ตารางวิเคราะห์ความผิดพลาดในการตรวจจับของ YOLOF

(%)	Truly classified	Falsely classified
Truly localized	<b>61.67</b>	15
Falsely localized	<b>16.67</b>	<b>6.67</b>

#### 4.1.3.2 วิเคราะห์ความแม่นยำในการจำแนกประเภท

จากผลการทดลอง ผู้ทดลองได้ทดสอบกับแบบจำลอง Faster R-CNN ด้วย ResNeXt-101 สามารถแบ่งประเภทของการวิเคราะห์ความแม่นยำการจำแนกประเภทดังตารางที่ 8 ได้แสดง confusion matrix ของ Faster R-CNN ด้วย ResNeXt-101 ซึ่งมีความแม่นยำในการจำแนกประเภทโดยเฉลี่ยที่ 91.39% คลาสไม่แน่ใจ มีความแม่นยำสูงสุดที่ 96.49% คลาสแน่นอนมีความคลุมเครือระหว่างคลาสไม่แน่ใจ หรือหลวมโดยมีข้อผิดพลาด 8.06% และ 3.22% ตามลำดับ ผลลัพธ์มีความผิดพลาดในการตรวจจับ (detection loss) คือความผิดพลาดในการตรวจจับส่วนที่ไม่ใช่สติกเกลียว และความผิดพลาดที่สติกเกลียวไม่ถูกตรวจจับที่ 3.72% ที่ไม่สามารถตรวจพบวัตถุได้จากกรอบที่ตีไว้

ตารางที่ 8 ตาราง Confusion matrix ของ Faster R-CNN ด้วย ResNeXt-101

		Actual		
		ดูแล้วแน่น (Visually tight)	ดูแล้วหลวม (Visually loose)	ไม่แน่ใจ (Unidentified)
Predicted	ดูแล้วแน่น (Snug-tight)	55 88.8%	2 6.2%	1 1.8%
	ดูแล้วหลวม (Loose)	2 3.2%	28 87.5%	1 1.8%
	ไม่แน่ใจ (Unidentified)	5 8.0%	2 6.2%	55 96.4%

## 4.2 ผลการทดสอบในข้อมูลชุดที่ 2

### 4.2.1 สลักเกลียว M16

#### 4.2.1.1 ผลการทดสอบการเปรียบเทียบแบบจำลอง

ในการทดสอบสลักเกลียว M16 ผู้ทดลองได้ใช้วิธีคัดแยกสลักเกลียวแบบประเภทชั้นแน่น (S) โดยนิยามแต่ละคลาสเพื่อไปสอนให้กับแบบจำลองดังนี้ เกลียวหลวม (หลวม) ชั้นด้วยมือจูนรูสึกแน่น (แน่น) ชั้นด้วยประแจจูนรูสึกแน่น (แน่น) ชั้นด้วยประแจ 50% ของพิกัดแรงบิด (แน่น) ชั้นด้วยประแจ 70% ของพิกัดแรงบิด (แน่น) และชั้นด้วยประแจ 100% (แน่น) แสดงดังรูปที่ 26 ซึ่งแบ่งประเภทตามสี สีแดงหมายถึงประเภทหลวม สีเขียวหมายถึงประเภทแน่น ในส่วนที่มองไม่เห็นรอยต่อชัดเจน ผู้จัดทำได้ทำฉลากเป็นประเภทไม่แน่ใจ



รูปที่ 26 วิธีคัดแยกสลักเกลียว M16 แบบประเภทชั้นแน่น

ผู้ทดลองได้เปรียบเทียบ ความแม่นยำของแบบจำลองที่และ backbone โดยใช้เกณฑ์ AP50 และ mAP พบว่า แบบจำลอง Faster R-CNN ที่ใช้ backbone เป็น ResNeXt-101 ให้ผลลัพธ์ที่แม่นยำมากที่สุด แสดงดังตารางที่ 9

ตารางที่ 9 ตารางเปรียบเทียบแบบจำลองที่ใช้ และผลลัพธ์ที่เพิ่มข้อมูลทั้งหมดแล้ว (M16)

Methods	Backbone	Unidentified	Snug-tight	Loose	AP50 (%)	mAP (%)
Faster R-CNN	ResNet-50	74.8	82.6	67.6	94.6	75.0
	ResNeXt-101	<b>75.6</b>	82.9	<b>73.9</b>	<b>95.2</b>	<b>77.5</b>
YOLOF	ResNet-50	69.9	<b>83.8</b>	65.6	92.9	73.1

#### 4.2.1.2 ผลลัพธ์การวิเคราะห์

##### 4.2.1.2.1 วิเคราะห์ความแม่นยำการจำแนกประเภทโดยรวม

จากผลการทดลอง ผู้ทดลองได้ทดสอบการจำแนกประเภทกับแบบจำลอง Faster R-CNN ด้วย ResNet-50, ResNeXt-101 และแบบจำลอง YOLOF สามารถแบ่งประเภทของการวิเคราะห์ความแม่นยำการจำแนกประเภทโดยรวมดังตารางที่ 10 - ตารางที่ 12 ได้แสดง confusion matrix ของแบบจำลองต่าง ๆ ซึ่งมีความแม่นยำในการแยกประเภท 83.82%, 90.82% และ 89.70% ตามลำดับ และมีความผิดพลาดในการตรวจจับอยู่ที่ 7.15%, 5.98% และ 17.08% ตามลำดับ จึงสรุปได้ว่าแบบจำลอง Faster R-CNN ด้วย ResNeXt-101 ให้ผลลัพธ์ที่แม่นยำที่สุดและมีความผิดพลาดในการตรวจจับน้อยที่สุด

ตารางที่ 10 ตาราง Confusion matrix ของ Faster R-CNN ด้วย ResNet-50 (M16)

		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	<b>237</b> 80.61%	0 0%	1 1.61%	<b>7</b> 63.64%
	Snug-tight	19 6.46%	<b>91</b> 73.98%	4 6.45%	2 18.18%
	Loose	17 5.78%	31 25.20%	<b>55</b> 88.71%	2 18.18%
	Background	<b>21</b> 7.14%	1 0.81%	2 3.23%	0 0%



ตารางที่ 11 ตาราง Confusion matrix ของ Faster R-CNN ด้วย ResNeXt-101 (M16)


		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	<b>239</b> 84.75%	0 0%	1 1.61%	<b>4</b> 66.67%
	Snug-tight	11 3.90%	<b>92</b> 90.20%	4 6.45%	1 16.67%
	Loose	13 4.61%	10 9.80%	<b>55</b> 88.71%	1 16.67%
	Background	<b>19</b> 6.74%	0 0%	2 3.23%	0 0%

ตารางที่ 12 ตาราง Confusion matrix ของ YOLOF (M16)

		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	<b>246</b> 85.12%	1 0.93%	4 6.06%	<b>27</b> 79.41%
	Snug-tight	10 3.46%	<b>90</b> 83.33%	4 6.06%	2 5.88%
	Loose	11 3.81%	15 13.89%	<b>56</b> 84.85%	5 14.71%
	Background	<b>22</b> 7.61%	2 1.85%	2 3.03%	0 0%

#### 4.2.1.2.2 วิเคราะห์ความผิดพลาดการจำแนกประเภทเชิงมุม

จากผลการทดลอง ผู้ทดลองได้ทดสอบการจำแนกประเภทเชิงมุมกับแบบจำลอง Faster R-CNN ด้วย ResNeXt-101 ที่เป็นแบบจำลองที่ให้ผลลัพธ์ที่แม่นยำที่สุด สามารถแบ่งประเภทของการวิเคราะห์ความผิดพลาดการจำแนกประเภทเชิงมุม หมายถึงภาพถ่ายรอยต่อสลักเกลียวที่มีมุมระหว่างกล้องและรอยต่อแบ่งตามมุมที่ถ่าย โดยแบ่งออกเป็นมุม 0-15 องศา 16-30 องศา และ 31-45 องศา ตัวอย่างดังรูปที่ 27 แสดงเป็น confusion matrix ดังตารางที่ 13 - ตารางที่ 15 ซึ่งความแม่นยำของการจำแนกประเภทเทียบเฉพาะประเภทแน่นและหลวมได้ 94.49%, 91.30% และ 79.31% ตามลำดับ และมีความผิดพลาดในการตรวจจับอยู่ที่ 5.15%, 7.50% และ 8.57% ตามลำดับ จึงสรุปได้ว่ามุมที่ถ่ายภาพส่งผลต่อความแม่นยำในการแยกประเภท



รูปที่ 27 ตัวอย่างภาพถ่ายในมุมต่าง ๆ (ก.) 0-15 องศา (ข.) 16-30 องศา (ค.) 31-45 องศา

ตารางที่ 13 ตาราง Confusion matrix ที่มุม 0-15 องศา

		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	<b>255</b> 87.33%	0 0%	1 1.65%	<b>2</b> 66.67%
	Snug-tight	10 3.42%	<b>54</b> 93.10%	2 3.70%	0 0%
	Loose	11 3.77%	4 6.90%	<b>49</b> 90.74%	1 33.33%
	Background	<b>16</b> 5.48%	0 0%	2 3.70%	0 0%

ตารางที่ 14 ตาราง Confusion matrix ที่มุม 16-30 องศา

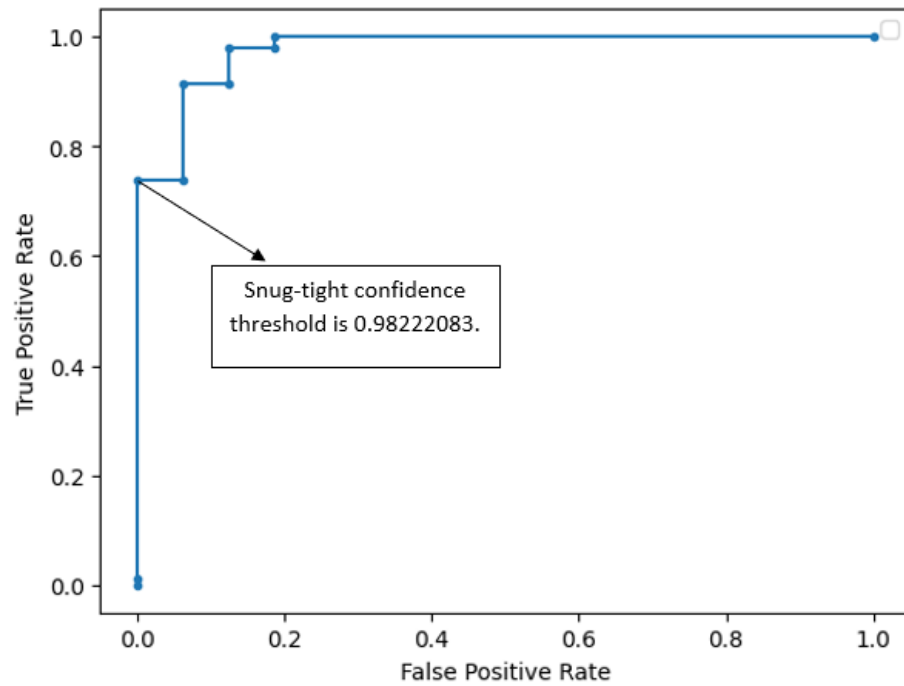
		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	<b>13</b> 92.86%	0 0%	0 0%	<b>2</b> 66.67%
	Snug-tight	0 0%	<b>15</b> 100.00%	2 25.00%	1 33.33%
	Loose	1 7.14%	0 0%	<b>6</b> 75.00%	0 0%
	Background	0 0%	0 0%	0 0%	0 0%

ตารางที่ 15 ตาราง Confusion matrix ที่มุม 31-45 องศา

		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	1 16.67%	0 0%	0 0%	0 0%
	Snug-tight	1 16.67%	23 79.31%	0 0%	0 0%
	Loose	1 16.67%	6 20.69%	0 0%	0 0%
	Background	3 50.00%	0 0%	0 0%	0 0%

#### 4.2.1.2.3 การปรับลดค่าผลบวกเทียมของจำแนกประเภทแบบหลวม

การลดค่าผลบวกเทียม (False negative) ของการจำแนกประเภทแบบหลวม เป็นสิ่งที่สำคัญในการนำแบบจำลองนี้ไปใช้ได้ เพราะความเสียหายจากการประเมินการเชื่อมต่อแบบหลวมเป็นแนนนั้นมีมากกว่าการตรวจสอบจากการประเมินการเชื่อมต่อแบบแน่นเป็นหลวม ทำให้จำเป็นต้องมีการปรับค่าความมั่นใจในการทำนายประเภทแน่นที่เหมาะสม ทดลองจากผลลัพธ์ของชุดทดสอบจากแบบจำลอง Faster R-CNN ด้วย ResNeXt-101 โดยตั้งค่าเพื่อหาค่าขีดเกณฑ์ (threshold) ของการทำนายประเภทแน่น เพื่อให้ค่าความมั่นใจไม่ถึงเกณฑ์ หรือสิ่งนี้อาจจะเป็นผลบวกเทียม (False positive) ประเภทแน่นลดลง โดยใช้การวิเคราะห์เส้นโค้ง Receiver Operating Characteristic (ROC) ทำให้ได้ค่าขีดเกณฑ์ของการจำแนกประเภทแน่นเป็น 0.9822 จากการเลือกค่าอัตราผลบวกเทียม (False positive rate) ที่น้อยที่สุดอยู่ที่ 0 และให้ค่าอัตราผลบวกแท้ (True positive rate) อยู่ที่ 0.7391 เมื่อค่าผลบวกเทียมของการจำแนกประเภทแบบแน่นลดลง ทำให้ผลบวกเทียมของการจำแนกประเภทแบบหลวมลดลงได้ แสดงดังตารางที่ 16




รูปที่ 28 ROC ระหว่างการจำแนกประเภทแน่น (Positive) และหลวม (Negative)

ตารางที่ 16 ตาราง Confusion matrix ที่ปรับลดค่าผลลบเทียมของจำแนกประเภทแบบหลวมแล้ว


		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	239 84.75%	0 0%	1 1.61%	4 66.67%
	Snug-tight	4 1.42%	<b>68</b> 66.67%	<b>0</b> 0%	0 0%
	Loose	20 7.09%	<b>34</b> 33.33%	<b>59</b> 95.16%	2 33.33%
	Background	19 6.73%	0 0%	2 3.22%	0 0%

#### 4.2.2 สลักเกลียว M22

ในการทดสอบสลักเกลียว M22 ผู้ทดลองได้ใช้วิธีคัดแยกสลักเกลียวโดยใช้พิกัดแรงบิดตามมาตรฐาน โดยนิยามแต่ละคลาสเพื่อไปสอนให้กับแบบจำลองดังนี้ เกลียวหลวม (หลวม) ขึ้นด้วยมือจนรู้สึกแน่น (หลวม) ขึ้นด้วยประแจจนรู้สึกแน่น (หลวม) ขึ้นด้วยประแจ 50% ของพิกัดแรงบิด (หลวม) ขึ้นด้วยประแจ 70% ของพิกัดแรงบิด (แน่น) และขึ้นด้วยประแจ 100% (แน่น) แสดงดังรูปที่ 29 ซึ่งแบ่งประเภทตามสี สีแดงหมายถึงประเภทหลวม สีเขียวหมายถึงประเภทแน่น ในส่วนที่มองไม่เห็นรอยต่อชัดเจน ผู้จัดทำได้ทำฉลากเป็นประเภทไม่แน่ใจ และได้เปรียบเทียบกับวิธีการคัดแยกสลักเกลียวแบบประเภทขั้นแน่น แสดงดังรูปที่ 30 อีกด้วย



รูปที่ 29 วิธีคัดแยกสลักเกลียว M22 ตามพิกัดแรงบิดมาตรฐาน



รูปที่ 30 วิธีคัดแยกสลักเกลียว M22 แบบประเภทขั้นแน่น

ผู้ทดลองได้นำแบบจำลอง Faster R-CNN ด้วย ResNeXt-101 ซึ่งเป็นแบบจำลองที่ให้ผลลัพธ์การตรวจจับที่แม่นยำที่สุด และแยกประเภทได้แม่นยำที่สุด ทดสอบเปรียบเทียบการตรวจจับหลักเกลียวประเภท M22 แบ่งตามวิธีการคัดแยกเป็นวิธีตามมาตรฐานแรงบิดและแบบประเภทชั้นแน่น ผลลัพธ์ดังตารางที่ 17 เพื่อเปรียบเทียบความแม่นยำในการตรวจจับรอยต่อ แล้ววิเคราะห์เปรียบเทียบความแม่นยำในการจำแนกประเภท ดังตารางที่ 18 และ ตารางที่ 19 พบว่าความแม่นยำของการจำแนกประเภทโดยรวมได้ 52.06% และ 65.92% ตามลำดับ และมีความผิดพลาดในการตรวจจับอยู่ที่ 17.43% และ 17.31% ตามลำดับ เมื่อเทียบกับผลลัพธ์ของแบบจำลองแต่ละแบบ พบว่า แบบที่แบ่งตามประเภทชั้นแน่นให้ความแม่นยำในการตรวจจับและการจำแนกประเภทได้ดีกว่าวิธีคัดแยกตามมาตรฐานเพราะเกณฑ์ในการตัดสินใจและวัดชัดเจนกว่า

ตารางที่ 17 ตารางเปรียบเทียบผลลัพธ์การทำนายแบ่งตามวิธีการคัดแยกประเภท (M22)

	Unidentified	Tight/ Snug-tight	Loose	AP50 (%)	mAP (%)
Standard	<b>58.0</b>	37.0	<b>57.4</b>	69.1	51.1
Snug-tight type	<b>58.0</b>	<b>65.7</b>	48.7	<b>78.1</b>	<b>57.5</b>

ตารางที่ 18 ตาราง Confusion matrix แบบจำลองที่ใช้วิธีการคัดแยกตามแรงบิดมาตรฐาน (M22)

		Actual			
		Unidentified	Tight	Loose	Background
Predicted	Unidentified	<b>56</b> 58.33%	2 1.71%	8 4.00%	5 21.74%
	Tight	9 9.38%	<b>51</b> 43.59%	52 26.00%	5 21.74%
	Loose	14 14.58%	48 41.03%	<b>120</b> 60.00%	<b>13</b> 56.52%
	Background	17 17.71%	16 14.68%	<b>20</b> 10.00%	0 0%


ตารางที่ 19 ตาราง Confusion matrix แบบจำลองที่ใช้วิธีการตัดแยกแบบประเภทขั้นแน่น (M22)

		Actual			
		Unidentified	Snug-tight	Loose	Background
Predicted	Unidentified	59 67.82%	8 4.76%	5 5.88%	6 33.33%
	Snug-tight	10 11.49%	146 86.90%	28 32.94%	11 61.11%
	Loose	4 4.60%	5 2.98%	31 36.47%	1 5.56%
	Background	14 16.09%	9 5.36%	21 24.71%	0 0%


#### 4.3 การแสดงผลจากจุดที่แบบจำลองสนใจ

ผู้ทดลองได้นำวิธี Grad-CAM ซึ่งเป็นวิธีหาจุดที่แบบจำลองสนใจและเป็นตัวชี้วัดในการจำแนกประเภทของสลักเกลียว ซึ่งเรียงตามลำดับความเข้มของสีตั้งแต่สีฟ้าที่หมายถึงมีผลต่อการจำแนกประเภทน้อย ไปจนถึงสีแดงที่หมายถึงมีผลต่อการจำแนกประเภทมาก หรือเรียกว่า Heat map ทำการทดลองทำนายประเภทของการเชื่อมต่อ โดยแบ่งออกเป็นภาพของการเชื่อมต่อที่มีน็อตอยู่ในแนวตั้งและการเชื่อมต่อที่มีน็อตอยู่ในแนวระดับ พบว่าการทำนายภาพการเชื่อมต่อที่มีน็อตในแนวตั้ง แบบจำลองทำนายประเภทของการเชื่อมต่อแน่นหรือหลวมจากความห่างของฐานที่ติดตั้งกับสลักเกลียวเพียงแบบเดียว แสดงดังรูปที่ 31 และรูปที่ 32 แต่การทำนายภาพการเชื่อมต่อที่มีน็อตในแนวระดับ แบบจำลองทำนายประเภทของการเชื่อมต่อแน่นหรือหลวมทั้งจากความห่างของฐานที่ติดตั้งกับสลักเกลียว แสดงดังรูปที่ 33 และจากความยาวของเกลียวน็อตที่ยื่นออกมาจากสลักเกลียว แสดงดังรูปที่ 34 ดังนั้นแบบจำลองนี้สามารถต่อยอดโดยการทำ augmentation แบบหมุนภาพในลักษณะต่าง ๆ ทำให้สามารถเพิ่มความแม่นยำให้กับแบบจำลองได้ อีกทั้งยังทำให้แบบจำลองสามารถรองรับภาพที่ถ่ายจากลักษณะหรือมุมต่าง ๆ ได้มากขึ้นอีกด้วย






รูปที่ 31 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 1 นี้อตแนวดิ่ง




รูปที่ 32 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 2 นี้อตแนวดิ่ง

จุฬาลงกรณ์มหาวิทยาลัย



รูปที่ 33 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 1 นี้อตแนวดิ่ง



รูปที่ 34 Heat map วิธีการจำแนกประเภทของแบบจำลองในชุดข้อมูลที่ 2 นี้ोटแนวระดับ



## บทที่ 5

### สรุปผลการทดลอง และข้อเสนอแนะ

งานวิจัยนี้ได้เสนอแบบจำลองเพื่อตรวจหาและจำแนกคุณภาพการเชื่อมต่อของสลักเกลียวสำหรับมุมมองต่างๆ โดยจัดประเภทการเชื่อมต่อของสลักเกลียวเป็นสามประเภท ได้แก่ ประเภทที่แน่น หลวม และไม่แน่ใจ โดยใช้แบบจำลอง Faster R-CNN และ YOLOF และได้ใช้ backbone เป็น ResNet-50-FPN และ ResNeXt-101-FPN พบว่าการเพิ่มข้อมูล (augmentation) ทำให้แบบจำลองสามารถตรวจจับหาตำแหน่งสลักเกลียวได้ถูกต้องมากยิ่งขึ้น ในส่วนของการเทียบความแม่นยำในการตรวจจับของแบบจำลอง พบว่าแบบจำลอง Faster R-CNN กับ ResNeXt-101-FPN ซึ่งเป็นแบบจำลองตรวจจับวัตถุแบบสองขั้นตอนนี้และการตรวจจับแบบเกือบเรียลไทม์ด้วยประสิทธิภาพที่สูงกว่า YOLOF โดยเฉพาะอย่างยิ่งเมื่อตรวจจับคลาสที่หลวมโดยการมองเห็น Faster R-CNN ด้วย ResNeXt-101-FPN ในชุดข้อมูลที่ 1 ได้รับความแม่นยำในการตรวจจับเฉลี่ย (mAP) ที่ 65.51% และความแม่นยำในการตรวจจับเฉลี่ยที่ IoU เป็น 50% ที่ 88.53% ความถูกต้องของการจัดประเภทโดยรวมตามกรอบที่ตรวจพบคือ 91.39% ในชุดข้อมูลที่ 2 ที่ใช้แบบจำลอง Faster R-CNN กับ backbone ResNeXt-101 ที่เป็นแบบจำลองที่แม่นยำที่สุดจากชุดข้อมูลที่ 1 ผลลัพธ์คือ การตรวจจับสลักเกลียวประเภท M16 ได้รับความแม่นยำในการตรวจจับเฉลี่ยที่ 77.5% และความแม่นยำในการตรวจจับเฉลี่ยที่ IoU เป็น 50% ที่ 95.2% ความถูกต้องของการจัดประเภทโดยรวมตามกรอบที่ตรวจพบคือ 90.82% โดยมุมที่วัดได้ดีที่สุดจากการแบ่งประเภทมุมจากการวัด 0-15, 16-30 และ 31-45 องศา พบว่ามุมจากการวัดที่มีขนาดไม่เกิน 15 องศา ให้ผลลัพธ์ที่แม่นยำในการแยกประเภทที่สุดอยู่ที่ 94.49% และแบบจำลองสามารถปรับลดค่าผลลบเทียมในการทำนายประเภทหลวมเป็น 0 อีกด้วย ในส่วนของการตรวจจับสลักเกลียวประเภท M22 ที่แบ่งตามประเภทขั้นแน่นและแบ่งตามแรงบิดมาตรฐาน โดยประเภทขั้นแน่นได้รับความแม่นยำในการตรวจจับเฉลี่ยที่ 57.5% และความแม่นยำในการตรวจจับเฉลี่ยที่ IoU เป็น 50% ที่ 78.1% และแบ่งตามแรงบิดมาตรฐานได้รับความแม่นยำในการตรวจจับเฉลี่ยที่ 51.1% และความแม่นยำในการตรวจจับเฉลี่ยที่ IoU เป็น 50% ที่ 69.1% เมื่อเทียบกับผลลัพธ์ของแบบจำลองแต่ละแบบพบว่า แบบที่แบ่งตามประเภทขั้นแน่นให้ความแม่นยำในการตรวจจับและการจำแนกประเภทได้ดีกว่าวิธีตัดแยกตามมาตรฐานเพราะเกณฑ์ในการตัดสินลากและวัดชัดเจนกว่า

เนื่องจากการเพิ่มประสิทธิภาพความแม่นยำสำหรับการนำไปใช้จริงมีแนวทางที่สามารถพัฒนาต่อไปในอนาคต โดยสามารถสรุปได้ดังนี้

1. การทำ augmentation ให้ครอบคลุมภาพประเภทต่าง ๆ ที่แบบจำลองสามารถพบเจอได้ และให้รองรับลักษณะที่แบบจำลองจะประเมินได้เมื่อภาพมีเงื่อนไขที่เปลี่ยนไป เช่น การหมุน การเบลอภาพ การถ่ายภาพในลักษณะแสงที่แตกต่างกัน เป็นต้น

2. การกำหนดเกณฑ์ในการถ่ายภาพที่แบบจำลองสามารถรองรับได้อย่างชัดเจน เช่น มุมในการถ่าย ระยะในการถ่าย

3. กำหนดภาพที่สอนแบบจำลองประเภทไม่แน่ใจให้เป็นสอนตามความแน่นหรือหลวมของการเชื่อมต่อ เพื่อลดความสับสนของแบบจำลอง

4. เนื่องจากข้อมูลมีจำนวนน้อย ควรลดความเอนเอียงในการประเมินผลด้วยการตรวจสอบแบบไขว้ (cross-validation)

ทั้งนี้หากงานวิจัยนี้ได้รับการพัฒนาต่อ ผู้วิจัยมีความเห็นว่า การนำข้อจำกัดเหล่านี้ไปพัฒนาต่อ จะทำให้เกิดประโยชน์ และทำให้เป็นผลดีต่องานที่เกี่ยวข้องกับประเมินความหลวมของการเชื่อมต่อแบบสลับเกลียวได้

## บรรณานุกรม

1. luorio, O., et al., *Sustainability of modular lightweight steel building from design to deconstruction*, R.A. LaBoube and W.W. Yu, Editors. 2018, Missouri University of Science and Technology. p. 515-528.
2. Lacey, A.W., et al., *Structural response of modular buildings – An overview*. Journal of building engineering, 2018. 16: p. 45-56.
3. Su, M., B. Yang, and X. Wang, *Research on Integrated Design of Modular Steel Structure Container Buildings Based on BIM*. Advances in Civil Engineering, 2022. 2022: p. 4574676.
4. Hyland, C. *High Strength Structural Bolting*. 2007.
5. Chen, M., et al., *Deep Feature Learning for Medical Image Analysis with Convolutional Autoencoder Neural Network*. IEEE Transactions on Big Data, 2021. 7(4): p. 750-758.
6. Kuutti, S., et al., *A Survey of Deep Learning Applications to Autonomous Vehicle Control*. Vol. PP. 2019.
7. Samant, R.M., et al., *Framework for Deep Learning-Based Language Models Using Multi-Task Learning in Natural Language Understanding: A Systematic Literature Review and Future Directions*. IEEE Access, 2022. 10: p. 17078-17097.
8. Sassi, P., P. Tripicchio, and C.A. Avizzano, *A Smart Monitoring System for Automatic Welding Defect Detection*. IEEE Transactions on Industrial Electronics, 2019. 66(12): p. 9641-9650.
9. Zhao, X., Y. Zhang, and N. Wang, *Bolt loosening angle detection technology using deep learning*. Structural Control and Health Monitoring, 2019. 26(1): p. e2292.
10. Wu, J., et al., *Detection of Bolt Looseness Based on Average Autocorrelation Function*. Shock and Vibration, 2021. 2021: p. 6662686.
11. Cha, Y.-J., K. You, and W. Choi, *Vision-based detection of loosened bolts using the Hough transform and support vector machines*. Automation in Construction, 2016. 71: p. 181-188.

12. Zhang, Y., et al., *Autonomous bolt loosening detection using deep learning*. *Structural Health Monitoring*, 2020. 19(1): p. 105-122.
13. Pham, H.C., et al., *Bolt-Loosening Monitoring Framework Using an Image-Based Deep Learning and Graphical Model*. *Sensors*, 2020. 20(12): p. 3382.
14. Nguyen, T., et al. *Object Detection Using Scale Invariant Feature Transform*. in *Genetic and Evolutionary Computing*. 2014. Cham: Springer International Publishing.
15. Dalal, N. and B. Triggs. *Histograms of oriented gradients for human detection*. in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. 2005.
16. Ren, S., et al., *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015. 39.
17. Chen, Q., et al., *You Only Look One-level Feature*. 2021.
18. Lin, T.Y., et al. *Focal Loss for Dense Object Detection*. in *2017 IEEE International Conference on Computer Vision (ICCV)*. 2017.
19. Xie, S., et al., *Aggregated Residual Transformations for Deep Neural Networks*. 2017. 5987-5995.
20. Lin, T.-Y., et al., *Feature Pyramid Networks for Object Detection*. 2017. 936-944.
21. Chen, P., *GridMask Data Augmentation*. 2020.
22. Singh, K.K., et al., *Hide-and-Seek: A Data Augmentation Technique for Weakly-Supervised Localization and Beyond*. *ArXiv*, 2018. [abs/1811.02545](https://arxiv.org/abs/1811.02545).
23. Deng, J., et al. *ImageNet: A large-scale hierarchical image database*. in *2009 IEEE Conference on Computer Vision and Pattern Recognition*. 2009.



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ประวัติผู้เขียน

ชื่อ-สกุล	ณัชพล พันธุ์เมธาฤทธิ์
วัน เดือน ปี เกิด	27 ตุลาคม 2540
สถานที่เกิด	กรุงเทพมหานคร
ที่อยู่ปัจจุบัน	28/48 ซอยหทัยราษฎร์ 24/1 ถนนหทัยราษฎร์ แขวงสามวาตะวันตก เขต คลองสามวา กรุงเทพมหานคร



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY