

การคัดแยกโครงสร้างทางจุลภาคของโลหะที่ผ่านกรรมวิธีฝังด้วยเทคนิค
การประมวลผลข้อมูลภาพ และการเรียนรู้เชิงลึก

ชัตติพงษ์ อยู่สำราญ

TNI

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
บัณฑิตวิทยาลัย สาขาเทคโนโลยีสารสนเทศ
สถาบันเทคโนโลยีไทย-ญี่ปุ่น
ปีการศึกษา 2565

POWDER METALLURGY MICROSTRUCTURE CLASSIFICATION USING
IMAGE PROCESSING AND DEEP LEARNING TECHNIQUES

Khattipong Usamran

TNI

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science Program in Information Technology

Graduate School
Thai-Nichi Institute of Technology

Academic Year 2022

หัวข้อวิทยานิพนธ์

การคัดแยกโครงสร้างทางจุลภาคของโลหะที่ผ่านกรรมวิธี
ผงด้วยเทคนิคการประมวลผลข้อมูลภาพ และการเรียนรู้
เชิงลึก

โดย

ชัตติพงษ์ อยู่สำราญ

สาขาวิชา

เทคโนโลยีสารสนเทศ

อาจารย์ที่ปรึกษาวิทยานิพนธ์

ดร.สะพรั่งสิทธิ์ มฤตสาร

บัณฑิตวิทยาลัย สถาบันเทคโนโลยีไทย-ญี่ปุ่น อนุมัติให้บัณฑิตวิทยาลัยนี้เป็น
ส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาโทบริหารธุรกิจ

.....คณบดีบัณฑิตวิทยาลัย

(รองศาสตราจารย์ ดร.พิชิต สุขเจริญพงษ์)

วันที่.....เดือน.....พ.ศ.....

คณะกรรมการสอบวิทยานิพนธ์

.....ประธานกรรมการ

(รองศาสตราจารย์ ดร.ตีฆัมพันธ์ เจริญพงษ์)

.....กรรมการ

(ดร.ศรายุทธ นนท์ศิริ)

.....กรรมการ

(ดร.ประมุข บุญเสียง)

.....อาจารย์ที่ปรึกษาวิทยานิพนธ์

(ดร.สะพรั่งสิทธิ์ มฤตสาร)

ชัตติพงษ์ อยู่สำราญ : การคัดแยกโครงสร้างทางจุลภาคของโลหะที่ผ่านกรรมวิธีผงด้วยเทคนิคการประมวลผลข้อมูลภาพ และการเรียนรู้เชิงลึก. อาจารย์ที่ปรึกษา : ดร.สพรั่งสิทธิ์ มณฑุสาร, 139 หน้า.

การประเมินลักษณะการหลอมรวมของเม็ดผงโลหะ (Sintering Neck) นั้นเป็นส่วนสำคัญที่ใช้ในการบ่งบอกถึงคุณภาพของการขึ้นรูปชิ้นงานโลหะ ที่ผ่านการขึ้นรูปด้วยกรรมวิธีผง (Powder Metallurgy) โดยวิเคราะห์จากลักษณะของรูพรุน ในภาพถ่ายโครงสร้างทางจุลภาคหลังการขึ้นรูป โดยในปัจจุบันการประเมินคุณภาพยังเป็นการวิเคราะห์ จากผู้เชี่ยวชาญเป็นหลัก โดยที่ยังไม่มีมาตรฐานอย่างชัดเจน

ทางผู้วิจัยได้เล็งเห็นถึงปัญหาและโอกาสที่สามารถนำการเรียนรู้เชิงลึกเข้ามาประยุกต์ใช้ในการแก้ไขปัญหา โดยใช้พื้นฐานของ CNN (Convolution Neural Network) โดยคัดเลือกมาทั้งหมด 5 อัลกอริทึม ได้แก่ ResNet-50, ResNet-101, Inception-v3, Xception และ GoogLeNet มาสร้างแบบจำลองในการประเมิน Sintering Neck ผ่านลักษณะของรูพรุนในภาพถ่ายโครงสร้างทางจุลภาค โดยอาศัยรูปภาพที่ผ่านการประเมินจากผู้เชี่ยวชาญทางด้านโลหะวิทยา จำนวน 3 คน มาเป็นต้นแบบในการสร้างแบบจำลองการเรียนรู้ เพื่อเป็นแนวทางในการสร้างมาตรฐานการประเมินในอนาคต

จากวัตถุประสงค์งานวิจัยที่ต้องการสร้างแบบจำลอง Deep Learning เพื่อใช้การประเมินคุณภาพของ Sintering Neck จากรูพรุนในภาพถ่ายโครงสร้างจุลภาค โดยอาศัยการเรียนรู้จากผู้เชี่ยวชาญเป็นต้นแบบ สามารถทำได้ซึ่งแบบจำลองที่สร้างโดยผู้เชี่ยวชาญ 3 คน และสร้างจากชุดข้อมูลเอกฉันท์นั้นให้ความแม่นยำมากที่สุด โดยมีค่าความแม่นยำอยู่ที่ 94.0-98.9% โดยที่แบบจำลองที่สร้างโดย Inception-v3 จะได้ค่าความแม่นยำสูงที่สุด ส่วนแบบจำลองด้วย GoogLeNet นั้นไม่สามารถคัดแยกประเภทของรูพรุนได้

TNI

KHATTIPONG USAMRAN : POWDER METALLURGY MICROSTRUCTURE CLASSIFICATION
USING IMAGE PROCESSING AND DEEP LEARNING TECHNIQUES. ADVISOR :
DR.SAPRANGSIT MRUETUSATORN, 139 PP.

Evaluation of the sintering neck is an important method for identifying powder metallurgy forming quality. The forming quality is evaluated by a characteristic of pores in microstructure images. Currently, the evaluation method is estimated based on experience from metallurgy experts because there is no exact standard for the evaluation.

The problems and opportunities has been realized that Deep learning could be applied to solve the problems. Based on CNN (Convolution Neural Network), a total of 5 algorithms, i.e. ResNet-50, ResNet-101, Inception-v3, Xception, and GoogLeNet were selected to create a model to assess the sintering neck through the pore characteristics in microstructure image, The evaluated microstructure images from 3 metallurgy experts were utilized for creating a machine learning model.

The objective of this research is to create a deep learning model to assess the quality of sintering necks from pores in microstructure images based on learning from experts as a model. It can be done where models created by 3 metallurgy experts and built from consensus datasets are the most accurate. It has an accuracy of 94.0-98.9%, with the model generated by Inception-v3 achieving the highest accuracy. The model with GoogLeNet was unable to classify the pore type.

Graduate School

Student's Signature.....

Field of Study Information Technology

Advisor's Signature.....

Academic Year 2022

กิตติกรรมประกาศ

การทำวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องด้วยได้รับความช่วยเหลือและกรุณาอย่างสูงจาก ดร.สพรั่งสิทธิ์ มฤตสาธร อาจารย์ที่ปรึกษางานวิจัย ที่ได้สละเวลา ให้ความรู้ ความเข้าใจ แนะนำแนวทาง แรงบันดาลใจให้พัฒนาตนเอง และคำปรึกษา จนสามารถทำให้ข้าพเจ้าสามารถดำเนินงานวิทยานิพนธ์ ได้สำเร็จ

อีกทั้งผู้วิจัยตระหนักถึงความตั้งใจจริงและความทุ่มเทของคณะกรรมการทุกท่าน ได้แก่ รองศาสตราจารย์ ดร.ทิมพันธุ์ เจริญพงษ์ ดร.ศรายุทธ นนท์ศิริ และดร.ประมุข บุญเสียง ที่กรุณาให้ข้อเสนอแนะและคำให้การที่เป็นประโยชน์ต่อการทำวิทยานิพนธ์ฉบับนี้ พร้อมทั้งแนะนำแนวทางในการปรับปรุง และแก้ไขข้อบกพร่องต่างๆ ด้วยความดูแลเอาใจใส่เป็นอย่างดีเยี่ยม จนสามารถทำให้วิทยานิพนธ์ฉบับนี้เสร็จสิ้นสมบูรณ์

ทางผู้วิจัยต้องขอขอบคุณทางบริษัท Acme International (Thailand) Ltd. และคุณธรรานนท์ อุษณะอำไพพงษ์ ผู้จัดการแผนก R&D/ผู้เชี่ยวชาญด้านโลหะวิทยาของทางบริษัท ที่ได้ช่วยสนับสนุนทรัพยากรในการทำงานวิจัย ทั้งในเรื่องของเครื่องมือ และบุคลากร เพื่อให้งานวิจัยสามารถดำเนินการได้สำเร็จลุล่วง

นอกจากนี้ทางผู้วิจัยได้รับแรงสนับสนุนจากครอบครัว ที่ได้สนับสนุนได้เรื่องของกำลังใจ และเข้าใจที่ทางผู้วิจัยต้องใช้เวลาในการดำเนินงานวิทยานิพนธ์

ผู้วิจัยหวังเป็นอย่างยิ่งว่า วิทยานิพนธ์ฉบับนี้จะก่อให้เกิดประโยชน์แก่ผู้ที่สนใจ และสามารถนำไปต่อยอดเพื่อประยุกต์ใช้กับองค์ความรู้ที่เกี่ยวข้อง อีกทั้งสามารถก่อให้เกิดแนวคิดเพื่อนำไปใช้ในการศึกษาหรือเป็นแนวทางในการทำการวิจัยที่เกี่ยวข้องในอนาคต

ชัตติพงษ์ อยู่สำราญ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฌ
สารบัญรูป.....	ฎ
บทที่	
1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	4
1.3 ประโยชน์ที่คาดว่าจะได้รับ.....	4
1.4 ขอบเขตของงานวิจัย.....	4
1.5 นิยามศัพท์เฉพาะ.....	5
2 หลักการ ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	6
2.1 ทฤษฎีที่เกี่ยวข้องกับโลหะผง (Powder Metallurgy).....	6
2.2 ทฤษฎีพื้นฐานการเตรียมภาพและการปรับปรุงภาพ (Preprocessing and Image Enhancement).....	9
2.3 ทฤษฎีที่เกี่ยวข้องกับการทำการเรียนรู้ด้วยเครื่อง (Machine Learning).....	13
2.4 งานวิจัยที่เกี่ยวข้อง.....	23
3 วิธีดำเนินงานวิจัย.....	31
3.1 ขั้นตอนการเตรียมชุดข้อมูล และประมวลผลข้อมูลภาพ.....	33
3.2 ขั้นตอนการทำการระบุประเภทข้อมูลภาพโดยมนุษย์ (Labeling Process).....	35
3.3 ขั้นตอนการสร้างแบบจำลองการเรียนรู้ (Deep Learning Model).....	36
3.4 ขั้นตอนการประเมินผล (Evaluation).....	38

สารบัญ (ต่อ)

บทที่	หน้า
4 ผลลัพธ์การวิจัย วิเคราะห์ และอภิปรายผลการทดลอง	40
4.1 ผลการทดลองจากแบบจำลองการเรียนรู้ผู้เชี่ยวชาญ 3 คน	40
4.2 ผลการทดลองจากแบบจำลองการเรียนรู้ผู้ผู้เชี่ยวชาญ 3 คน และพนักงาน ปฏิบัติการ 2 คน	56
5 บทสรุป และข้อเสนอแนะ	65
5.1 สรุปและอภิปรายผลการวิจัย	65
5.2 ปัญหาและอุปสรรคในการทำวิจัย	66
5.3 ข้อเสนอแนะงานวิจัย	66
บรรณานุกรม	67
ภาคผนวก	72
ภาคผนวก ก. โค้ดโปรแกรม (System Code)	73
ภาคผนวก ข. การตีพิมพ์ผลงานวิจัย	106
ภาคผนวก ค. รายละเอียดเอกสารประกอบการนำเสนอสอบป้องกันวิทยานิพนธ์	115
ประวัติย่อผู้วิจัย	139

สารบัญตาราง

ตาราง	หน้า
2.1 ข้อมูลเปรียบเทียบชั้น Layer ของอัลกอริทึมของ Deep Learning	21
2.2 โครงสร้างของ Confusion Matrix	22
2.3 การเปรียบเทียบงานวิจัยที่ประยุกต์ใช้การประมวลผลข้อมูลภาพกับรูปพรรณในงาน ทางด้านธรณีวิทยา	30
3.1 จำนวนรูปภาพที่ใช้ในการทำ Training Model ในกรณี 3.3.1	36
3.2 จำนวนรูปภาพที่ใช้ในการทำ Training Model ในกรณี 3.3.2	38
3.3 จำนวนรูปภาพที่ใช้ในการทดสอบ Testing Model ในกรณี 3.4.1.1	39
4.1 ผลลัพธ์ Confusion Matrix ของ ResNet-50	40
4.2 ผลลัพธ์ Confusion Matrix ของ ResNet-101	41
4.3 ผลลัพธ์ Confusion Matrix ของ Inception-v3	42
4.4 ผลลัพธ์ Confusion Matrix ของ Xception	43
4.5 ผลลัพธ์ Confusion Matrix ของ GoogLeNet	44
4.6 ผลลัพธ์ค่า %Precision ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบเอกฉันท์	46
4.7 ผลลัพธ์ค่า %Sensitivity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบเอกฉันท์	47
4.8 ผลลัพธ์ค่า %Specificity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบเอกฉันท์	47
4.9 ผลลัพธ์ค่า %F1-Score ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบเอกฉันท์	47
4.10 ผลลัพธ์ Confusion Matrix ของ Resnet-50	48
4.11 ผลลัพธ์ Confusion Matrix ของ ResNet-101	49
4.12 ผลลัพธ์ Confusion Matrix ของ Inception-v3	50
4.13 ผลลัพธ์ Confusion Matrix ของ Xception	51
4.14 ผลลัพธ์ Confusion Matrix ของ GoogLeNet	52
4.15 ผลลัพธ์ค่า %Precision ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็น ส่วนมาก	55
4.16 ผลลัพธ์ค่า %Sensitivity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็น ส่วนมาก	55
4.17 ผลลัพธ์ค่า %Specificity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็น ส่วนมาก	55

สารบัญตาราง (ต่อ)

ตาราง	หน้า
4.18 ผลลัพธ์ค่า %F1-Score ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็น ส่วนมาก	56
4.19 ระยะเวลาที่ใช้ในการสร้างแบบจำลอง Deep Learning โดยมีหน่วยเป็นนาที.....	56
4.20 ผลลัพธ์ Confusion Matrix ของ ResNet-50.....	57
4.21 ผลลัพธ์ Confusion Matrix ของ ResNet-101.....	58
4.22 ผลลัพธ์ Confusion Matrix ของ Inception-v3	59
4.23 ผลลัพธ์ Confusion Matrix ของ Xception.....	60
4.24 ผลลัพธ์ Confusion Matrix ของ GoogLeNet.....	61
4.25 ผลลัพธ์ค่า %Precision ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูลเอกฉันท์.....	63
4.26 ผลลัพธ์ค่า %Sensitivity ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูลเอกฉันท์.....	63
4.27 ผลลัพธ์ค่า %Specificity ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูลเอกฉันท์.....	63
4.28 ผลลัพธ์ค่า %F1-Score ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูลเอกฉันท์.....	64

TNI

TAHTI - NICHI INSTITUTE OF TECHNOLOGY

สารบัญรูป

รูป	หน้า
1.1 กระบวนการขึ้นรูปโลหะด้วยผงโลหะ	1
1.2 ภาพเปรียบเทียบ Sintering Neck ที่ดีและไม่ดีจากเอกสารการสอนของบริษัท Höganäs.....	2
1.3 รูปภาพของ Sintering Neck ที่ไม่ดี อ้างอิงจากเอกสารการสอนของบริษัท Höganäs.....	3
1.4 ตัวอย่างลักษณะรูปภาพโครงสร้างทางจุลภาคของรูพรุน	4
2.1 กระบวนการขึ้นรูปโลหะด้วยผงโลหะ	7
2.2 รูปภาพลักษณะการหลอมรวมของโลหะผงในช่วง Initial Stage a.) ภาพจำลอง 2 มิติ b.) ภาพจำลอง 3 มิติ	7
2.3 รูปภาพลักษณะการหลอมรวมของโลหะผงในช่วง Intermediate State a.) ภาพจำลอง 2 มิติ b.) ภาพจำลอง 3 มิติ	8
2.4 รูปภาพลักษณะการหลอมรวมของโลหะผงในช่วง Final State a.) ภาพจำลอง 2 มิติ b.) ภาพจำลอง 3 มิติ	8
2.5 ภาพ Histogram ก่อนและหลังการทำ Stretching.....	9
2.6 ภาพฮิสโตแกรมที่ผ่านการทำให้ Histogram Stretching a.) ภาพดั้งเดิมก่อนการทำ Histogram Stretching b.) ภาพหลังการทำ Histogram Stretching.....	10
2.7 ภาพฮิสโตแกรมที่ผ่านการทำให้ Histogram Equalization a.) ภาพดั้งเดิมก่อนการทำ Histogram Equalization b.) ภาพหลังการทำ Histogram Equalization	10
2.8 ภาพเปรียบเทียบก่อนและหลังการทำ Image Sharpening หัวไหล่ของมนุษย์	11
2.9 ภาพตัวที่ใช้ในการวัดค่า Histogram (a-d) และรูปภาพค่า Histogram ของ Pixel ที่มีค่า 0-255 (e-h)	12
2.10 ภาพการทำ Global Thresholding ด้วยอัลกอริทึมต่างชนิดกัน.....	12
2.11 ภาพหลังกระบวนการทำ Local Adaptive Thresholding ภาพ Grey Scale (a-d) และภาพหลังการทำ Binarization (q-t)	13
2.12 ขั้นตอนการประมวลผลข้อมูลภาพเบื้องต้นด้วย CNN.....	15
2.13 ลักษณะก่อนและหลังกระบวนการทำ Flattening	16
2.14 ภาพโครงสร้างการเรียนรู้ด้วยเครื่องของ Alexnet.....	17
2.15 ภาพเปรียบเทียบการเรียนรู้ของ Alexnet และ VGGNet.....	17

สารบัญรูป (ต่อ)

รูป	หน้า
2.16 ภาพของลำดับชั้นย่อย Inception Layer.....	18
2.17 ภาพรวม Architecture ของ GoogLeNet.....	18
2.18 ภาพรวมรายละเอียด Convolution Layer ที่เปลี่ยนแปลงจาก GoogLeNet ใน Inception-v3.....	19
2.19 ภาพรวม Architecture ของ Inception-v3.....	19
2.20 ภาพรวม Architecture ของ Xception	20
2.21 ภาพ Residual ของ Layer ที่ใช้ใน ResNet	20
2.22 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึม CNN ของ Alfredo	21
2.23 ค่าผลลัพธ์การเปรียบเทียบความแม่นยำของ CNN จากงานวิจัยของ Vishali.....	26
2.24 ข้อมูลผลลัพธ์การเปรียบเทียบความแม่นยำ CNN จากงานวิจัยของ Deyani	27
3.1 ขั้นตอนการเตรียมชิ้นงานโลหะเพื่อทำการส่องดูภาพผ่านกล้องจุลทรรศน์.....	31
3.2 Flow Chart ภาพรวมขั้นตอนการทำงานวิจัย	32
3.3 ตัวอย่างรูปภาพความผิดปกติที่เกิดจากกระบวนการเตรียมชิ้นงาน	33
3.4 รายละเอียดองค์ประกอบที่สำคัญของภาพ	34
3.5 ตัวอย่างภาพก่อนและหลังการทำ Binarization	34
3.6 รูปภาพตัวอย่าง Guideline สำหรับใช้ในการประเมิน.....	35
3.7 รูปแบบการทำ K-Fold Cross Validation.....	37
3.8 รูปโครงสร้าง Architecture และ Activation Function ที่ใช้ในการสร้างแบบจำลอง	37
4.1 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-50	41
4.2 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-101.....	42
4.3 กราฟ Individual Plot ความน่าจะเป็นของ Inception-v3.....	43
4.4 กราฟ Individual Plot ความน่าจะเป็นของ Xception	44
4.5 กราฟ Individual Plot ความน่าจะเป็นของ GoogLeNet.....	45
4.6 แผนภูมิแท่งเปรียบเทียบค่าความแม่นยำชุดข้อมูลทดสอบแบบจำลองเอกฉันท์ ด้วยชุดทดสอบเอกฉันท์.....	45
4.7 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-50	48
4.8 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-101	49

สารบัญรูป (ต่อ)

รูป	หน้า
4.9 กราฟ Individual Plot ความน่าจะเป็นของ Inception-v3.....	50
4.10 กราฟ Individual Plot ความน่าจะเป็นของ Xception	51
4.11 กราฟ Individual Plot ความน่าจะเป็นของ GoogLeNet.....	52
4.12 แผนภูมิเปรียบเทียบค่าความแม่นยำแบบจำลองเอกฉันท์ ด้วยชุดทดสอบความเห็น ส่วนมาก	53
4.13 กราฟ Interval Plot ความน่าจะเป็นของประเภทรูปพรุนที่ไม่ดี.....	53
4.14 กราฟ Interval Plot ความน่าจะเป็นของประเภทรูปพรุนที่ดี.....	53
4.15 กราฟ Interval Plot ความน่าจะเป็นของประเภทรูปพรุนที่ดีมาก.....	54
4.16 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-50	57
4.17 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-101	58
4.18 กราฟ Individual Plot ความน่าจะเป็นของ Inception-v3.....	59
4.19 กราฟ Individual Plot ความน่าจะเป็นของ Xception	60
4.20 กราฟ Individual Plot ความน่าจะเป็นของ GoogLeNet.....	61
4.21 แผนภูมิแท่งเปรียบเทียบค่าความแม่นยำทดสอบแบบจำลองผู้เชี่ยวชาญและปฏิบัติการ ด้วยชุดทดสอบเอกฉันท์.....	62

TNI


THAI - NICHI INSTITUTE OF TECHNOLOGY

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ในปัจจุบันวัสดุโลหะเป็นส่วนประกอบสำคัญในหลายอุตสาหกรรม ไม่ว่าจะเป็นอุตสาหกรรมก่อสร้าง อุตสาหกรรมยานยนต์ อุตสาหกรรมทางการแพทย์ อุตสาหกรรมอิเล็กทรอนิกส์ เป็นต้น โดยการขึ้นรูปโลหะนั้นมีกระบวนการที่หลากหลายในปัจจุบันไม่ว่าจะเป็นขึ้นรูปด้วยวิธีการรีด (Rolling Process) การตีขึ้นรูป (Forging Process) และอื่นๆ โดยวัสดุตั้งต้นก่อนที่จะทำการขึ้นรูปนั้นไม่ได้หลายประเภท ไม่ว่าจะเป็นการนำเศษโลหะ (Scrap) มาทำการหลอมใหม่ การถลุงโลหะจากสินแร่ (Ore) เป็นต้น ซึ่งในปัจจุบันได้มีการพัฒนาวิธีการผลิตโลหะจากการที่นำผงโลหะ (Metal Powder) มาผ่านกระบวนการอัด (Compacting) ผ่านแม่แบบ (Die) แล้วนำไปผ่านกระบวนการเผาผนึก (Sintering) เพื่อให้ได้ชิ้นงานตามความต้องการ ซึ่งจะเรียกโดยรวมว่าเทคนิคการขึ้นรูปโลหะผงด้วยการอัด (Compact and Sinter : P/M) [1] โดยภาพกระบวนการเผาผนึกแสดงให้เห็นในรูปที่ 1.1




รูปที่ 1.1 กระบวนการขึ้นรูปโลหะด้วยผงโลหะ [1]

เทคนิคการขึ้นรูปโลหะผงได้มีแนวโน้มการนำมาใช้ในอุตสาหกรรมมากขึ้น จากข้อมูลทางสถิติการตลาดจากเว็บไซต์ Grand View Research [2] ได้คาดการณ์การเติบโตของการใช้งานโลหะผงในตลาดอยู่ที่ 11.6% จากปี 2020 ถึงปี 2027 จากความต้องการในการใช้งานของอุตสาหกรรมทางอากาศยานและการป้องกันประเทศ นอกจากนี้ข้อมูลจากเว็บไซต์ Research and Markets [3] ยังได้ระบุถึงข้อดีของเทคนิคโลหะผงที่ทำให้เป็นที่ต้องการของตลาด ไม่ว่าจะเป็นเทคนิคการขึ้นรูปที่สามารถควบคุม


ปริมาณของรูพรุน (Porosity) ได้ สามารถขึ้นรูปชิ้นงานที่มีรูปร่างซับซ้อน และต้องการความแม่นยำของขนาดและรูปร่างของชิ้นงาน สามารถปรับส่วนผสมของชนิดผงโลหะเพื่อให้ได้คุณสมบัติที่เหมาะสมกับการใช้งานประเภทต่างๆ และยังเป็นการขึ้นรูปที่ไม่เกิดของเสียจากกระบวนการผลิต (Scrap) อีกด้วย ส่วนข้อเสียของการขึ้นรูปโลหะผงนั้น คือ จะไม่สามารถขึ้นรูปชิ้นงานที่มีขนาดใหญ่ได้ เนื่องจากต้องใช้แรงอัด (Compact Force) ที่สูงซึ่งมีความเสี่ยงทำให้แม่พิมพ์ (Mold) เสียหาย และต้นทุนที่สูงสืบเนื่องมาจากเครื่องจักรที่มีความสามารถในการสร้างแรงอัดที่สูงนั้นมีราคาแพง

ในการวิเคราะห์โครงสร้างทางจุลภาค (Microstructure) ของโลหะผง นอกจากการตรวจสอบชนิดของเนื้อโลหะ (Metal Phase) แล้วยังมีการตรวจสอบในเรื่องของรูพรุน โดยอ้างอิงจากมาตรฐานโลหะผง MPIF 35 [4] ได้กล่าวถึงความสัมพันธ์ของปริมาณรูพรุนนั้นส่งผลถึงความหนาแน่นของชิ้นงานโลหะ นอกจากนี้รูพรุนยังสามารถบ่งบอกถึงคุณภาพการหลอมรวมของเม็ดโลหะผงที่เรียกว่า Sintering Neck ผ่านกระบวนการเผาผนึก โดยปัจจุบันการประเมิน Sintering Neck นั้นยังใช้การประเมินจากผู้เชี่ยวชาญ และยังไม่มีเกณฑ์การประเมินที่แน่นอน โดยตัวอย่างภาพโครงสร้างทางจุลภาคของ Sintering Neck ที่ดี และไม่ดีจะดูตัวอย่างได้จากรูปที่ 1.2 โดยเมื่อเพิ่มกำลังขยายของภาพถ่ายโครงสร้างทางจุลภาคจะเห็นรูปร่างของรูพรุนที่มีขนาดใหญ่ขึ้น ดังที่แสดงให้เห็นในรูปที่ 1.3 นอกจากนี้ยังมีงานวิจัยที่ศึกษาผลกระทบของรูพรุนในโลหะผง อาทิเช่น งานวิจัยเกี่ยวกับรูปร่างของรูพรุนนั้นส่งผลต่อความแข็งแรงต่อการล้าตัว (Fatigue Strength) ของโลหะผง [5] หรืองานวิจัยที่ระบุว่ารูพรุนนั้นมีผลต่อกับพฤติกรรมทางกล (Mechanical Behavior) ของโลหะผง [6] เป็นต้น



รูปที่ 1.2 ภาพเปรียบเทียบ Sintering Neck ที่ดีและไม่ดีจากเอกสารการสอนของบริษัท Höganäs [7]

- a. และ c. ตัวอย่างโครงสร้างทางจุลภาคแบบ Sintering Neck ที่ไม่ดี
- b. และ d. ตัวอย่างโครงสร้างทางจุลภาคแบบ Sintering Neck ที่ดี



Free Graphite and poor Sintering Necks


รูปที่ 1.3 รูปภาพของ Sintering Neck ที่ไม่ดี อ้างอิงจากเอกสารการสอนของบริษัท Höganäs [7]

ในปัจจุบันได้มีงานวิจัยที่ได้นำเทคโนโลยีเกี่ยวกับการประมวลผลข้อมูลภาพเข้ามาประยุกต์ใช้ในการวิเคราะห์เกี่ยวกับโครงสร้างทางจุลภาคมากขึ้น อาทิเช่นงานวิจัยที่ได้ทำการเปรียบเทียบการวัดปริมาณรูพรุนด้วยโปรแกรม Image เพื่อหาความหนาแน่นของโลหะ แล้วนำไปเปรียบเทียบกับวิธีการวัดแบบดั้งเดิมด้วยการชั่งน้ำหนัก [8] หรืองานวิจัยที่สร้างแบบจำลองในการวิเคราะห์ชนิดของเนื้อโลหะจากรูปภาพโดยใช้เทคนิคของการประมวลผลข้อมูลภาพผนวกกับการใช้เครือข่ายประสาทเทียมแบบคอนโวลูชัน (Fully Convolutional Neural Networks: FCNN) [9] นอกจากงานประเภทโลหะแล้วยังมีงานวิจัยเกี่ยวกับธรณีศาสตร์ ที่ใช้เทคโนโลยีการประมวลผลข้อมูลภาพในการวิเคราะห์รูพรุน อาทิเช่น งานวิจัยที่วัดปริมาณของรูพรุนในชั้นดิน ด้วยการประมวลผลข้อมูลภาพ [10]

จากรายละเอียดที่กล่าวไปข้างต้นผู้วิจัยได้เล็งเห็นถึงการประเมิน Sintering Neck จากรูปภาพโครงสร้างทางจุลภาค ที่ยังใช้ประสบการณ์จากผู้เชี่ยวชาญในการประเมิน และยังไม่มีความมาตรฐานในการกำหนดที่ชัดเจนดังนั้นทางผู้วิจัยจึงมุ่งเน้นในการพัฒนาแบบจำลองในการคัดแยกประเภทของ Sintering Neck ที่ดีหรือไม่ดีโดยใช้เทคโนโลยีของเทคนิคการประมวลผลข้อมูลภาพ (Image Processing Techniques) และการเรียนรู้ของเครื่อง (Machine Learning) มาช่วยในการคัดแยกคุณภาพของ Sintering Neck จากรูปร่างของรูพรุน โดยในงานวิจัยได้ทำการแบ่งลักษณะคุณภาพของ Sintering Neck จากรูปถ่ายโครงสร้างทางจุลภาคของรูพรุนที่บ่งบอกถึงลักษณะการหลอมรวม ออกเป็น 3 ประเภทตามคำแนะนำของผู้เชี่ยวชาญทางด้านโลหะ อันได้แก่

1. รูพรุนที่บ่งบอกถึงกระบวนการหลอมรวมที่ไม่ดี (Not Good)
2. รูพรุนที่บ่งบอกถึงกระบวนการหลอมรวมที่ดี (Good)
3. รูพรุนที่บ่งบอกถึงกระบวนการหลอมรวมที่ดีมาก (Very Good)

โดยตัวอย่างรูปโครงสร้างทางจุลภาคของรูพรุนจะแสดงให้เห็นในรูปที่ 1.4 โดยรูพรุนจะถูกประเมินจากผู้เชี่ยวชาญทางด้านโลหวิทยา โดยที่ผลของการประเมินของภาพนั้นอาจจะแตกต่างออกไปขึ้นอยู่กับประสบการณ์ และความถนัดของผู้เชี่ยวชาญแต่ละคน ดังนั้นทางผู้วิจัยจึงได้นำเทคนิคการเรียนรู้เชิงลึก (Deep Learning) เข้ามาประยุกต์ใช้ในงานวิจัย



a.) Not Good

b.) Good

c.) Very Good

รูปที่ 1.4 ตัวอย่างลักษณะรูปภาพโครงสร้างทางจุลภาคของรูพรุน

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อคัดแยกคุณภาพของ Sintering Neck ประเภทที่ไม่ดี ประเภทที่ดี และประเภทที่ดีมาก โดยวิเคราะห์จากรูปร่างรูพรุนในภาพถ่ายโครงสร้างทางจุลภาคของชิ้นงานที่ขึ้นรูปด้วยโลหะผง โดยนำเทคนิคการประมวลผลข้อมูลภาพ และการเรียนรู้ของเครื่องเข้ามาช่วยในการคัดแยก เพื่อช่วยลดความผิดพลาดหรือความคลาดเคลื่อน และลดเวลาจากการประเมินด้วยมนุษย์

1.3 ประโยชน์ที่คาดว่าจะได้รับ

1.3.1 สามารถสร้างแบบจำลอง (Model) หรือโปรแกรมที่สามารถช่วยมนุษย์ในการตัดสินใจการวิเคราะห์ปัญหาเกี่ยวกับ Sintering Neck ในงานโลหะผง โดยประเมินจากลักษณะรูพรุนในภาพถ่ายโครงสร้างทางจุลภาค

1.3.2 สามารถนำแบบจำลองหรือโปรแกรมที่ได้จากงานวิจัยมาเป็นแนวทางการสร้างมาตรฐานเกี่ยวกับการประเมินคุณภาพของ Sintering Neck ในกระบวนการขึ้นรูปด้วยโลหะผง

1.4 ขอบเขตของงานวิจัย

1.4.1 การวิเคราะห์รูพรุนในงานวิจัยใช้กับโครงสร้างทางจุลภาคของโลหะผง

1.4.2 ข้อมูล (Data Set) ที่ใช้ในงานวิจัยได้รับการสนับสนุนมาจากบริษัท Acme International (Thailand) Ltd.)

1.4.3 ผู้เชี่ยวชาญที่ใช้เป็นต้นแบบในการสร้าง Machine Learning Model มีทั้งหมด 3 คน

1.5 นิยามศัพท์เฉพาะ

1.5.1 **กรรมวิธีผง (Powder Metallurgy (P/M))** หมายถึง กระบวนการขึ้นรูปชิ้นงานโลหะ โดยวัสดุตั้งต้นจะเป็นลักษณะเม็ดผงโลหะ

1.5.2 **กระบวนการเผาผนึก (Sintering)** หมายถึง กระบวนการขึ้นรูปชิ้นงาน ด้วยการผ่านกรรมวิธีทางความร้อนออกมาเป็นชิ้นงานจากแบบหรือแม่พิมพ์

1.5.3 **การขึ้นรูปโลหะผงด้วยการอัด Compact and Sintering (P/M)** หมายถึง เป็นกระบวนการขึ้นรูปโลหะ โดยการนำผงโลหะมาทำการอัดใส่แม่พิมพ์ แล้วนำไปผ่านกระบวนการเผาผนึกออกมาเป็นชิ้นงาน

1.5.4 **โครงสร้างทางจุลภาค (Microstructure)** หมายถึง การนำวัสดุมาทำการดูโครงสร้างผ่านกล้องจุลทรรศน์ โดยจะมีจุดประสงค์เพื่อดูความผิดปกติที่เกิดขึ้นจากกระบวนการผลิต (Defect) หรือลักษณะของเนื้อโลหะเป็นต้น

1.5.5 **โครงสร้างโลหะ (Metal Phase)** หมายถึง โครงสร้างของโลหะที่ส่งผลต่อคุณสมบัติต่างๆ ของโลหะ โดยวิธีการตรวจสอบจะนำโลหะมาผ่านกรรมวิธีการกัดกรด (Etching) แล้วดูลักษณะโครงสร้างผ่านกล้องจุลทรรศน์

1.5.6 **การหลอมรวมของเม็ดโลหะผง (Sintering Neck)** หมายถึง เป็นลักษณะรูปร่างของผงโลหะผ่านกระบวนการหลอมหรือเผาผนึก โดยลักษณะที่ดีหรือไม่ดีสามารถ สังเกตได้จากรูปร่างของรูพรุนผ่านภาพถ่ายโครงสร้างทางจุลภาค

1.5.7 **รูพรุน (Porosity)** หมายถึง ช่องว่างที่เกิดขึ้นในเนื้อวัสดุหลังการขึ้นรูป ความแข็งแรงต่อการล้า (Fatigue Strength) หมายถึง เป็นคุณสมบัติของวัสดุที่ทนต่อการรับแรง

บทที่ 2

หลักการ ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

เพื่อให้บรรลุจุดประสงค์ของงานวิจัยที่ต้องการคัดแยกอนุพันธ์ที่ทำให้เกิด Sintering Neck ที่ดีหรือไม่ดี นั้นทางผู้วิจัยจึงได้มุ่งเน้นศึกษาทฤษฎีพื้นฐานเกี่ยวกับวิธีการต่างที่จะนำมาใช้ในงานวิจัย โดยแบ่งออกเป็น 3 หัวข้อหลักดังต่อไปนี้

1. ทฤษฎีพื้นฐานที่เกี่ยวข้องกับโลหะผง
2. ทฤษฎีพื้นฐานการเตรียมภาพและการปรับปรุงภาพ
3. ทฤษฎีพื้นฐานและอัลกอริทึมของการเรียนรู้ด้วยเครื่อง

นอกจากนี้ทางผู้วิจัยได้ทำการศึกษางานวิจัยที่มีลักษณะระเบียบวิธีวิจัยที่ใกล้เคียงกัน ไม่ว่าจะเป็นการประยุกต์การใช้งานการประมวลผลข้อมูลภาพ หรือการเรียนรู้ด้วยเครื่องโดยผู้วิจัยแบ่งเนื้อหา ดังนี้


1. งานวิจัยที่ศึกษาเกี่ยวข้องกับโลหะผง Powder Metallurgy (P/M)
2. งานวิจัยที่ศึกษาเกี่ยวข้องกับวิธีการของการประมวลผลข้อมูลภาพ (Image Processing)
3. งานวิจัยที่ศึกษาเกี่ยวกับการนำการเรียนรู้เชิงลึก (Deep Learning) มาใช้ในการคัดแยก
รูปภาพ
4. งานวิจัยที่มีแนวคิดการประยุกต์ใช้วิธีการที่ใกล้เคียงกันกับงานประเภทอื่น

2.1 ทฤษฎีที่เกี่ยวข้องกับโลหะผง (Powder Metallurgy)

2.1.1 นิยามของโลหะผง (Powder Metallurgy)

กรรมวิธีผง (Powder Metallurgy) คือ ศาสตร์ที่ศึกษากระบวนการขึ้นรูปโลหะ โดยนำผงโลหะมาทำให้เกิดประโยชน์ทั้งด้านวิศวกรรมและด้านอื่นๆ กระบวนการผลิตขึ้นรูปโลหะด้วยกรรมวิธีผงนั้นจะแสดงให้เห็นในรูปที่ 2.1 โดยกระบวนการกรรมวิธีผงมีส่วนประกอบสำคัญหลัก 3 ส่วน ได้แก่ ชนิดผงโลหะ กระบวนการขึ้นรูป และคุณสมบัติของผลิตภัณฑ์ โดยที่คุณสมบัติของผลิตภัณฑ์ เช่น ความแข็งแรง (Strength) ของชิ้นงาน คุณสมบัติความแข็ง (Hardness) เป็นต้น คุณสมบัติของชิ้นงานนั้นจะขึ้นอยู่กับตัวแปรต่างๆ ไม่ว่าจะเป็น โครงสร้างทางจุลภาคของเนื้อโลหะหลังการขึ้นรูป ส่วนผสมทางเคมีของผงโลหะก่อนทำการขึ้นรูป ความเสียดทานภายใน ขนาด รูปร่าง และอุณหภูมิที่ใช้ในการผลิต การขึ้นรูปโลหะผงโดยทั่วไปมี 3 ขั้นตอนดังนี้

1. ขั้นตอนการผสมผงโลหะ (Mixing)
2. ขั้นตอนการอัดผง (Compacting)
3. ขั้นตอนการเผาผนึก (Sintering)




รูปที่ 2.1 กระบวนการขึ้นรูปโลหะด้วยผงโลหะ [1]

2.1.2 กระบวนการเผาผนึกโลหะผง (Sintering) [11]


ในกระบวนการขึ้นรูปโลหะผง นอกจากปัจจัยในเรื่องของการผสมผงโลหะ และกระบวนการอัดผงแล้ว กระบวนการเผาผนึกยังเป็นอีกหนึ่งปัจจัยที่ส่งผลต่อคุณสมบัติของชิ้นงานหลังกระบวนการขึ้นรูป โดยขั้นตอนการหลอมรวมของเม็ดโลหะในกระบวนการเผาผนึก กรณีที่เม็ดผงโลหะเป็นชนิดเดียวกันจะเรียกขั้นตอนการหลอมหลวมของเม็ดโลหะประเภทนี้ว่า Solid State โดยจะสามารถแบ่งเป็นขั้นตอนตามลักษณะพฤติกรรมของเม็ดโลหะออกเป็น 3 ช่วง ดังนี้

1. ช่วง Initial State จะเป็นช่วงที่เกิดการหลอมรวมของเม็ดผงโลหะ หรือที่เรียกว่า Sintering Neck โดยผิวของผงโลหะในขั้นตอนนี้ยังอยู่ในลักษณะทรงกลม ไม่มีการเปลี่ยนแปลงหรือเสียรูปมากนัก ดังที่แสดงในรูปที่ 2.2




รูปที่ 2.2 รูปภาพลักษณะการหลอมรวมของโลหะผงในช่วง Initial Stage a.) ภาพจำลอง 2 มิติ b.) ภาพจำลอง 3 มิติ [11]

2. ช่วง Intermediate State จะเป็นช่วงที่ผิวของผงโลหะเริ่มมีการเสียรูปและยึดติดกัน โดยขั้นตอนนี้ เนื้อโลหะ (Grain) จะเริ่มมีการเติบโตอันเนื่องมาจากการได้รับพลังงานจากกระบวนการเผาผนึก ดังที่แสดงในรูปที่ 2.3



รูปที่ 2.3 รูปภาพลักษณะการหลอมรวมของโลหะผงในช่วง Intermediate State a.) ภาพจำลอง 2 มิติ b.) ภาพจำลอง 3 มิติ [11]

3. ช่วง Final stage เป็นช่วงที่เนื้อโลหะเริ่มมีการเติบโตถึงขีดสุดและมีความหนาแน่นมากขึ้น โดยช่องว่างระหว่างเนื้อโลหะที่เกิดขึ้นหลังการเย็นตัวจะถูกเรียกว่ารูพรุน (Pores) ดังที่แสดงในรูปที่ 2.4



รูปที่ 2.4 รูปภาพลักษณะการหลอมรวมของโลหะผงในช่วง Final State a.) ภาพจำลอง 2 มิติ b.) ภาพจำลอง 3 มิติ [11]


นอกจากนี้ในกรณีที่เม็ดผงโลหะในการผสมเป็นธาตุโลหะที่ต่างชนิดกัน อาทิเช่น เม็ดผงโลหะเหล็ก (Fe) ผสมกับเม็ดผงโลหะทองแดง (Cu) จะมีช่วงของ ของเหลว (Liquid State) เพิ่มเข้ามาเนื่องจากอุณหภูมิจุดหลอมเหลว (Melting Point) ของโลหะทั้ง 2 ชนิดไม่เท่ากัน โดยโลหะที่มีจุดหลอมเหลวต่ำ อาทิเช่น ทองแดง หรือ อลูมิเนียม จะมีการละลายเข้าไปในช่องว่างหรือรูพรุน ทำให้คุณสมบัติของชิ้นงานมีการเปลี่ยนแปลงเป็นต้น

2.2 ทฤษฎีพื้นฐานการเตรียมภาพและการปรับปรุงภาพ (Preprocessing and Image Enhancement)


เป็นกระบวนการปรับปรุงภาพ โดยมีจุดประสงค์เพื่อต้องการเห็นข้อมูลองค์ประกอบของภาพได้ชัดเจนขึ้น และยังเป็นขั้นตอนที่ใช้ในการคัดกรองความผิดปกติของภาพ (Noise) หรือ ใช้ในการแยกวัตถุที่สนใจ (Object) ออกจากภาพพื้นหลัง (Background) ของภาพ โดยเทคนิคเบื้องต้นที่ทางผู้วิจัยศึกษาจากหนังสือ Preprocessing and Image Enhancement [12] และ Principles of Digital Image Processing : Advanced Methods [13] เพื่อมาปรับปรุงภาพในงานวิจัยมีดังนี้

2.2.1 การปรับระดับสีของภาพด้วยวิธีขยาย Histogram (Contrast Adjustment by Histogram Stretching) [14]

เป็นกระบวนการที่ปรับความเข้มของภาพโดยใช้ Histogram ในการกระจายค่าความเข้มของสีรูปภาพ ให้ภาพนั้นมีความต่างระหว่างค่าความเข้มสูงสุด และน้อยสุดตามกราฟในรูปภาพที่ 2.5 โดยที่ค่า P_i คือค่าความน่าจะเป็นในเชิงปริมาณของความเข้มของภาพ q และ g คือตำแหน่งของ q ที่ความเข้มของสีมีค่า P_i สูงโดยหลักของการทำ Histogram Stretching คือการขยายให้ค่าความเข้ม P_i ไปทั่วทั้งภาพโดยใช้ ค่าเฉลี่ย ของค่าความเข้มกระจายไปทั่วภาพ ตัวอย่างลักษณะกราฟ Histogram ก่อนและหลังกระบวนการ Histogram Stretching จะแสดงให้เห็นในรูปที่ 2.5 โดยที่ลักษณะการยืดของความเข้มภาพจะเป็นลักษณะเส้นตรง โดยตัวอย่างภาพก่อนและหลังกระบวนการทำ Histogram Stretching จะแสดงให้เห็นในรูปที่ 2.6




รูปที่ 2.5 ภาพ Histogram ก่อนและหลังการทำ Stretching [14]



รูปที่ 2.6 ภาพชิปคอมพิวเตอร์ที่ผ่านการทำ Histogram Stretching a.) ภาพดั้งเดิมก่อนการทำ Histogram Stretching b.) ภาพหลังการทำ Histogram Stretching [14]

2.2.2 การแบ่งความเข้มของภาพด้วย Histogram (Histogram Equalization) [14]

เป็นกระบวนการปรับค่าความเข้มของภาพ (Contrast) ของภาพพื้นหน้าและภาพพื้นหลังให้ชัดเจนมากยิ่งขึ้น โดยลักษณะภาพที่ได้จะต่างจากวิธี Histogram Stretching ที่ใช้ค่าเฉลี่ยความเข้มของภาพโดยรวมกระจายเข้าไปในแต่ละตำแหน่งของภาพ ภาพจะมีการเกลี่ยความเข้มในแต่ละตำแหน่ง Pixels ให้ไม่กระจุกตัวอยู่ตำแหน่งใดตำแหน่งหนึ่ง โดยภาพเปรียบเทียบกับก่อนและหลังจากกระบวนการการทำ Histogram Equalization จะแสดงในรูปที่ 2.7



รูปที่ 2.7 ภาพชิปคอมพิวเตอร์ที่ผ่านการทำ Histogram Equalization a.) ภาพดั้งเดิมก่อนการทำ Histogram Equalization b.) ภาพหลังการทำ Histogram Equalization [14]

2.2.3 การทำภาพให้คมชัด (Image Sharpening) [14]

เป็นเทคนิคที่ใช้ในการปรับภาพให้คมชัด โดยมีวัตถุประสงค์หลักในการลดความไม่ชัดเจนของวัตถุในภาพซึ่งอาจเกิดเนื่องมาจากการที่ถ่ายภาพวัตถุ ขณะที่วัตถุเคลื่อนไหว หรือเกิดจากสภาพแวดล้อมที่ถ่ายภาพ ทำให้ไม่เห็นรายละเอียดที่สำคัญของภาพ โดยการทำ Image Sharpening จะเป็นการปรับความถี่ของภาพให้มีความละเอียดมากยิ่งขึ้น โดยวิธีการทำภาพให้คมชัดจะทำให้เห็นองค์ประกอบของภาพที่ชัดเจนขึ้น แต่จะมีผลข้างเคียงคือภาพที่ได้หลังจากกระบวนการนี้จะมี Noise มากขึ้นหลังผ่านกระบวนการ โดยตัวอย่างภาพก่อนและหลังการทำ Image Sharpening จะแสดงให้เห็นในรูปที่ 2.8



a.) ภาพดั้งเดิมก่อนการทำ Image Sharpening

b.) ภาพหลังการทำ Image Sharpening


รูปที่ 2.8 ภาพเปรียบเทียบก่อนและหลังการทำ Image sharpening หัวไหล่ของมนุษย์ [14]

2.2.4 การทำภาพขาวดำ (Binarization) ด้วยการทำ Global Thresholding [13]

การทำ Thresholding เป็นกระบวนการที่แปลงภาพ Gray Scale ให้เป็นภาพขาวดำ (Binary Image) โดยสมมุติค่าระดับของตำแหน่ง Pixel ของภาพ คือ (u,v) ซึ่งในแต่ละ Pixel จะมีค่าความเข้มของสีเทาโดยมีค่าอยู่ที่ 0-255 จะกำหนดอยู่ในรูปของตัวแปร I โดยเมื่อกำหนดค่าเกณฑ์ในการแบ่งภาพ (Threshold Value) เท่ากับ q ค่า Pixel ที่มีค่าความเข้มสีเทาน้อยกว่าหรือเท่ากับ q จะถูกมองให้เป็นภาพพื้นหลัง (Background) โดยถูกจัดให้อยู่ใน Set ของ C_0 และ ค่า Pixel ที่มีค่าความเข้มสีเทามากกว่า q จะถูกมองให้เป็นภาพพื้นหน้า (Foreground) โดยถูกจัดให้อยู่ใน Set ของ C_1 ซึ่งสามารถเขียนเป็นสมการได้ตามสมการที่ 2.1


$$(u,v) \in \begin{cases} C_0 & \text{if } I(u,v) \leq q \text{ (background)} \\ C_1 & \text{if } I(u,v) > q \text{ (foreground)} \end{cases} \quad (2.1)$$

โดยเมื่อนำค่าความเข้มในแต่ละ Pixel ของภาพ Grayscale มาทำการ Plot ค่า Histogram ก่อนที่จะทำการแปลงภาพเป็นภาพขาวดำ (Binary Image) จะแสดงให้เห็นในรูปที่ 2.9



รูปที่ 2.9 ภาพตัวที่ใช้ในการวัดค่า Histogram (a-d) และรูปภาพค่า Histogram ของ Pixel ที่มีค่า 0-255 (e-h) [13]

นอกจากนี้กระบวนการทำ Global Thresholding ยังมีการพัฒนาใช้ค่าอัลกอริทึมที่ต่างกัน โดยภาพ Binary Image ที่ได้จะมีลักษณะของภาพที่ต่างกันดังที่แสดงในรูปภาพที่ 2.10




รูปที่ 2.10 ภาพการทำ Global Thresholding ด้วยอัลกอริทึมต่างชนิดกัน [13]

2.2.5 การทำภาพ Binarization ด้วยการทำ Local Adaptive Thresholding [13]

กระบวนการสร้างภาพ Binarization Image ด้วยการที่ใช้ค่า Thresholding ค่าคงที่ค่าเดียวของวิธี Global thresholding นั้นในบางครั้งภาพที่ได้องค์ประกอบที่สำคัญของภาพจะถูกมองเป็นภาพพื้นหลัง ทำให้สูญเสียส่วนสำคัญของตัวภาพ ดังรูปที่ 2.10 ดังนั้นแทนที่จะใช้ค่า Thresholding

เพียงค่าเดียวกับทุก Pixel ในภาพ จึงได้มีการประยุกต์ที่จะใช้ค่า Thresholding หลายค่า $Q(u,v)$ โดยอิงจากองค์ประกอบภาพรวมในแต่ละตำแหน่งของ Pixels $I(u,v)$ ในภาพมาเป็นค่า Thresholding จะทำให้ภาพที่ได้นั้นไม่ถูกกลืนเป็นภาพพื้นหลังจากค่า Thresholding เพียงค่าเดียว ทำให้ภาพที่ได้หลังกระบวนการทำ Binarization ได้ภาพที่มีรายละเอียดของวัตถุที่สนใจได้มากกว่า โดยตัวอย่างภาพที่ได้จากการทำ Local Thresholding จะแสดงในรูปที่ 2.11



รูปที่ 2.11 ภาพหลังกระบวนการทำ Local Adaptive Thresholding ภาพ Grey Scale (a-d) และ ภาพหลังการทำ Binarization (q-t) [13]

2.3 ทฤษฎีที่เกี่ยวข้องกับการทำการเรียนรู้ด้วยเครื่อง (Machine Learning)

ทางผู้วิจัยได้ทำการศึกษารายละเอียดการทำ Machine Learning ประเภทต่างๆ เพื่อใช้ในการคัดเลือกวิธีการที่จะนำมาประยุกต์ใช้ในงานวิจัย

2.3.1 รูปแบบของข้อมูล [14]

รูปแบบข้อมูลที่แบ่งตามโครงสร้าง โดยทั่วไปแล้วจะแบ่งออกเป็นลักษณะ 2 ลักษณะใหญ่ด้วยกันคือข้อมูลที่มีโครงสร้าง (Structured Data) ซึ่งเป็นข้อมูลที่มีรูปแบบที่ชัดเจนแน่นอน โดยส่วนมากจะถูกเก็บในรูปแบบตาราง และข้อมูลที่มีโครงสร้างไม่แน่นอนหรือไม่ชัดเจนนั้นจะถูกเรียกว่า (Unstructured Data) อาทิเช่น รูปภาพ เสียง หรือ วิดีทัศน์ เป็นต้น โดยรูปแบบของข้อมูลจะเป็นปัจจัยที่สำคัญเพื่อที่จะใช้ในการคัดเลือกวิธีการ หรือ อัลกอริทึม ที่จะใช้ในการสร้างรูปแบบการเรียนรู้ของเครื่อง (Machine Learning)

2.3.1.1 ข้อมูลที่มีโครงสร้างชัดเจน (Structured Data)

ข้อมูลที่มีโครงสร้างที่ชัดเจนมักถูกเก็บในรูปแบบของตาราง (Table) ซึ่งประกอบด้วยแถว (Row) และ คอลัมน์ (Column) โดยที่บางครั้งชื่อเรียกจะถูกเปลี่ยนไปขึ้นอยู่กับชนิดของการทำงาน อาทิเช่น ข้อมูลที่เป็นแถวอาจมีชื่อเรียกว่า ตัวอย่าง (Example) หรือ อินสแตนซ์ (Instance) และข้อมูลในแนวคอลัมน์ อาจจะมีชื่อเรียกว่า แอตทริบิวต์ (Attribute) หรือฟีเจอร์ (Feature) เป็นต้น

2.3.1.2 ข้อมูลที่ไม่มีโครงสร้างชัดเจน (Unstructured Data)

ข้อมูลที่ไม่ได้อยู่ในรูปแบบของตาราง อาทิเช่นข้อมูลที่เป็นรูปภาพ เสียง หรือ วิดีทัศน์ โดยข้อมูลเหล่านี้จะมีปริมาณมหาศาลเมื่อเทียบกับข้อมูลประเภทที่มีโครงสร้าง ดังนั้นในการนำข้อมูลที่ไม่มีโครงสร้างมาวิเคราะห์ มักจะถูกแปลงมาให้อยู่ในรูปแบบข้อมูลที่มีโครงสร้างก่อน เช่น ข้อมูลรูปภาพ จะถูกนำมาแปลงเป็นข้อมูลตัวเลขในภาพ อาทิเช่น ค่าความเข้มของสี ตำแหน่งของ Pixel หลังจากนั้นถึงนำข้อมูลเหล่านี้มาใช้ในการวิเคราะห์ข้อมูลในลำดับถัดไป

2.3.2 เทคนิคการเรียนรู้

2.3.2.1 เทคนิคการเรียนรู้แบบมีผู้สอน (Supervised Learning)


เทคนิคการเรียนรู้แบบมีผู้สอน หรือ Supervised Learning นั้นจะเน้นการเรียนรู้จากข้อมูลที่มีอยู่ในอดีตเพื่อนำมาสร้างแบบจำลอง ที่ใช้ในการทำนายหรือคาดการณ์สิ่งที่จะเกิดขึ้นในอนาคต ไม่ว่าจะใช้วิธีการสร้างสมการทางคณิตศาสตร์ เพื่อใช้ในการทำนายข้อมูล หรือการนำข้อมูลมาจัดประเภท เพื่อสร้างรูปแบบการเรียนรู้ นอกจากนี้ Supervised Learning นั้นสามารถแยกย่อยลงไปได้อีก คือ การจำแนกประเภทข้อมูล (Classification) และการประมาณค่าข้อมูล (Regression) โดยทั้ง 2 ประเภทนี้ จะมีลักษณะของผลลัพธ์ที่ต่างกัน

2.3.2.2 เทคนิคการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

เทคนิคการเรียนรู้แบบไม่มีผู้สอน หรือ Unsupervised Learning เป็นเทคนิคที่จะใช้การพิจารณาลักษณะของข้อมูลเป็นหลัก โดยลักษณะข้อมูลที่พิจารณามักจะมีรูปแบบที่ชัดเจน โดยเทคนิคหลักที่ใช้กับการเรียนรู้แบบไม่มีผู้สอน คือ เทคนิคการหาความสัมพันธ์ (Association Rule) และการแบ่งกลุ่มข้อมูล (Clustering)

2.3.3 โครงสร้างประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) [15]

Convolutional Neural Network (CNN) เป็นรูปแบบการเรียนรู้เชิงลึก (Deep Learning) ประเภทหนึ่งที่เป็นที่นิยมในปัจจุบัน โดยมักนำมาใช้กับข้อมูลประเภทรูปภาพ เพื่อหาลักษณะเด่นของตัวข้อมูลภาพ เพื่อจดจำหรือเรียนรู้รูปแบบคุณลักษณะที่สำคัญของภาพ อาทิ เช่น ใบหน้าคน ภาพวัตถุ หรือ ฉากหลังของภาพ เป็นต้น โดยโครงสร้างของ CNN สามารถแบ่งออกเป็น 2 ส่วนหลัก คือ Feature Learning และ Classification ตามรูปที่ 2.12



รูปที่ 2.12 ขั้นตอนการประมวลผลข้อมูลภาพเบื้องต้นด้วย CNN [15]

2.3.3.1 Feature Learning Layers

จะสามารถแบ่งลำดับชั้นย่อยได้อีก 3 ชั้น คือ Convolution Layer, Rectified Linear Unit Layer และ Pooling Layer [15] [16] [17]

1. Convolution Layer จะเป็นชั้นที่ดำเนินการเกี่ยวกับการนำ ชุดข้อมูลภาพ ไปประมวลผลกับชุดของ Convolutional Filters เช่นความสว่างของภาพ หรือ ความคมของขอบภาพ ซึ่งจะได้ลักษณะที่สำคัญหลังจากผ่านกระบวนการนี้


2. ReLU: Rectified Linear Unit Layer จะเป็นชั้นที่ทำให้การเรียนรู้จากชุดข้อมูล ที่ได้นั้นมีประสิทธิภาพมากขึ้น โดยใช้วิธีการ Mapping ข้อมูลที่เป็นค่าลบ (-) ให้เป็นศูนย์ (0) ส่วนข้อมูลที่เป็นค่าบวก (+) ให้คงไว้ชั้นนี้ ซึ่งจะกรองส่วนสำคัญของลักษณะข้อมูลภาพมาไว้ใช้ในการประเมินในลำดับชั้นถัดไป

3. Pooling Layers เป็นชั้นที่ดำเนินการรวบรวมข้อมูล เพื่อลดความซับซ้อนของชุดข้อมูลลง โดยใช้วิธีการสุ่มตัวอย่างข้อมูลแบบไม่เชิงเส้น, การลดจำนวนพารามิเตอร์ เพื่อให้โครงข่ายได้เรียนรู้ข้อมูลเฉพาะส่วนที่สำคัญ และตัดข้อมูลที่ไม่เกี่ยวข้องกับภาพออกไปจากกระบวนการเรียนรู้ โดยผลลัพธ์สุดท้ายจะได้คุณลักษณะ (Feature) ที่สำคัญของภาพออกมาเพื่อใช้ในกระบวนการคัดแยก (Classification) ในลำดับถัดไป

2.3.3.2 Classification Layers [16] [17]

หลังจากที่ได้คุณลักษณะข้อมูลภาพที่สำคัญจากการทำ Feature Learning แล้ว ข้อมูลภาพที่ได้มาจะถูกนำมาทำการแบ่งประเภทหรือจัดกลุ่มของข้อมูลภาพ โดย Layer นี้เป็น Layer สุดท้ายที่ใช้ในการทำนายข้อมูลของภาพว่า ภาพที่นำมาประมวลผลและสร้างกลุ่มการเรียนรู้ว่าเป็นภาพกลุ่มไหน โดยแบ่งออกเป็น 3 ขั้นตอนที่สำคัญ ได้แก่

1. Flattening หลังจากที่ได้ฝังคุณลักษณะ (Feature Map) จากขั้นตอนการทำ Pooling Layer แล้ว ข้อมูลจะถูกนำมาจัดเรียงใหม่ในลักษณะเชิงเส้นตัวอย่างเช่น ข้อมูลของสีที่เก็บอยู่ในรูปแบบของ Matrix หลังจากกระบวนการ Flattening จะถูกแปลงจาก Matrix ให้เป็น Column ดังที่แสดงให้เห็นในรูปที่ 2.13



รูปที่ 2.13 ลักษณะก่อนและหลังกระบวนการทำ Flattening


2. Fully Connected Layer เป็นกระบวนการที่นำผลลัพธ์ของกระบวนการทำ Flattening มาทำการสร้างเครือข่ายเชื่อมโยงเพื่อทำการจัดกลุ่มหาคุณสมบัติที่สำคัญขององค์ประกอบของภาพ เพื่อใช้ในการระบุประเภทของภาพในกระบวนการถัดไป

3. Softmax Function เป็นขั้นตอนหลังจาก Fully Connected Layer ที่จะทำการคำนวณความน่าจะเป็นของภาพ จาก Fully Connected Layer ว่าคุณสมบัติเหล่านี้มีความน่าจะเป็น กลุ่มภาพประเภทใดจากชุดข้อมูล

นอกจากนี้ทางผู้วิจัยได้เลือกทำการทบทวนโครงสร้างของสถาปัตยกรรมของการเรียนรู้เชิงลึกประเภท Convolutional Neural Network เพื่อนำมาเลือกใช้เป็นตัวเลือกในงานวิจัยโดยมีรายการที่ทบทวนดังนี้ AlexNet, GoogLeNet, VGGNet, ResNet101, ResNet-50, Inception-v3 และ Xception


Alexnet [18] เป็นโครงสร้างของ CNN แบบเรียบง่ายถูกคิดค้นโดย Alex และ Geoffrey โดยที่ยึดรูปแบบการทำ CNN แบบดั้งเดิม ที่ใช้ภาพที่มีขนาด Pixels ที่น้อยกว่ามาเป็นตัวกรอง (Filter) ในชั้นภาพที่ใหญ่กว่าโดยมีการเพิ่มในเรื่องของการทำ ReLu Function เพื่อจำแนกข้อมูลออกเป็น 0 กับ

1 โดยมีจุดประสงค์เพื่อกรองข้อมูลที่ไม่สำคัญออกจากภาพ โดยโครงสร้างของ Alexnet จะแสดงให้เห็นในรูปที่ 2.14




รูปที่ 2.14 ภาพโครงสร้างการเรียนรู้ด้วยเครื่องของ Alexnet [18]

VGGNet [19] [20] เป็นสถาปัตยกรรมการเรียนรู้ที่ถูกเสนอโดย Simonyan และ Zisserman ในปี 2014 ซึ่งมีขั้นตอนการ Training ของแบบจำลองเหมือนกับ Alexnet แต่จะมีปริมาณขั้นของการทำ Convolutional ที่มากกว่า Alexnet ตามรูปที่ 2.15




รูปที่ 2.15 ภาพเปรียบเทียบการเรียนรู้ของ Alexnet และ VGGNet [20]

GoogLeNet (Inception-v1) [17] [21] เป็นสถาปัตยกรรมที่พัฒนาโดย C. Szegedy et al. จากทีมของ Google Research ที่ชนะการแข่งขันในงานการจำแนกภาพของ ILSVRC 2014 โดยที่ GoogLeNet จะไม่ได้ใช้ Fully-Connected Layer เป็นตัวบ่งบอกคุณสมบัติของภาพ แต่จะทดแทนด้วยลำดับชั้นย่อยที่เรียกว่า Inception Layer ดังที่แสดงในรูปที่ 2.16 ทำให้ใช้ทรัพยากรในการประมวลผลที่น้อยกว่า โดยองค์ประกอบภาพรวมโครงสร้างของ GoogLeNet จะแสดงในรูปที่ 2.17




รูปที่ 2.16 ภาพของลำดับชั้นย่อย Inception Layer [17]




รูปที่ 2.17 ภาพรวม Architecture ของ GoogLeNet [17]

Inception-v3 [22] [23] เป็นสถาปัตยกรรมที่พัฒนาต่อยอดมาจาก GoogLeNet หรือ Inception-v1 ในปี 2015 โดยมีรายละเอียดที่สำคัญที่เพิ่มเข้ามาได้แก่ การทำโครงสร้าง Convolution Layer ใหม่ ด้วยกระบวนการ Factorization (การแยกตัวประกอบ) โดยมีการเปลี่ยนแปลง 3 Layer หลักดังรูปที่ 2.18 โดยองค์ประกอบภาพรวมโครงสร้างของ Inception-v3 จะแสดงในรูปที่ 2.19




รูปที่ 2.18 ภาพรวมรายละเอียด Convolution Layer ที่เปลี่ยนแปลงจาก GoLeNet ใน Inception-v3 [23]




รูปที่ 2.19 ภาพรวม Architecture ของ Inception-v3 [23]

Xception [24] เป็นสถาปัตยกรรมที่พัฒนาโดย Google เช่นเดียวกับ GoLeNet และ Inception-v3 โดยได้มีการเผยแพร่งานวิจัยในปี 2017 โดยได้ปรับปรุงเพิ่มเติมในส่วน of Depthwise Convolution และ Pointwise Convolution เข้าไปในโครงของ CNN โดยองค์ประกอบภาพรวมโครงสร้างของ Inception-v3 จะแสดงในรูปที่ 2.20




รูปที่ 2.20 ภาพรวม Architecture ของ Xception [25]

ResNet [26] เป็นสถาปัตยกรรมที่ถูกพัฒนาเพื่อมาแก้ไขในเรื่องของลักษณะองค์ประกอบที่สำคัญของวัตถุในภาพนั้นหายไประหว่างกระบวนการเรียนรู้ ทำให้การเรียนรู้ในช่วงขั้นตอนหลังจากนั้นไม่เกิดการค้นพบคุณลักษณะใหม่ เนื่องจากองค์ประกอบที่สำคัญนั้นถูกตัดออกไป ได้ทำการนำเสนอแบบจำลองที่มีการเรียนรู้เทียบกับผลลัพธ์การเรียนรู้เก่าในทุก 2 Layer ดังที่แสดงในรูปที่ 2.21 เพื่อไม่ให้ข้อมูลองค์ประกอบที่สำคัญจากการเรียนรู้ใน Layer เก่า นั้นหายไป โดยจะมีลักษณะคล้ายคลึงกับ GoogLeNet



รูปที่ 2.21 ภาพ Residual ของ Layer ที่ใช้ใน ResNet [17]

โดยจากงานวิจัยของ Alfredo ได้ทำการเปรียบเทียบความแม่นยำของอัลกอริทึมประเภทต่างๆ ไว้ตามรูปที่ 2.22



รูปที่ 2.22 กราฟเปรียบเทียบความแม่นยำของอัลกอริทึม CNN ของ Alfredo [27]

เมื่อนำแบบจำลองในแต่ละสถาปัตยกรรม มาทำการเปรียบเทียบชั้น (Layer) และ ลำดับปีที่ตีพิมพ์ในงานวิจัยในแต่ละอัลกอริทึม จะแสดงในตารางที่ 2.1

ตารางที่ 2.1 ข้อมูลเปรียบเทียบชั้น Layer ของอัลกอริทึมของ Deep Learning

No.	อัลกอริทึม (Algorithm)	ปีที่คิดค้น (Year)	Layers			
			Convolutional	Pooling	Fully Connected	Total
1	AlexNet	2012	5	3	3	25
2	VGGNet16	2014	13	5	3	41
3	GoogLeNet	2014	57	14	1	144
4	Inception-v3	2015	94	14	1	316
5	Xception	2017	74	5	1	171
6	ResNet-50	2015	104	2	1	177
7	ResNet-101	2015	104	2	1	347

นอกจากนี้ทางผู้วิจัยได้ทำการศึกษางานวิจัยที่ได้ทำการเปรียบเทียบ ทรัพยากรที่ใช้ ในการสร้างแบบจำลองจากอัลกอริทึมในแต่ละประเภทเพื่อนำมาประยุกต์ใช้ในงานวิจัย โดยทางผู้วิจัย ได้เลือก GoogLeNet ที่ใช้ทรัพยากรในการสร้างแบบจำลองน้อยแต่มีความแม่นยำที่ต่ำ เพื่อใช้ในการ ทดสอบโค้ดของแบบจำลอง และได้เลือก ResNet-50, ResNet-101, Inception-v3 และ Xception

จากค่าความแม่นยำที่สูงและใช้ทรัพยากรในการสร้างแบบจำลองไม่สูงมากนักมาใช้ในการเปรียบเทียบและสร้างแบบจำลองในงานวิจัย

2.3.4 ตัวชี้วัดการประเมินผล [28]

ทางผู้วิจัยได้เลือกศึกษาการประเมินประสิทธิภาพของแบบจำลอง โดยใช้เครื่องมือ Confusion Matrix ซึ่งเป็นเครื่องมือที่นิยมใช้ในการประเมินผลลัพธ์ของการทำการเรียนรู้ด้วยเครื่อง โดยมีหลักการนำข้อมูลผลลัพธ์ของแบบจำลองที่ประมวลผลได้ มาเทียบกับข้อมูลจริงโดยมีโครงสร้างและนิยามของตัวแปร ตามตารางที่ 2.2

ตารางที่ 2.2 โครงสร้างของ Confusion Matrix

Prediction/Actual	Yes	No
Yes	TP	FP
No	FN	TN

โดยมีนิยามค่าข้อมูลที่ใส่ลงไปในตาราง ดังต่อไปนี้

True Positive(TP) คือ ผลลัพธ์แบบจำลองที่เกิดขึ้นจริง และข้อมูลจริงเป็นสิ่งที่เกิดขึ้นจริง

True Negative(TN) คือ ผลลัพธ์แบบจำลองที่เกิดขึ้นจริง และข้อมูลจริงเป็นสิ่งที่ไม่เกิดขึ้นจริง

False Positive(FP) คือ ผลลัพธ์แบบจำลองที่ไม่เกิดขึ้นจริง และข้อมูลจริงเป็นสิ่งที่เกิดขึ้นจริง

False Negative(FN) คือ ผลลัพธ์แบบจำลองที่ไม่เกิดขึ้นจริง และข้อมูลจริงเป็นสิ่งที่ไม่เกิดขึ้น

จริง

โดยค่าข้อมูลสามารถนำมาสร้างดัชนีชี้วัดข้อมูล เพื่อใช้ในการประเมินและวิเคราะห์ผลได้

ดังต่อไปนี้

Accuracy หรือ ค่าความถูกต้อง เป็นค่าดัชนีที่บ่งบอกถึงความถูกต้องของแบบจำลองที่ถูกสร้างขึ้น โดยค่าความถูกต้องของทุกประเภทของข้อมูล (Class) สามารถคำนวณได้จากสมการที่ 2.2

$$\text{Accuracy} = \frac{(\text{TPs} + \text{TNs})}{(\text{TPs} + \text{TNs} + \text{FPs} + \text{FNs})} \quad (2.2)$$

Precision หรือ ค่าความแม่นยำ เป็นค่าที่บ่งบอกถึงความเที่ยงตรงในแต่ละประเภทของกลุ่มข้อมูลที่สนใจ นั้นมีความแม่นยำของผลลัพธ์ของแบบจำลองได้ถูกต้อง เมื่อเทียบกับกลุ่มข้อมูลประเภทอื่นที่ถูกนำผลลัพธ์เพิ่มเข้ามาในประเภทของกลุ่มที่สนใจ สามารถคำนวณได้จากสมการที่ 2.3

$$\text{Precision} = \frac{\text{TPs}}{(\text{TPs} + \text{FPs})} \quad (2.3)$$

Recall/Sensitivity หรือ ค่าความไว เป็นค่าที่บ่งบอกถึงความไวในการตรวจจับข้อมูลในแต่ละประเภทของกลุ่มข้อมูล ว่ากลุ่มข้อมูลที่สนใจมีความสามารถในการตรวจจับข้อมูลได้ถูกต้อง เมื่อเทียบกับข้อมูลของประเภทเดียวกัน ที่ถูกทำนายไปเป็นกลุ่มข้อมูลอื่น สามารถคำนวณได้จากสมการที่ 2.4

$$\text{Sensitivity} = \frac{\text{TPs}}{(\text{TPs} + \text{FNs})} \quad (2.4)$$

Specificity หรือ ความจำเพาะ เป็นค่าที่บ่งบอกถึงความจำเพาะของกลุ่มข้อมูล ว่ากลุ่มข้อมูลนั้นมีความจำเพาะที่จะไม่ถูกทำนายไปเป็นกลุ่มข้อมูลอื่น สามารถคำนวณได้จากสมการที่ 2.5

$$\text{Specificity} = \frac{\text{TNs}}{(\text{TNs} + \text{FPs})} \quad (2.5)$$

F1-Score เป็นค่าเฉลี่ยที่เกิดจากนำค่า Precision และค่า Recall มาเฉลี่ยกันเพื่อแสดงความถูกต้องของข้อมูลในแต่ละกลุ่ม สามารถคำนวณได้จากสมการที่ 2.6

$$\text{F1-Score} = 2 * \frac{\text{Precision} * \text{Recall}}{(\text{Precision} + \text{Recall})} \quad (2.6)$$

2.4 งานวิจัยที่เกี่ยวข้อง

งานวิจัยเรื่อง การคัดแยกโครงสร้างทางจุลภาคของโลหะที่ผ่านกรรมวิธีผงด้วยเทคนิคการประมวลผลข้อมูลภาพ ทางผู้วิจัยได้ทำการศึกษางานวิจัย ที่มีลักษณะจุดประสงค์หรือวิธีการที่ใกล้เคียงกัน เพื่อเป็นแนวทางในการดำเนินงานวิจัยโดยมีลำดับเนื้อหาที่เกี่ยวข้องดังนี้

2.4.1 งานวิจัยที่ศึกษาเกี่ยวข้องกับโลหะผง Powder Metallurgy (P/M)

2.4.2 งานวิจัยที่ศึกษาเกี่ยวกับวิธีการของการประมวลผลข้อมูลภาพ (Image Processing)

2.4.3 งานวิจัยที่ศึกษาเกี่ยวกับการนำการเรียนรู้เชิงลึก (Deep Learning) มาใช้ในการคัดแยกประเภทข้อมูลรูปภาพ

2.4.4 งานวิจัยที่มีแนวความคิดการประยุกต์วิธีการที่ใกล้เคียงกันกับลักษณะงานประเภทอื่น

2.4.1 งานวิจัยที่ศึกษาเกี่ยวข้องกับโลหะผง Powder Metallurgy (P/M)

ในหัวข้อนี้ทางผู้วิจัยได้ทำการศึกษาเกี่ยวกับงานวิจัยทางด้านโลหะวิทยา ที่ได้ศึกษาเกี่ยวกับผลกระทบของรูพรุนในโลหะผง เพื่อแสดงให้เห็นถึงความสำคัญและประโยชน์จากการวิเคราะห์รูพรุนในโลหะผง เนื่องจากกระบวนการขึ้นรูปโลหะผงนั้น รูพรุนเป็นผลลัพธ์ที่เกิดจากกระบวนการผลิตที่หลีกเลี่ยงไม่ได้ แต่สามารถควบคุมได้จากปัจจัยต่างๆ อาทิเช่น ขนาดของอนุภาคผงโลหะก่อนทำการเผาผนึก อุณหภูมิที่ใช้ในการเผาผนึก หรือ ระยะเวลาที่ใช้ในการเผาผนึก เป็นต้น

M. K. Dunstan et al. [29] ได้ทำการศึกษาวิจัยเกี่ยวกับ ความแข็งแรงต่อการล้า (Fatigue Strength) ในโลหะ Titanium Alloy ชั้นคุณภาพ (Grade) Ti-6Al-4V โดยพิจารณาปัจจัยที่มีผลกระทบ จากขนาดรูพรุน รูปร่างของรูพรุน ตำแหน่งของรูพรุน ขนาดของโครงสร้างเหล็ก และชนิดของเนื้อเหล็ก โดยที่ชิ้นงานจะขึ้นรูปด้วยกรรมวิธีผง โดยผลลัพธ์จากงานวิจัยได้แสดงให้เห็นว่าในโครงสร้างทางจุลภาคของเนื้อเหล็ก แบบหยาบ (Coarse Microstructure) นั้น รูปร่างและขนาดของรูพรุนจะมีผลกระทบต่อความแข็งแรงต่อการล้าของโลหะ ที่มากกว่ารูพรุนที่อยู่ในโครงสร้างจุลภาคเนื้อเหล็กแบบละเอียด (Fine Microstructure) ในสัดส่วนปริมาณรูพรุนในเนื้อเหล็กที่เท่ากัน เนื่องจากรูพรุนในโครงสร้างแบบหยาบนั้นจะเป็นตัวตั้งต้นของรอยแตก (Crack) และจุดศูนย์รวมความเค้น (Stress Concentration) ได้ดีกว่าโครงสร้างแบบละเอียด และยังเป็นตัวที่ทำให้รอยแตกที่เกิดขึ้นสามารถแพร่ขยายตัวได้อย่างรวดเร็ว

J. Park et al. [6] ได้ทำการศึกษาเหล็กกล้าคาร์บอนต่ำที่ขึ้นรูปโดยกรรมวิธีผง โดยที่ศึกษาคุณสมบัติทางกลที่ได้จากการขึ้นรูปเทียบกับชนิดของเนื้อเหล็ก และปริมาณของรูพรุนว่าส่งผลต่อค่าความต้านทานการเสียรูป (Yield Strength) ของโลหะหรือไม่ โดยที่งานวิจัยได้สรุปไว้ว่า รูพรุนนั้นส่งผลต่อความหนาแน่นของชิ้นงานที่ขึ้นรูปด้วยผง และส่งผลกระทบไปถึงค่าความแข็ง (Hardness) อย่างมีนัยสำคัญโดยวัสดุที่มีความหนาแน่นมาก ปริมาณรูพรุนจะน้อยทำให้ค่าความต้านทานการเสียรูปของวัสดุนั้นมีค่าที่สูง

2.4.2 งานวิจัยที่ศึกษาเกี่ยวกับวิธีการของการประมวลผลข้อมูลภาพ (Image Processing)

ในปัจจุบันเทคโนโลยี Image Processing ได้มีการนำมาประยุกต์ใช้ในเชิงอุตสาหกรรมโลหะ อาทิเช่น การตรวจสอบสิ่งผิดปกติ (Defect) ที่เกิดขึ้นกับผลิตภัณฑ์โดยการใช้การตรวจจับจากกล้องวงจรปิด การวิเคราะห์สิ่งเจือปน (Inclusion) ในเนื้อเหล็ก และการนับสินค้าคงคลังเพื่อลดความผิดพลาดที่เกิดขึ้นจากการปฏิบัติงานด้วยมนุษย์เป็นต้น โดยงานวิจัยที่ผู้วิจัยได้ศึกษาในหัวข้อนี้จะเกี่ยวข้องกับการประยุกต์ใช้ Image Processing เพื่อให้เห็นภาพรวมงานวิจัยที่ใช้ในอุตสาหกรรม

Y. Liu et al. [30] ได้ทำการนับผลิตภัณฑ์ท่อเหล็ก (Stainless Steel Pipe) โดยใช้เทคนิคของ Image Processing เข้ามาช่วยในการคัดแยกภาพผลิตภัณฑ์เหล็กออกจากพื้นหลังด้วยกระบวนการ Thresholding และใช้อัลกอริทึม ในการนับพื้นที่วงกลมในภาพเพื่อใช้ระบุจำนวนผลิตภัณฑ์เหล็ก ในงานวิจัยได้ประเมินความแม่นยำของแบบจำลองที่สร้างขึ้น ด้วยดัชนีความแม่นยำ (Accuracy) โดยที่ผลลัพธ์จากการประเมินอยู่ที่ 93.7%

S. J. Lee et al. [31] ได้ประยุกต์ใช้เทคนิค Deep Convolutional Neural Network (DCNN) ในการระบุหมายเลขที่เขียนอยู่บนผลิตภัณฑ์เหล็ก โดยได้ทำการเปรียบเทียบกับงานวิจัยของที่ใช้วิธีการ Median Filter Based Anisotropic Diffusion (WMFAD) จากการทดสอบตัวอักษรทั้งหมด 2,876 ตัวอักษรด้วยวิธีการ DCNN มีความผิดพลาดอยู่ที่ 63 ตัวอักษรคิดเป็นความแม่นยำอยู่ที่ 97.81% ซึ่งมากกว่าวิธี Median filter ที่มีความแม่นยำอยู่ที่ 95.41%

Z. Xinman et al. [32] ได้เสนองานวิจัยเกี่ยวกับการนับเหล็กโครงสร้างที่ทำการวิ่งอยู่ในกระบวนการผลิต โดยใช้เทคโนโลยีทางด้านการประมวลผลข้อมูลภาพ มานับจำนวนเหล็กในรูปแบบสี่เหลี่ยมผืนผ้า โดยจากงานวิจัยได้ทำการแปลงสี่เหลี่ยมผืนผ้า เป็นรูปภาพและใช้วิธีการของ Canny ในการแยกเส้นเหล็กโครงสร้างเพื่อที่จะทำการนับด้วยวิธีการของ Hough Line Detection โดยค่าความแม่นยำของการนับจากงานวิจัยระบุไว้อยู่ที่ 100%

L. Xiaohu and O. Jineng [33] นำเสนองานวิจัยที่ใช้ อัลกอริทึมที่ใช้เทคนิคของ Otsu Binarization มาใช้ในการแยกตัวเหล็กที่ต้องการจะนับแยกออกจากภาพพื้นหลัง และใช้อัลกอริทึมของการสร้างเส้นรอบวง (Contour) มาช่วยในการหาจุดศูนย์กลางของตัวเหล็กที่จะนับจากรูป จากงานวิจัยความแม่นยำของวิธีการประยุกต์ใช้เส้นรอบวงในการนับเหล็กอยู่ที่ 98% โดยใช้เวลาในการประมวลผลน้อยกว่า 2 วินาที

X. Yan and X. Chen [34] ได้นำเสนออัลกอริทึม ที่ช่วยในการเพิ่มประสิทธิภาพการนับเหล็กเส้นโดยงานวิจัยมีจุดมุ่งเน้นในการแก้ปัญหาไม่สามารถแยกเหล็กเส้นออกจากกัน อันเนื่องมาจากการที่รูปของเหล็กเส้นนั้นติดกัน โดยหลังจากการทำ Image Segmentation ด้วยเทคนิคของ Otsu Threshold จากหลักการทำงานของอัลกอริทึม ที่งานวิจัยได้นำเสนอนั้นจะเป็นการสร้างสัมประสิทธิ์ (K) โดยคำนวณอัตราส่วนของพื้นที่วงกลมที่จะพิจารณาการนับ (Si) เทียบกับค่าเฉลี่ยของพื้นที่วงกลมโดยรวม (S_i) โดยสมการที่ใช้ $K = \frac{S_i}{S_o}$ โดยที่ค่าสัมประสิทธิ์ K จะใช้บ่งบอกว่าตำแหน่งพื้นที่ที่พิจารณาอยู่เป็นตัวรบกวน (Noise) รูปเหล็กเส้นจำนวนหนึ่งเส้น หรือเหล็กเส้นที่มีการติดกัน ในกรณีที่เหล็กเส้นที่ติดกันจะใช้การคำนวณรัศมี ในการบ่งบอกถึงปริมาณของเหล็กที่ติดกันเพื่อเพิ่มความแม่นยำในการนับ โดยจากงานวิจัยมีในการนับเหล็กเส้นที่ปริมาณ 510 เส้น มีความแม่นยำอยู่ที่ 99.80%

2.4.3 งานวิจัยที่ศึกษาเกี่ยวกับการนำการเรียนรู้เชิงลึก (Deep Learning) มาใช้ในการคัดแยก รูปภาพ

ในปัจจุบันได้มีการนำเทคนิค Deep Learning เข้ามาประยุกต์ใช้ในการคัดแยกรูปภาพ ในอุตสาหกรรมที่หลากหลายมากยิ่งขึ้นไม่ว่าจะเป็นการใช้ในการคัดแยกและตรวจจับของเสียในกระบวนการผลิต หรือ การตรวจจับใบหน้าของลูกค้าในร้านสะดวกซื้อ เป็นต้น โดยลักษณะที่นำมาใช้มีทั้งแบบ Supervised Learning และ Unsupervised Learning ขึ้นอยู่กับจุดประสงค์ของงานนั้นๆ ซึ่งในปัจจุบันได้มีการใช้ Software สำเร็จรูป หรือ Open Source ที่ใช้ในการทำ Deep Learning อย่างแพร่หลาย ดังนั้นในหัวข้อนี้ทางผู้วิจัยได้มุ่งเน้น ศึกษางานวิจัยที่มีการนำอัลกอริทึมของ Deep Learning มาใช้ในการทำการคัดแยกรูปภาพหรือการรู้จำแบบ (Pattern Recognition)

V. Aggarwal and G. Kaur [35] ได้ตีพิมพ์งานวิจัย ที่ทำการทบทวนเกี่ยวกับ แนวคิด ที่นำ Convolution Neural Network (CNN) มาประยุกต์ใช้ในการทำการคัดแยกรูปภาพ งานวิจัยได้ทำการเปรียบเทียบความแม่นยำ ที่เกิดจากวิธีการของ Deep Learning ที่ต่างกัน และงานวิจัยได้ทำการทบทวนการประยุกต์ De-Noising Convolutional Network (DnCNN) ด้วยเทคนิค Batch Normalization และ Residual ซึ่งผลจากการทบทวนทางผู้วิจัยได้ให้ข้อสังเกตว่า ในปัจจุบันยังไม่มีเทคนิคไหนที่ดีที่สุด โดยที่ขึ้นอยู่กับรูปแบบของชุดข้อมูล โดยงานวิจัยที่ถูกนำมาเปรียบเทียบแสดงให้เห็นในตารางที่ 2.3

Paper name	Dataset	DL Network	Learning technique	Accuracy
Zhang K (2017)	BSD68	DnCNN ¹	Batch Normalization	82%
Kolsch A (2017)	TOBACCO-3482	ELM ²	Transfer Learning	83.25%
He K (2016)	CIFAR-10	DnCNN	Residual	85%
Liu P (2015)	CIFAR-10	CNN ³	Supervised	88%
Jaswal D (2014)	UCML	CNN	Unsupervised	93.18%

¹Denoising Convolutional Neural Network (DnCNN)

²Extreme Learning Machine (ELM)

³Convolution Neural Network (CNN)

รูปที่ 2.23 ค่าผลลัพธ์การเปรียบเทียบความแม่นยำของ CNN จากงานวิจัยของ Vishali [35]

D. Bhamare and P. Suryawanshi [36] ได้ทำการทบทวนงานวิจัยที่เกี่ยวกับ Pattern Recognition ทั้งแบบ Supervised Learning และ Unsupervised Learning โดยที่ผู้วิจัยได้ทำการนำงานวิจัยที่ตีพิมพ์ในช่วง 2014-2017 จำนวน 33 ฉบับ มาทำการทบทวน และเปรียบเทียบหลักการ ทำงานในแต่ละฉบับ โดยผลจากการทบทวนทางผู้วิจัยได้สรุปว่า รูปแบบการทำ Invariant Pattern Recognition เป็นที่ต้องการ อาทิเช่น การหารูปแบบของตัวอักษร หรือ ใบหน้า โดยแนวโน้มการเพิ่มความแม่นยำของการระบุตัวตน และการตรวจสอบ จะใช้รูปแบบของ Machine Learning ที่หลากหลายมากขึ้น โดยงานวิจัยที่ถูกนำมาเปรียบเทียบจะแสดง ให้เห็นในรูปที่ 2.24

Reference	Technique	System requirement	Results	Conclusion
D'Addona DM et al. [8]	Artificial neural network (ANN) and DNA-based computing	MATLAB	The error is a bit more than 1% for the SGB image set	ANN and DBC, can be used to reduce unnecessary time and volume of information while solving complex computation problems
Gao G et al. [9]	Robust and discriminative low-rank representation (RDLRR) with a simple linear multi-classifier	Yale B data base, Multi-PIE database	Occlusion level is 40%. RDLRR always achieves stable performance when α varies from 0.1 to 1	RDLRR was robust to corruptions: illumination changes, real disguise and block occlusion, and yielded better performances
Iwana BK et al. [10]	dynamic time warping (DTW) based Dissimilarity space embedding (DSE)	UNIPEN on-line handwriting data set	average of $96.67 \pm 4.38\%$	DTW-based distance measure can be classified with a high accuracy and low prototype count
Mage L et al. [11]	Hierarchical clustering; classification tree	197 DSC curves	85% of critical compounds were correctly identified	predictive modelling was improved by the graphical clustering
Naz S et al. [12]	CNN and MDLSTM	UPTI dataset	recognition rate is 98.12%	The combination of CNN and MDLSTM proved to be an effective feature extraction method
Uhlmann E et al. [13]	SLM machine. Nearest Neighbour, Bayes Classifier, Neural Network, and Support Vector Machine (SVM), k-mean algorithms	CMT tool	The Bayes Classifier, due to the achieved accuracy of 63%	The result showed that an automatic classification for the SLM machine is possible
Peralta D et al. [14]	CNN, DNN	Intel Core i7-3820 processor (3.60 GHz) and 24GB RAM. The CNNs were run on a single Nvidia GeForce GTX TITAN GPU (2688 cores, 6144 MB GDDR5 RAM). Data base: SFinGe, NIST-DB4	the proposed network obtains 99.60% accuracy	The robustness experiments also showed that the deep learning strategy was able to obtain a very high test accuracy
Chatterjee A et al. [15]	bio speckle analysis, visuo-numeric algorithm, 3D sensor, MSF* and non-normalized histogram techniques	MATLAB		Overall the proposed technique is very simple, fast, low cost and full field
Peralta D et al. [16]	AFIS with hierarchical classification	SFinGe, NIST-SD4, NIST-SD14	Classification accuracy For Segmented 0.9376 For Not segmented 0.9189	The results obtained over several databases highlight the very good classification accuracy obtained by the proposal, while eliminating the rejection rate
Zeng Y et al. [17]	DP-KELM, kernel-based extreme learning machine (KELM) classifier with deep perceptual features	8 Intel(R) Xeon(R) E5-2643 CPUs (3.30 GHz), 12 GB DDR4	Recognition rate is 99.54%	The proposed method uses a relatively simple architecture that reduces the computation cost
Muhammad Jamal Afridi et al. [18]	Deep Learning Technique in Convolutional Neural Networks	Standard MNIST, Places-MIT Databases	Performance percentage is 60.1% with 5% of selected training data	The Efficiency of ranking source CNNs was improved by proposed Information Theoretic Framework
Olfa Ben Ahmed et al. [19]	Multiple Kernel Learning Technique	ADNI Datasets	Classification accuracies for AD versus NC-90.2%, MCI versus NC-79.42% and AD versus MCI-76.63%	Substantial enhancement of accuracy could be achieved for recognition of AD by MKL
ZeyadHailat et al. [20]	Unsupervised machine learning with McMFL method	Benchmark Facial Datasets includes AR, Yale, PubFig83 Datasets	Recognition percentage for AR-95.04%, Yale-98.97%, PubFig83-95.85%	The discriminative features in object recognition problems were determined and the recognition rates could be improved by McMFL method
RanaAamir Raza Ashfaq et al. [21]	Fuzziness Based Semi-Supervised Machine Learning Technique	NSL-KDD Dataset	Testing accuracies for KDD test+ = 84.12%, KDD test 21- = 68.82%	The performance of the classifier for Intrusion Detection system could be improved by FSSLA

รูปที่ 2.24 ข้อมูลผลลัพธ์การเปรียบเทียบความแม่นยำ CNN จากงานวิจัยของ Deyani [36]

Reference	Technique	System requirement	Results	Conclusion
Philippe Burlina et al. [22]	Transfer Learning in associate with Deep Learning technique	NIH-AREDS Dataset	Accuracy (i) for Machine Class4-79.4%,class3-81.5%, class2-93.4% (ii) for physician grading Class 4-75.8%, class 3-85%, class 2-93.4%	The accuracy of the Classification problem of ARIA and AMD analysis were improved using the application of transfer learning technique
James H Cole et al. [23]	Predictive Modelling Approach Based on Deep Learning	Large, multi-site BAHG dataset	RMS Error for Gray Matter (GM) - 5.31, White Matter (WM)-6.54, GM + WM-5.67, Raw-6.46	The accuracy of CNN brain-predicted age with reduced computation time could be achieved using PMA
Xieping-Gao et al. [24]	Hidden Markov Tree Model of Dual-tree Complex Wavelet Transform with Genetic Algorithm	Nijmegen, MIAS, DDSM Datasets	AUC for Nijmegen-0.9856, MIAS-0.9941, DDSM-0.9168	The accuracy and stability could be improved by DTCWT-HMT using Genetic Algorithm for Micro-calcification Diagnosis problem
JananiKalyanam et al. [25]	Unsupervised Machine Learning Technique	TwitterSpherePublic API	Totally 84.2% of tweets are observed and tested	The process of carrying out the unwanted tweets from the TwitterSphere Public API could be achieved by proposed method
Mohamed Layounit et al. [26]	Pattern Adapted Wavelets for the detection and sizing of metal-loss defects	MATLAB	Length Prediction Accuracy-90% Depth Prediction Accuracy-90%	The estimation of length and depth of metal-loss defects could be achieved with high accuracy using PAW
David M Schnyer et al. [27]	Support Vector Machine Learning Technique	Right Hemisphere Whole Brain FA map with eight datasets	Total Accuracy-74.0% with 80% Specificity and 68% Sensitivity	The classification of adults with MDD and HC could be achieved by SVM with high accuracy

รูปที่ 2.24 ข้อมูลผลลัพธ์การเปรียบเทียบความแม่นยำ CNN จากงานวิจัยของ Deyani (ต่อ) [36]

2.4.4 งานวิจัยที่มีแนวทางการประยุกต์วิธีการที่ใกล้เคียงกันกับงานประเภทอื่น

ในหัวข้อนี้ทางผู้วิจัยได้ทำการศึกษางานวิจัยที่มีการประยุกต์ใช้แนวความคิดที่ใกล้เคียงกัน โดยผู้วิจัยมุ่งเน้นการศึกษางานวิจัยไปทางด้าน ธรณีศาสตร์ (Geology Science) ที่มีการนำศึกษารูพรุนที่อยู่ในชั้นดิน หรือชั้นหิน โดยมุ่งเน้นงานวิจัยที่มีการประยุกต์เทคโนโลยีเกี่ยวกับการนำ Image Processing และ Deep Learning เข้าไปช่วยในการวิเคราะห์ เพื่อทำการศึกษาวิธีการดำเนินงานวิจัย และตัวชี้วัดที่ใช้ในการประเมิน

R. Arnay et al [37] ได้ทำการศึกษาวิจัยโดยมีจุดประสงค์เพื่อที่จะทำ การคัดแยกประเภทของลักษณะรูพรุนหรือช่องว่างในชั้นหิน โดยใช้ Convolutional Neural Network (CNN) มาสร้างการเรียนรู้และคัดแยกประเภทของช่องว่างในชั้นหิน โดยการนำภาพถ่ายทางจุลภาคที่มีรูพรุนอยู่ข้างในที่มีขนาด 600X400 ถึง 4416X3312 Pixels มาทำการแบ่งออกเป็นภาพย่อยที่มีขนาด 224X224 Pixels เพื่อสร้างการเรียนรู้ โดยวิธีในงานวิจัยได้ทำการเปรียบเทียบรูปแบบการทำ Training Data ไว้ 2 วิธีคือ วิธีที่หนึ่งใช้ภาพย่อยที่มาจากภาพเดิมชุดเดียวกัน ในการทำ Training และ Testing Data และวิธีที่สองใช้ที่ใช้ในการทำ Training และ Testing Data ที่มาจากภาพคนละชุดกัน โดยจากงานวิจัยพบว่าวิธีที่หนึ่ง มีความแม่นยำในการทำนายมากกว่า โดยมีความแม่นยำอยู่ที่ 98% ส่วนวิธีที่สองจะได้ความแม่นยำที่น้อยกว่า ซึ่งมีความแม่นยำอยู่ที่ 88%

M. Abedini et al. [38] ต้องการที่จะทำการเปรียบเทียบการใช้ Neural Network ของการทำ Deep Learning ที่มีอัลกอริทึมที่ต่างกันไปใช้ในการคัดแยกรูพรุนของดิน โดยงานวิจัยได้เลือกมา 2 วิธี คือ Back Propagation Network (BPN) และ Stack Auto Encoder (SAE) โดยที่ได้

ทำการแบ่งประเภทของรูปพรุน ออกเป็น 6 ประเภทจากคุณสมบัติทั้งหมด 13 ลักษณะ โดยชุดข้อมูลที่ใช้ในการสร้างการเรียนรู้แบ่งออกเป็น Training Data จำนวน 682 รูป และ Testing Data จำนวน 278 รูป งานวิจัยเลือกใช้เครื่องมือ Confusion Matrix มาใช้ในการประเมินการคัดแยกชนิดของรูปพรุนทั้ง 6 ประเภท พบว่าวิธีการเรียนรู้แบบ SAE สามารถสร้างแบบจำลองที่มีความแม่นยำในการคัดแยกรูปพรุนได้ดีกว่าแบบ BPN ซึ่งความแม่นยำของ SAE อยู่ที่ 96.4% ส่วน BPN อยู่ที่ 94.6%

F. Bordignon et al. [39] ต้องการที่จะนำเสนอการนำ Deep Learning ไปประยุกต์ใช้ในการวัดขนาดเนื้อดิน และการกระจายตัวของรูปพรุนในเนื้อดิน โดยใช้ภาพจำลอง 3 มิติจากโปรแกรมมาทำการสร้างกระบวนการเรียนรู้ เพื่อที่จะนำมาใช้ในการวัดขนาด และการกระจายตัวของรูปพรุนของภาพถ่ายโครงสร้างทางจุลภาค โดยงานวิจัยได้เลือก CNN มาใช้ในการสร้างกระบวนการเรียนรู้ โดยขั้นตอนแรกได้ทำการสร้างภาพจำลองรูปพรุน ที่มีขนาดต่างกันจำนวน 20,000 รูปโดยมีขนาดของรูปภาพอยู่ที่ 64X64X64 Pixels มาทำเป็น Training Data และใช้ภาพถ่ายชั้นดิน จำนวน 5,000 ภาพ โดยมีขนาดรูปภาพอยู่ที่ 512X512X512 Pixels มาทำเป็น Testing data และใช้ Histogram มาช่วยในการประเมินผล โดยผลลัพธ์จากการทำ Histogram วิธีการสร้างภาพจำลองสามมิติ ของผู้วิจัยมีผลลัพธ์ใกล้เคียงกับต้นฉบับงานวิจัยที่ถูกนำมาอ้างอิง

จากงานวิจัยที่กล่าวไปข้างต้น สามารถสรุปเทคโนโลยีที่มีการนำ Image Processing และ Deep learning มาประยุกต์ใช้ตามตารางที่ 2.5 โดยจะเห็นได้ว่าความแม่นยำ ในแต่ละงานวิจัยมีค่ามากกว่า 90% ดังนั้นจากข้อมูล ทางผู้วิจัยจึงตั้งสมมุติฐานว่าการทำ Image Processing และ Deep Learning สามารถนำมาใช้ในการคัดแยก และประเมินรูปแบบรูปพรุนในงานโลหะผง ที่ทางผู้วิจัยจะดำเนินการได้

TNI

TAHITI - NICHII INSTITUTE OF TECHNOLOGY

ตารางที่ 2.3 การเปรียบเทียบงานวิจัยที่ประยุกต์ใช้การประมวลผลข้อมูลภาพกับรูปพรุนในงานทางด้านธรณีวิทยา

No.	Topic	Publish Year	จุดประสงค์	Image processing technique	Deep learning technique	Number of Data set	Development Tool	Accuracy
1	Soil micromorphological image classification using deep learning: The porosity parameter	Jan-21	ทำการคัดแยกประเภทของลักษณะรูพรุนหรือช่องว่างในชั้นหิน โดยใช้ CNN มาใช้ในการสร้างการเรียนรู้และคัดแยกประเภทของช่องว่างในชั้นหิน	- Data augmentation	CNN	Training data: 1500 รูป (224X224 pixels) Testing data: อยู่ที่ 114-1500 รูป (224X224) ขึ้นอยู่กับประเภทรูพรุน	LabelMe tool Tensorflow Keras	Confusion matrix สูงสุด 98% ต่ำสุด 88%
2	Porosity classification from thin sections using image analysis and neural networks including shallow and deep learning in Jahrum formation	Jan-18	นำเสนอการใช้ Neural network ในการแยกลักษณะของรูพรุนในดินโดยทำการเปรียบเทียบระหว่าง BPN (Back-propagation network) และ SAE (Stacked autoencoder)	- Median filter - Dilate - Erode	BPN SAE	Training data: 682 รูป Testing data: 278 รูป	Image Pro Plus สำหรับ Feature extraction	ความแม่นยำ (Accuracy) BPN : 94.60% SAE : 96.04%
3	Deep learning for grain size and porosity distributions estimation on micro-CT images	Aug-18	นำเสนอการทำ Deep learning ไปประยุกต์ใช้ในการศึกษาขนาดของเนื้อดิน การกระจายตัวของรูพรุน โดยใช้ภาพจำลองภาพ 3 มิติจากโปรแกรมมาสร้างแบบจำลองการทำนาย ภาพถ่ายดินจริง	- Thresholding โดยใช้ Histogram	CNN	Training data: ภาพที่ 3D ใช้ในการทำ Training data (จากโปรแกรม): 20000 รูป (64X64X64 pixels) Testing data: 5000 รูป (512X512X512 pixels)	Keras Tensorflow	ใช้ Histogram ในการประเมิน แต่ไม่ได้ระบุความแม่นยำ

บทที่ 3

วิธีดำเนินงานวิจัย


ในกระบวนการเตรียมชิ้นงานเพื่อทำการถ่ายภาพโครงสร้างทางจุลภาคของโลหะผงนั้น ทางผู้ปฏิบัติการในห้องวิจัยต้องทำการนำชิ้นงานผ่านกระบวนการขัดหยาบ (Grinding) ด้วยกระดาษทรายน้ำ แล้ว หลังจากนั้นจึงทำการขัดละเอียด (Polishing) ด้วยผงอลูมินา (Alumina Powder) เพื่อให้รอยขีดบนหน้าชิ้นงานโลหะมีรอยที่เกิดจากการขัดให้น้อยที่สุด ดังที่แสดงในรูปที่ 3.1 ดังนั้นเพื่อลดปัญหาที่เกิดจากระบวนการขัด อาทิเช่น รอยขีดที่หลงเหลือจากกระบวนการเตรียมชิ้นงาน รอยน้ำที่เกิดจากการขัด และ ความไม่ชัดของภาพอันเนื่องจากการขัดผิวโลหะที่ไม่ได้ระนาบ ดังนั้นผู้วิจัยจึงได้มีการกระบวนการทำ Image Pre Processing เพื่อทำการลดความผิดพลาดจากกระบวนการเตรียมชิ้นงานก่อนที่จะนำรูปภาพโครงสร้างทางจุลภาคไปทำกระบวนการเรียนรู้ของเครื่อง



รูปที่ 3.1 ขั้นตอนการเตรียมชิ้นงานโลหะเพื่อทำการส่องดูภาพผ่านกล้องจุลทรรศน์

โดยเนื้อหารายละเอียดขั้นตอนการดำเนินงานวิจัยเบื้องต้นดังที่แสดงใน Flow Chart ดังรูปที่ 3.2 โดยกระบวนการในงานวิจัยจะแบ่งออกเป็นขั้นตอนหลัก 4 ขั้นตอนได้แก่

- 3.1 ขั้นตอนการเตรียมชุดข้อมูล และประมวลผลข้อมูลภาพ
- 3.2 ขั้นตอนการทำการระบุประเภทข้อมูลภาพโดยมนุษย์ (Labeling Process)
- 3.3 ขั้นตอนการสร้างแบบจำลองการเรียนรู้ (Deep Learning Model)
- 3.4 ขั้นตอนการประเมินผล (Evaluation)




รูปที่ 3.2 Flow Chart ภาพรวมขั้นตอนการทำงานวิจัย

3.1 ขั้นตอนการเตรียมชุดข้อมูล และประมวลผลข้อมูลภาพ

3.1.1 ชุดข้อมูลภาพ (Image Dataset)

ชุดข้อมูลภาพโครงสร้างทางจุลภาคทางผู้วิจัยได้รับความอนุเคราะห์จากทางบริษัท Acme International (Thailand) Ltd. โดยข้อมูลประกอบไปด้วยภาพถ่ายโครงสร้างทางจุลภาคของชิ้นงานโลหะ ประเภทเหล็กกล้าคาร์บอนต่ำ (Low Carbon Steel) ที่ผ่านกระบวนการขึ้นรูปโดยกรรมวิธีโลหะผง จำนวนทั้งหมด 175 รูป โดยรูปภาพจะมีขนาดกำลังขยายอยู่ที่ 100 เท่า (100X) มีความละเอียดภาพถ่าย (Resolution) อยู่ที่ 3656x2740 Pixel และมีค่า DPI (Dots per inch) อยู่ที่ 96 DPI โดยองค์ประกอบของภาพโครงสร้างทางจุลภาค จะประกอบไปด้วยรูพรุน (สีดำ) เนื้อเหล็ก (สีขาว) และสิ่งผิดปกติ (Noise) ที่เกิดขึ้นจากกระบวนการเตรียมชิ้นงาน อาทิเช่น คราบน้ำ รอยขีดของกระดาษทราย และภาพสะท้อนจากแสงไฟภายในห้องที่ทำการถ่ายภาพ โดยสิ่งผิดปกติในตัวอย่างจำเป็นต้องผ่าน กระบวนการประมวลผลข้อมูลภาพเพื่อกำจัดองค์ประกอบที่ไม่จำเป็นของภาพออก ตัวอย่างของสิ่งผิดปกติที่เกิดขึ้นในกระบวนการเตรียมชิ้นงานจะแสดงในรูปที่ 3.3




รูปที่ 3.3 ตัวอย่างรูปภาพความผิดปกติที่เกิดจากกระบวนการเตรียมชิ้นงาน


3.1.2 การประมวลผลข้อมูลภาพ (Image Processing)

ในกระบวนการประมวลผลข้อมูลภาพ ภาพจะถูกทำการตัดองค์ประกอบที่ผิดปกติในภาพ อาทิเช่น รอยขีด คราบน้ำจากกระบวนการขัด ดังที่กล่าวไว้ในหัวข้อ 3.1.1 โดยองค์ประกอบวัตถุที่สำคัญของภาพที่ใช้ในการประเมิน คุณภาพของ Sintering Neck คือ เนื้อเหล็กส่วนที่เป็นสีขาวในรูปภาพ และรูพรุนส่วนที่มีลักษณะสีดำในรูปภาพ ดังที่แสดงในรูปที่ 3.4 ดังนั้นกระบวนการ Binarization จึงถูกนำมาใช้เพื่อใช้ในการตัดองค์ประกอบของภาพที่ไม่จำเป็น โดยจะทำการเปลี่ยนภาพถ่ายโครงสร้างทางจุลภาค จากภาพสี (RGB) เป็นภาพขาวดำ(Binary Image) ด้วยกรรมวิธี Adaptive Thresholding

ผ่านโปรแกรม Matlab ที่ค่า Sensitivity(I) = 0.5 โดยที่สิ่งผิดปกติโดยทั่วไป จะมีค่าความเข้มสี (Intensity) ที่ต่ำกว่ารูปพรุน โดยภาพหลังจากการทำ Binarization สิ่งผิดปกติ จะถูกประเมินเป็นในส่วนของเนื้อเหล็ก ดังที่แสดงในรูปที่ 3.5 ซึ่งตรงกับหลักความเป็นจริงที่สิ่งผิดปกติจะเกิดขึ้นที่ตำแหน่งของเนื้อเหล็ก ไม่ได้เกิดขึ้นที่ตำแหน่งของรูปพรุน



รูปที่ 3.4 รายละเอียดองค์ประกอบที่สำคัญของภาพ



ภาพดั้งเดิมก่อนทำ Binarization

ภาพหลังการทำ Binarization

รูปที่ 3.5 ตัวอย่างภาพก่อนและหลังการทำ Binarization

3.2 ขั้นตอนการทำการระบุประเภทข้อมูลภาพโดยมนุษย์ (Labeling Process)

ในขั้นตอนนี้ภาพโครงสร้างทางจุลภาค ที่มีความละเอียด 3656x2740 Pixel จะถูกลดขนาดลงเหลือ 3584x2688 Pixel หลังจากนั้น จะถูกแบ่งจากภาพย่อย ออกเป็นทั้งหมด 12 ภาพ ซึ่งได้รับคำแนะนำจากผู้เชี่ยวชาญว่าการแบ่งจากภาพใหญ่ออกมาเป็นภาพย่อย 12 ภาพ จะทำให้สามารถประเมินคุณภาพของ Sintering Neck จากลักษณะของรูพรุนได้มีประสิทธิภาพ โดยที่ขนาดของภาพจะไม่เล็กลงเกินไป จนทำให้ไม่สามารถประเมินคุณภาพของ Sintering Neck ได้โดยภาพหลังจากที่ทำการแบ่งจะมีความละเอียดอยู่ที่ 896x896 Pixel โดยภาพจะถูกนำไปประเมินคุณภาพของ Sintering Neck โดยผู้เชี่ยวชาญทางด้านโลหะวิทยา เพื่อลดความเอนเอียง (Bias) ของข้อมูลทางผู้วิจัยได้ให้ผู้เชี่ยวชาญ 3 คน ที่มีประสบการณ์ทำงานในสายงานทางด้านโลหวิทยามากกว่า 3 ปี เป็นผู้ประเมินภาพ โดยคุณภาพของ Sintering Neck ในงานวิจัยได้แบ่งระดับคุณภาพ ออกเป็น 3 ประเภท ได้แก่ ประเภทรูพรุนที่ทำให้เกิด Sintering Neck ที่หลอมรวมได้ไม่ดี โดยในงานวิจัยจะนิยามว่า “รูพรุนที่ไม่ดี (Not Good)” ประเภทรูพรุนที่ทำให้เกิด Sintering Neck ที่หลอมรวมได้ดี โดยในงานวิจัยจะนิยามว่า “รูพรุนที่ดี (Good)” และประเภทรูพรุนที่ทำให้เกิด Sintering Neck ที่หลอมรวมได้ดีมาก โดยในงานวิจัยจะนิยามว่า “รูพรุนที่ดีมาก (Very Good)” เพื่อให้สอดคล้องความเข้าใจ โดยใช้ตัวอย่างภาพการประเมินแบบเดียวกันตาม Guideline ที่ได้รับคำแนะนำจากทางบริษัท Höganäs AB รูปที่ 3.6 เพื่อใช้เป็นชุดข้อมูลในการสร้างแบบจำลองการเรียนรู้ในลำดับถัดไป



รูปที่ 3.6 รูปภาพตัวอย่าง Guideline สำหรับใช้ในการประเมิน

นอกจากนี้ทางผู้วิจัยได้นำชุดข้อมูลภาพชุดเดียวกันไปให้พนักงานในห้องปฏิบัติการ ที่มีอายุการทำงานด้านสายงานโลหะวิทยาน้อยกว่า 2 ปี จำนวน 2 คน มาทำการประเมินเพิ่มเติม เพื่อใช้ในการศึกษาประสิทธิภาพของผู้ประเมินนั้นมีผลต่อความแม่นยำ (Accuracy) ของแบบจำลองที่ถูกสร้างขึ้นหรือไม่

3.3 ขั้นตอนการสร้างแบบจำลองการเรียนรู้ (Deep Learning Model)

หลังจากที่ชุดข้อมูลภาพได้ถูกทำการประเมินจากผู้เชี่ยวชาญจำนวน 3 คน และพนักงานห้องปฏิบัติการจำนวน 2 คน ได้ถูกมาสร้างแบบจำลอง (Model) โดยแบ่งออกเป็น 2 กรณีดังนี้

กรณีที่ 1 แบบจำลองที่ถูกสร้างจากผู้เชี่ยวชาญ

กรณีที่ 2 แบบจำลองที่ถูกสร้างจากผู้เชี่ยวชาญ และ พนักงานปฏิบัติการ

3.3.1 การสร้างแบบจำลองการเรียนรู้จากผู้เชี่ยวชาญ


ผลลัพธ์ภาพที่ผ่านการทำ Labeling จากผู้เชี่ยวชาญดังตารางที่ 3.1 โดยภาพที่ผู้เชี่ยวชาญให้ความเห็นเหมือนกันทั้ง 3 คน ในงานวิจัยนี้จะนิยามว่าภาพที่มิติ “เอกฉันท์” โดยภาพจะถูกทำการ Augmentation ที่ 90° 180° และ 270° โดยภาพหลังผ่านกระบวนการ Augmentation จะมีจำนวนอยู่ที่ 2,864 ภาพ

ตารางที่ 3.1 จำนวนรูปภาพที่ใช้ในการทำ Training Model ในกรณี 3.3.1


Class	Expert 1	Expert 2	Expert 3	Same Vote	Data Augmented
1. Not Good	478	1,758	1,274	463	1,852
2. Good	1,538	258	685	169	676
3. Very Good	84	84	141	84	336
Total	2,100	2,100	2,100	716	2,864

หลังจากนั้นภาพที่มีความเห็นของผู้เชี่ยวชาญที่เหมือนกันทั้ง 3 คนหลังจากการทำ Augmentation จะถูกนำเข้ากระบวนการเรียนรู้เชิงลึก Deep Learning ทั้งหมด 5 อัลกอริทึม ได้แก่ Resnet-50, Resnet-101, Xception, Inception-V3 ที่มีค่าความแม่นยำที่สูงและใช้ทรัพยากรในการประมวลผลไม่มากโดยอ้างอิงจากงานวิจัยของ S. Bianco et al. [40] และ GoogLeNet ที่ใช้เวลาในการประมวลผลและทรัพยากรที่น้อย เมื่อเทียบกับ Deep Learning รูปแบบอื่น เหมาะสำหรับการทดสอบว่ากระบวนการ Coding นั้นเกิด ข้อผิดพลาดหรือไม่ โดยการสร้างแบบจำลอง Training

Model ของ Deep Learning ทั้ง 5 รูปแบบ จะถูกสร้างผ่านโปรแกรม Matlab โดยตั้งค่า Learning Rate อยู่ที่ 0.01 และค่า Mini Batch Size อยู่ที่ 32 โดยชุดข้อมูลจะแบ่งการเรียนรู้ ออกเป็นทั้งหมด 4 ชุด Training 3 ชุด และ Validation 1 ชุด โดยใช้การคัดเลือกแบบสุ่ม (Random) เพื่อป้องกันการ Bias ของข้อมูล แล้วจึงทำการ Training Model เป็นจำนวนทั้งหมด 4 รอบ ดังที่แสดงในรูปที่ 3.7 โดยที่ Deep Learning Architecture และ Activation Function ที่ใช้จะแสดงในรูปที่ 3.8



รูปที่ 3.7 รูปแบบการทำ K-Fold Cross Validation



รูปที่ 3.8 รูปโครงสร้าง Architecture และ Activation Function ที่ใช้ในการสร้างแบบจำลอง

นอกจากแบบจำลองที่ถูกสร้างโดยจากผู้เชี่ยวชาญทางด้านโลหะวิทยาเป็นหลักแล้วนั้น ทางผู้วิจัยยังต้องการศึกษาเพิ่มเติม *นอกเหนือจากวัตถุประสงค์หลัก ในสมมุติฐานเกี่ยวกับประสบการณ์ของผู้ที่นำมาเป็นต้นแบบการสร้างแบบจำลอง Deep Learning นั้นมีผลต่อประสิทธิภาพของแบบจำลองหรือไม่ ดังนั้นจึงได้ทำการสร้างแบบจำลองด้วยการเพิ่มผลการประเมินจากพนักงานปฏิบัติการจำนวน 2 คนที่มีอายุการทำงานน้อยกว่า 2 ปี เข้ามาช่วยประเมินภาพเพื่อใช้ในการสร้างแบบจำลอง โดยสรุปแล้วผู้ประเมินแบบจำลองจะมีทั้งหมด 5 คน แบ่งออกเป็นผู้เชี่ยวชาญ 3 คน พนักงานปฏิบัติการ 2 คน

3.3.2 การสร้างแบบจำลองการเรียนรู้จากผู้เชี่ยวชาญ และพนักงานห้องปฏิบัติการ*

ผลลัพธ์ภาพที่ผ่านการทำ Labeling เพิ่มเติมจากพนักงานปฏิบัติการจำนวน 2 คน รวมกับผู้เชี่ยวชาญอีก 3 คน จะถูกแสดงในตารางที่ 6 โดยในขั้นตอนนี้ ภาพที่ถูกนำไปใช้ในการสร้างแบบจำลองจะเลือกภาพที่มีความน่าจะเป็น 80% กล่าวคือมีความคิดเห็นเหมือนกันอย่างน้อย 4 คน จาก 5 คน เนื่องจากในกรณีนี้เอกฉันท์ที่เหมือนกัน 5 คนนั้นมีจำนวนภาพน้อยมาก โดยขั้นตอนการสร้างแบบจำลองนั้นยังเหมือนกับ กรณีในหัวข้อ 3.3.1 ที่ใช้เพียงผู้เชี่ยวชาญจำนวน 3 คน

ตารางที่ 3.2 จำนวนรูปภาพที่ใช้ในการทำ Training Model ในกรณี 3.3.2

Class	Expert 1	Expert 2	Expert 3	Operator 1	Operator 2	Same Vote (>= 4/5)	Data Augmented
1. Not Good	478	1,758	1,274	1,927	1,945	1,248	4,992
2. Good	1,538	258	685	89	96	142	568
3. Very Good	84	84	141	84	59	84	336
Total	2,100	2,100	2,100	2,100	2,100	1,474	5,896

3.4 ขั้นตอนการประเมินผล (Evaluation)

โดยการวัดผลของการเรียนรู้เชิงลึกนั้น จะถูกประเมินด้วยค่า %Accuracy, %Precision, %Sensitivity, Specificity และ F1-Score เพื่อใช้ในการวิเคราะห์แบบจำลองการเรียนรู้เชิงลึก ผ่านเครื่องมือ Confusion Matrix และเวลาที่ใช้ในการสร้างการเรียนรู้ในแต่ละกลไกของ Deep Learning โดยใช้ชุดข้อมูลทดสอบ (Testing Set) แบ่งลักษณะข้อมูลออกเป็น 2 ชุด ดังนี้

3.4.1 ชุดข้อมูลทดสอบที่ใช้ทดสอบแบบจำลองที่สร้างด้วยผู้เชี่ยวชาญ 3 คน

โดยแบ่ง Testing Data Set ออกมาเป็น 2 ส่วน ได้แก่

3.4.1.1 Testing Data Set ที่มีความเอกฉันท์ กล่าวคือ เป็นชุดข้อมูลภาพที่ ผู้เชี่ยวชาญ ได้ให้ความเห็นเหมือนกัน ทั้งหมด 3 คน โดยมีทั้งหมดจำนวน 282 รูป แบ่งเป็นออกเป็น รูปภาพของ รุพรุ่นที่ไม่ดีจำนวน 169 รูป รุพรุ่นที่ดี 65 รูป และรุพรุ่นที่ดีมากจำนวน 48 รูป ดังที่แสดงให้เห็นใน ตารางที่ 3.3

ตารางที่ 3.3 จำนวนรูปภาพที่ใช้ในการทดสอบ Testing Model ในกรณี 3.4.1.1

Type (Probability)	Not Good	Good	Very Good
ความเห็นเอกฉันท์ (1)	169	65	48
Total	169	65	48

3.4.1.2 Testing Data Set ความเห็นส่วนมาก กล่าวคือเป็นชุดข้อมูล ที่ผู้เชี่ยวชาญเหมือนกันอย่างน้อย 2 คน จาก 3 คน โดยมีทั้งหมดจำนวน 804 รูป แบ่งเป็นออกเป็น รูปภาพของรูปพรุนที่ไม่ดีจำนวน 476 รูป รูปพรุนที่ดี 279 รูป และรูปพรุนที่ดีมากจำนวน 49 รูป ดังที่แสดงให้เห็นในตารางที่ 3.4

ตารางที่ 3.4 จำนวนรูปภาพที่ใช้ในการทดสอบ Testing Model ในกรณี 3.4.1.2

Type (Probability)	Not Good	Good	Very Good
ความเห็นเอกฉันท์ (1)	169	65	48
ความเห็นส่วนมาก (0.66)	307	214	1
Total	476	279	49

3.4.2 ชุดข้อมูลทดสอบที่ใช้ทดสอบแบบจำลองที่สร้างด้วยผู้เชี่ยวชาญ 3 คน และปฏิบัติการ 2 คน

โดยภาพที่ถูกนำมาใช้ในการทดสอบแบบจำลองจะเป็นชุดข้อมูลทดสอบ ชุดเดียวกับที่ใช้ในหัวข้อ 3.4.1.1 เพื่อนำข้อมูลค่าความแม่นยำมาเปรียบเทียบกันระหว่างแบบจำลองที่สร้างโดยผู้เชี่ยวชาญเพียงอย่างเดียวกับผู้เชี่ยวชาญ และพนักงานระดับปฏิบัติการ

บทที่ 4

ผลลัพธ์การวิจัย วิเคราะห์ และอภิปรายผลการทดลอง

ในหัวข้อนี้จะแบ่งผลลัพธ์ของแบบจำลอง Deep learning ออกเป็น 2 ส่วน ได้แก่

4.1 ผลการทดลองจากแบบจำลองการเรียนรู้ผู้เชี่ยวชาญ 3 คน

4.2 ผลการทดลองจากแบบจำลองการเรียนรู้ผู้เชี่ยวชาญ 3 คน และพนักงานปฏิบัติการ 2 คน

โดยจะเรียงลำดับผลการทดลองจากแบบจำลอง Deep learning ดังนี้ ResNet-50, ResNet-101, Inception-v3, Xception และ GoogLeNet หลังจากนั้นจึงนำข้อมูลมาสรุปในเชิงของการเปรียบเทียบ

4.1 ผลการทดลองจากแบบจำลองการเรียนรู้ผู้เชี่ยวชาญ 3 คน

ผลการทดลองชุดนี้จะเป็น 2 ชุดข้อมูลทดสอบได้

4.1.1 ชุดข้อมูลทดสอบที่เป็นเอกฉันท์อิงตามชุดข้อมูลในหัวข้อ 3.4.1.1


4.1.2 ชุดข้อมูลทดสอบความเห็นส่วนมากอิงตามชุดข้อมูลในหัวข้อ 3.4.1.2

4.1.1 ผลการทดลองชุดข้อมูลที่เป็นเอกฉันท์

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปภาพในแต่ละประเภทของแบบจำลอง ResNet-50 จะแสดงให้เห็นในตารางที่ 4.1 โดยมีค่า Accuracy อยู่ที่ 98.6% และกราฟ Individual Plot ได้แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.88-0.98 ดังที่แสดงให้เห็นในรูปที่ 4.1

ตารางที่ 4.1 ผลลัพธ์ Confusion Matrix ของ ResNet-50

Confusion Matrix: Resnet-50					
Output Class	Not Good	167 59.2%	2 0.7%	0 0.0%	98.8% 1.2%
	Good	2 0.7%	63 22.3%	0 0.0%	96.9% 3.1%
	Very Good	0 0.0%	0 0.0%	48 17.0%	100% 0.0%
		98.8% 1.2%	96.9% 3.1%	100% 0.0%	98.6% 1.4%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.1 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-50

ผลลัพธ์ของค่าความแม่นยำการทำนายรูพรุนในแต่ละประเภทของแบบจำลอง ResNet-101 จะแสดงให้เห็นในตารางที่ 4.2 โดยมีค่า %Accuracy อยู่ที่ 95.4% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.73-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.2

ตารางที่ 4.2 ผลลัพธ์ Confusion Matrix ของ ResNet-101

Confusion Matrix: Resnet-101					
Output Class	Not Good	168 59.6%	12 4.3%	0 0.0%	93.3% 6.7%
	Good	1 0.4%	53 18.8%	0 0.0%	98.1% 1.9%
	Very Good	0 0.0%	0 0.0%	48 17.0%	100% 0.0%
		99.4% 0.6%	81.5% 18.5%	100% 0.0%	95.4% 4.6%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.2 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-101

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปภาพในแต่ละประเภทของแบบจำลอง ของ Inception-v3 จะแสดงให้เห็นในตารางที่ 4.3 โดยมีค่า %Accuracy อยู่ที่ 98.9% และกราฟ Individual Plot แสดงช่วง และ ค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล มีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.92-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.3

ตารางที่ 4.3 ผลลัพธ์ Confusion Matrix ของ Inception-v3

Confusion Matrix: Inception-v3					
Output Class	Not Good	169 59.9%	3 1.1%	0 0.0%	98.3% 1.7%
	Good	0 0.0%	62 22.0%	0 0.0%	100% 0.0%
	Very Good	0 0.0%	0 0.0%	48 17.0%	100% 0.0%
		100% 0.0%	95.4% 4.6%	100% 0.0%	98.9% 1.1%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.3 กราฟ Individual Plot ความน่าจะเป็นของ Inception-v3

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปหุ่นในแต่ละประเภทของแบบจำลอง Xception จะแสดงให้เห็นในตารางที่ 4.4 โดยมีค่า %Accuracy อยู่ที่ 94.0% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.72-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.4

ตารางที่ 4.4 ผลลัพธ์ Confusion Matrix ของ Xception

Confusion Matrix: Xception					
Output Class	Not Good	169	15	0	91.8%
		59.9%	5.3%	0.0%	8.2%
	Good	0	50	2	96.2%
		0.0%	17.7%	0.7%	3.8%
	Very Good	0	0	46	100%
		0.0%	0.0%	16.3%	0.0%
		100%	76.9%	95.8%	94.0%
		0.0%	23.1%	4.2%	6.0%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.4 กราฟ Individual Plot ความน่าจะเป็นของ Xception

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปหุ่นในแต่ละประเภทของแบบจำลอง GoogLeNet จะแสดงให้เห็นในตารางที่ 4.5 โดยมีค่า %Accuracy อยู่ที่ 59.9% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.13-0.63 ดังที่แสดงให้เห็นในรูปที่ 4.5


ตารางที่ 4.5 ผลลัพธ์ Confusion Matrix ของ GoogLeNet

Confusion Matrix: GoogLeNet					
Output Class	Not Good	169 59.9%	65 23.0%	48 17.0%	59.9% 40.1%
	Good	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	Very Good	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
		100% 0.0%	0% 100%	0.0% 100%	59.9% 40.1%
		Not Good	Good	Very Good	
Target Class					



รูปที่ 4.5 กราฟ Individual Plot ความน่าจะเป็นของ GoogLeNet

โดยเมื่อนำข้อมูลค่า %Accuracy ของแบบจำลอง Deep Learning ทั้ง 5 รูปแบบ มาเปรียบเทียบกันจะได้ตามแผนภูมิแท่ง ดังรูปที่ 4.6



รูปที่ 4.6 แผนภูมิแท่งเปรียบเทียบค่าความแม่นยำชุดข้อมูลทดสอบแบบจำลองเอกฉันท ด้วยชุดทดสอบเอกฉันท

จากผลการทดลองแบบจำลองของ Deep Learning ในการคัดแยกรูปพรุน โดยใช้ชุดข้อมูลทดสอบที่เป็นเอกฉันทังกราฟในรูปที่ 4.6 มีค่า %ความแม่นยำ (Accuracy) อยู่ที่ 94.0% ถึง 98.9% โดยแบบจำลองที่ให้ค่า %Accuracy สูงสุดจะเป็นแบบจำลองของ Inception-v3 ที่ให้ค่าความแม่นยำอยู่ที่ 98.9% ยกเว้น GoogLeNet ที่มี %Accuracy อยู่ที่ 64.7% เนื่องจากแบบจำลองไม่สามารถคัดแยกประเภทของรูปพรุนได้ โดยภาพทั้งหมดจะถูกจัดให้เป็นภาพประเภทของรูปพรุนที่ไม่ดี โดยสังเกตได้จากตาราง Confusion Matrix ของ GoogLeNet ที่แสดงให้เห็นในตารางที่ 4.5 นอกจากนี้ เมื่อนำความน่าจะเป็นในแต่ละรูปมาทำกราฟ Individual Plot จะพบว่าความน่าจะเป็นของภาพประเภทรูปพรุนที่ไม่ดี และประเภทรูปพรุนที่ดีมาก ค่าเฉลี่ยความน่าจะเป็นที่แบบจำลองคำนวณได้ประเภทเดียวกับภาพจริง นั้นมีค่าความน่าจะเป็นที่สูงโดยมีค่ามากกว่า 0.9 ในทุกอัลกอริทึม ในทางกลับกันภาพประเภทของรูปพรุนที่ดีที่เป็นประเภทที่อยู่ตรงกลางระหว่างประเภทรูปพรุนที่ไม่ดี และดีมากนั้น ค่าเฉลี่ยของค่าความน่าจะเป็นนั้นจะมีค่าน้อยกว่าประเภทรูปพรุนอีก 2 โดยดูได้จากภาพที่ 4.1 4.2 4.3 และ 4.4 นอกจากนี้เมื่อนำแต่ละแบบจำลองมาคำนวณหาค่า Precision (ความเที่ยงตรง) Sensitivity (ความสามารถในการตรวจจับ) Specificity (ความสามารถในการเจาะจง) และค่า F1-Score (ค่าเฉลี่ยระหว่าง Precision และ Sensitivity) ดังที่แสดงในตารางที่ 4.6 4.7 4.8 และ 4.9 จะพบว่า ประเภทรูปพรุนที่ดีมากจะเป็นรูปพรุนที่มีค่า F1-Score และ Specificity ที่สูงเนื่องจากเป็นรูปพรุนที่แบบจำลองสามารถคัดแยกได้โดยง่าย รูปพรุนที่ไม่ดีนั้นจะมีค่า Precision ที่ต่ำเนื่องจากแบบจำลองจะมองมองรูปพรุนประเภทที่ดีมาเป็นส่วนหนึ่งของประเภทรูปพรุนที่ไม่ดีด้วย ส่วนในกรณีรูปพรุนที่ดีจะมีค่า Sensitivity ที่ต่ำกล่าวคือแบบจำลองจะมีโอกาสที่จะประเมินรูปพรุนที่ดีเป็นรูปพรุนประเภทอื่น ซึ่งในกรณีของงานวิจัยนี้รูปพรุนที่ดีจะถูกทำนายไปทางที่ไม่ดีได้มากกว่าซึ่งสอดคล้องกับค่าเฉลี่ยความน่าจะเป็นของกราฟ Individual Plot ในประเภทของรูปพรุนจริงที่ไม่ดี จะมีค่ามากกว่าประเภทรูปพรุนที่ดีมาก ดังที่แสดงในรูปที่ 4.1 4.2 4.3 และ 4.4

ตารางที่ 4.6 ผลลัพธ์ค่า %Precision ของแบบจำลองเอกฉันท ด้วยชุดข้อมูลทดสอบเอกฉันท

Model	Precision (%)		
	Not Good	Good	Very Good
ResNet-50	98.8%	96.9%	100.0%
ResNet-101	93.3%	98.1%	100.0%
Inception-v3	98.3%	100.0%	100.0%
Xception	91.8%	96.2%	100.0%
GoogLeNet	59.9%	-	-

ตารางที่ 4.7 ผลลัพธ์ค่า %Sensitivity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบเอกฉันท์

Sensitivity (%)			
Model	Not Good	Good	Very Good
ResNet-50	98.8%	96.9%	100.0%
ResNet-101	99.4%	81.5%	100.0%
Inception-v3	100.0%	95.4%	100.0%
Xception	100.0%	76.9%	95.8%
GoogLeNet	100.0%	-	-

ตารางที่ 4.8 ผลลัพธ์ค่า %Specificity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบเอกฉันท์

Specificity (%)			
Model	Not Good	Good	Very Good
ResNet-50	98.2%	99.1%	100.0%
ResNet-101	89.4%	99.5%	100.0%
Inception-v3	97.3%	100.0%	100.0%
Xception	86.5%	99.1%	100.0%
GoogLeNet	0.0%	100.0%	100.0%

ตารางที่ 4.9 ผลลัพธ์ค่า %F1-Score ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบเอกฉันท์


F1-Score (%)			
Model	Not Good	Good	Very Good
ResNet-50	98.8%	96.9%	100.0%
ResNet-101	96.3%	89.1%	100.0%
Inception-v3	99.1%	97.6%	100.0%
Xception	95.8%	85.5%	97.9%
GoogLeNet	74.9%	-	-

4.1.2 ผลการทดลองชุดข้อมูลทดสอบความเห็นส่วนมาก

ผลลัพธ์ของค่าความแม่นยำการทำนายรูพรุนในแต่ละประเภทของแบบจำลอง Resnet-50 จะแสดงให้เห็นในตารางที่ 4.10 โดยมีค่า %Accuracy อยู่ที่ 80.6% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.74-0.96 ดังที่แสดงให้เห็นในรูปที่ 4.7

ตารางที่ 4.10 ผลลัพธ์ Confusion Matrix ของ Resnet-50

Confusion Matrix: ResNet-50					
Output Class	Not Good	354 44.0%	26 3.2%	0 0.0%	93.2% 6.8%
	Good	122 15.2%	245 30.5%	0 0.0%	66.8% 33.2%
	Very Good	0 0.0%	8 1.0%	49 6.1%	86.0% 14.0%
		74.4% 25.6%	87.8% 12.2%	100% 0.0%	80.6% 19.4%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.7 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-50

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปภาพในแต่ละประเภทของแบบจำลอง ResNet-101 จะแสดงให้เห็นในตารางที่ 4.11 โดยมีค่า %Accuracy อยู่ที่ 80.0% และกราฟ Individual Plot แสดงช่วง และค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.63-0.96 ดังที่แสดงให้เห็นในรูปที่ 4.8

ตารางที่ 4.11 ผลลัพธ์ Confusion Matrix ของ ResNet-101

Confusion Matrix: ResNet-101					
Output Class	Not Good	398 49.5%	77 9.6%	0 0.0%	83.8% 16.2%
	Good	78 9.7%	196 24.4%	0 0.0%	71.5% 33.2%
	Very Good	0 0.0%	6 0.7%	49 6.1%	89.1% 14.0%
		83.6% 16.4%	87.8% 12.2%	100% 0.0%	80.0% 20.0%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.8 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-101

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปภาพในแต่ละประเภทของแบบจำลอง Inception-v3 จะแสดงให้เห็นในตารางที่ 4.12 โดยมีค่า %Accuracy อยู่ที่ 81.7% และกราฟ Individual Plot แสดงช่วง และค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.76-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.9

ตารางที่ 4.12 ผลลัพธ์ Confusion Matrix ของ Inception-v3

Confusion Matrix: Inception-v3					
Output Class	Not Good	366 45.5%	37 4.6%	0 0.0%	90.8% 9.2%
	Good	110 13.7%	242 30.1%	0 0.0%	68.8% 31.3%
	Very Good	0 0.0%	6 0.0%	49 6.1%	100% 0.0%
		76.9% 23.1%	87.8% 13.3%	100% 0.0%	81.7% 18.3%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.9 กราฟ Individual Plot ความน่าจะเป็นของ Inception-v3

ผลลัพธ์ของค่าความแม่นยำการทำนายรูพรุนในแต่ละประเภทของแบบจำลอง Xception จะแสดงให้เห็นในตารางที่ 4.13 โดยมีค่า %Accuracy อยู่ที่ 82.2% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.67-0.91ดังที่แสดงให้เห็นในรูปที่ 4.10

ตารางที่ 4.13 ผลลัพธ์ Confusion Matrix ของ Xception

Confusion Matrix: Xception					
Output Class	Not Good	403 50.1%	67 8.3%	0 0.0%	85.7% 14.3%
	Good	73 9.1%	211 26.2%	2 0.2%	73.8% 26.2%
	Very Good	0 0.0%	1 0.1%	47 5.8%	97.9% 2.1%
		84.7% 15.3%	75.6% 24.4%	95.9% 4.1%	82.2% 17.8%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.10 กราฟ Individual Plot ความน่าจะเป็นของ Xception

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปภาพในแต่ละประเภทของแบบจำลอง GoogLeNet จะแสดงให้เห็นในตารางที่ 4.14 โดยมีค่า %Accuracy อยู่ที่ 59.2% และกราฟ Individual Plot แสดงช่วง และค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.13- 0.63 ดังที่แสดงให้เห็นในรูปที่ 4.11


ตารางที่ 4.14 ผลลัพธ์ Confusion Matrix ของ GoogLeNet

Confusion Matrix: GoogLeNet					
Output Class	Not Good	476 59.2%	279 34.7%	49 6.1%	59.2% 40.8%
	Good	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	Very Good	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
		100% 0.0%	0.0% 100%	0.0% 100%	59.2% 40.8%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.11 กราฟ Individual Plot ความน่าจะเป็นของ GoogLeNet


โดยเมื่อนำข้อมูลค่าความแม่นยำ ของแบบจำลอง Deep Learning ทั้ง 5 รูปแบบ มาเปรียบเทียบกันจะได้ตามแผนภูมิแท่ง ดังรูปที่ 4.12 นอกจากนี้เมื่อนำข้อมูลความน่าจะเป็นในแบบจำลอง มาเปรียบเทียบกับความน่าจะเป็นจริงของรูป โดยค่าความน่าจะเป็นของรูปมีค่าเท่ากับ 0.66 กล่าวคือมีความเห็นเหมือนกัน 2 คนจาก 3 คน และมีค่าเท่ากับ 1 ในกรณีที่ภาพเป็นเอกฉันท์ โดยใช้กราฟ Interval Plot แสดงการกระจายตัวเพื่อดูลักษณะความสัมพันธ์ของค่าความน่าจะเป็น โดยแบ่ง ออกเป็น ชุดข้อมูลภาพของรูปพรุนที่ไม่ดี ดังกราฟที่ 4.13 ชุดข้อมูลของภาพรูปพรุนที่ดี ดังรูปที่ 4.14 และชุดข้อมูลภาพรูปพรุนที่ดีมาก ดังรูปที่ 4.15




รูปที่ 4.12 แผนภูมิเปรียบเทียบค่าความแม่นยำแบบจำลองเอกฉันท์ ด้วยชุดทดสอบความเห็นส่วนมาก



รูปที่ 4.13 กราฟ Interval Plot ความน่าจะเป็นของประเภทรูปพรุนที่ไม่ดี



รูปที่ 4.14 กราฟ Interval Plot ความน่าจะเป็นของประเภทรูปพรุนที่ดี



รูปที่ 4.15 กราฟ Interval Plot ความน่าจะเป็นของประเภทรูปพรุนที่ดีมาก

จากผลการทดลองแบบจำลองของ Deep Learning ในการคัดแยกรูปพรุน โดยใช้ชุดข้อมูลทดสอบความเห็นส่วนมากดังกราฟในรูปที่ 4.12 มีค่าความแม่นยำอยู่ที่ 80.0% ถึง 82.2% โดยแบบจำลองที่ให้ค่าความแม่นยำสูงสุดจะเป็นแบบจำลองของ Xception ที่ให้ค่าความแม่นยำอยู่ที่ 82.2% ยกเว้น GoogLeNet ที่มีค่าความแม่นยำ อยู่ที่ 59.2% เนื่องจากแบบจำลองไม่สามารถคัดแยกประเภทของรูปพรุนได้เหมือนกับชุดข้อมูลภาพทดสอบแบบที่เป็นเอกฉันท์ โดยภาพทั้งหมดจะถูกจัดมองเป็นภาพประเภทของรูปพรุนที่ไม่ดี โดยสังเกตได้จากตาราง Confusion matrix ของ GoogLeNet ที่แสดงให้เห็นในตารางที่ 4.14 นอกจากนี้ เมื่อนำความน่าจะเป็นในแต่ละรูปมาทำกราฟ Individual Plot จะพบว่าค่าเฉลี่ยของความน่าจะเป็นของภาพที่ทำนายจากแบบจำลอง ของประเภทรูปพรุนที่ไม่ดี ประเภทรูปพรุนที่ดี และประเภทรูปพรุนที่ดีมากนั้นจะน้อยกว่า ชุดข้อมูลทดสอบที่เป็นเอกฉันท์อย่างชัดเจน โดยสาเหตุเนื่องมาจากภาพที่ใช้ในความทดสอบเองนั้นยังมีความไม่แน่นอน กล่าวคือ ภาพที่นำมาทดสอบในแต่ละประเภท จะมีทั้งภาพที่ผู้เชี่ยวชาญเห็นตรงกัน 2 คนจาก 3 คน รวมอยู่ด้วยซึ่งต่างกับชุดข้อมูลทดสอบเอกฉันท์ที่จะใช้ภาพที่มีความเห็นตรงกันทั้งหมดเพียงอย่างเดียว โดยเมื่อนำค่าความน่าจะเป็นมาสร้างกราฟ Interval Plot แบ่งตามกลุ่มความน่าจะเป็นจริงของภาพ โดยแบ่งเป็น ภาพที่ความเห็นเหมือนกัน 2 คน จาก 3 คน ความน่าจะเป็น 0.66 และภาพที่มีความเห็นเหมือนกันทั้งหมด ความน่าจะเป็น 1 พบว่าค่าความน่าจะเป็นที่ได้แบบจำลองจะมีความใกล้เคียงกับความน่าจะเป็นจริงของภาพ ดังที่แสดงในรูปที่ 4.13 4.14 และ 4.15 นอกจากนี้เมื่อนำแต่ละแบบจำลองมาคำนวณหาค่า Precision, Sensitivity, Specificity และค่า F1-Score ดังที่แสดงในตารางที่ 4.15 4.16 4.17 และ 4.18 จะพบว่า ประเภทรูปพรุนที่ดีมากจะเป็นรูปพรุนที่มีค่า F1-Score และ Specificity ที่สูงเนื่องจากเป็นรูปพรุนที่แบบจำลองสามารถคัดแยกได้โดยง่าย ซึ่งเหมือนกับข้อมูลชุดทดสอบเอกฉันท์ที่กล่าวไว้ในหัวข้อ 4.1 ในขณะที่รูปพรุนที่ไม่ดีกับรูปพรุนที่ดีนั้นค่า

F1-Score จะน้อยกว่าชุดข้อมูลทดสอบเอกฉันท์เนื่องจากภาพประเภทรูปหุ่นทั้ง 2 แบบ จะมีข้อมูลที่ผู้เชี่ยวชาญให้ความเห็นเหมือนกัน 2 คนจาก 3 คน ในปริมาณมากทำให้ %Precision และ %Sensitivity มีค่าน้อยกว่าชุดข้อมูลทดสอบเอกฉันท์

ตารางที่ 4.15 ผลลัพธ์ค่า %Precision ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็นส่วนมาก

Precision (%)			
Model	Not Good	Good	Very Good
ResNet-50	93.2%	66.8%	86.0%
ResNet-101	83.8%	71.5%	89.1%
Inception-v3	90.8%	68.8%	100.0%
Xception	85.7%	73.8%	97.9%
GoogLeNet	59.2%	-	-

ตารางที่ 4.16 ผลลัพธ์ค่า %Sensitivity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็นส่วนมาก

Sensitivity (%)			
Model	Not Good	Good	Very Good
ResNet-50	74.4%	87.8%	100.0%
ResNet-101	83.6%	70.3%	100.0%
Inception-v3	76.9%	86.7%	100.0%
Xception	84.7%	75.6%	95.9%
GoogLeNet	100.0%	-	-

ตารางที่ 4.17 ผลลัพธ์ค่า %Specificity ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็นส่วนมาก

Specificity (%)			
Model	Not Good	Good	Very Good
ResNet-50	91.9%	76.8%	98.7%
ResNet-101	76.1%	85.1%	99.0%
Inception-v3	88.7%	79.0%	100.0%
Xception	79.4%	85.7%	99.8%
GoogLeNet	0.0%	100.0%	100.0%

ตารางที่ 4.18 ผลลัพธ์ค่า %F1-Score ของแบบจำลองเอกฉันท์ ด้วยชุดข้อมูลทดสอบความเห็นส่วนมาก

F1-Score (%)			
Model	Not Good	Good	Very Good
ResNet-50	82.7%	75.9%	92.5%
ResNet-101	83.7%	70.9%	94.2%
Inception-v3	83.3%	76.7%	100.0%
Xception	85.2%	74.7%	96.9%
GoogLeNet	74.4%	-	-

นอกจากนี้ข้อมูลเวลาที่ใช้ในการสร้างแบบจำลองของในแต่ละอัลกอริทึมจะแสดงให้เห็นในตารางที่ 4.19 โดยมีหน่วยเป็นนาที

ตารางที่ 4.19 ระยะเวลาที่ใช้ในการสร้างแบบจำลอง Deep Learning โดยมีหน่วยเป็นนาที


Sensitivity (%)			
Model	Not Good	Good	Very Good
ResNet-50	74.4%	87.8%	100.0%
ResNet-101	83.6%	70.3%	100.0%
Inception-v3	76.9%	86.7%	100.0%
Xception	84.7%	75.6%	95.9%
GoogLeNet	100.0%	-	-

4.2 ผลการทดลองจากแบบจำลองการเรียนรู้ผู้เชี่ยวชาญ 3 คน และพนักงานปฏิบัติการ 2 คน

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปพรรณในแต่ละประเภทของแบบจำลอง ResNet-50 จะแสดงให้เห็นในตารางที่ 4.20 โดยมีค่า %Accuracy อยู่ที่ 86.9% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล โดยมีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.44-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.16

ตารางที่ 4.20 ผลลัพธ์ Confusion Matrix ของ ResNet-50

Confusion Matrix: ResNet-50					
Output Class	Not Good	169 59.9%	36 12.8%	0 0.0%	82.4% 17.6%
	Good	0 0.0%	29 10.3%	1 0.4%	96.7% 3.3%
	Very Good	0 0.0%	0 0.0%	47 16.7%	100% 0.0%
		100% 0.0%	44.6% 55.4%	97.9% 2.1%	86.9% 13.1%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.16 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-50

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปหุ่นในแต่ละประเภทของแบบจำลอง ResNet-101 จะแสดงให้เห็นในตารางที่ 4.21 โดยมีค่า %Accuracy อยู่ที่ 79.8% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล มีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.26-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.17

ตารางที่ 4.21 ผลลัพธ์ Confusion Matrix ของ ResNet-101

Confusion Matrix: ResNet-101					
Output Class	Not Good	169 59.9%	57 20.2%	0 0.0%	74.8% 25.2%
	Good	0 0.0%	8 2.8%	0 0.0%	100% 0.0%
	Very Good	0 0.0%	0 0.0%	48 17.0%	100% 0.0%
		100% 0.0%	12.3% 87.7%	100% 0.0%	79.8% 20.2%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.17 กราฟ Individual Plot ความน่าจะเป็นของ ResNet-101

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปภาพในแต่ละประเภทของแบบจำลอง Inception-v3 จะแสดงให้เห็นในตารางที่ 4.22 โดยมีค่า %Accuracy อยู่ที่ 83.0% และกราฟ Individual Plot แสดงช่วงและค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล มีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.33-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.18

ตารางที่ 4.22 ผลลัพธ์ Confusion Matrix ของ Inception-v3

Confusion Matrix: Inception-v3					
Output Class	Not Good	169 59.9%	47 16.7%	0 0.0%	78.2% 21.8%
	Good	0 0.0%	18 6.4%	1 0.4%	94.7% 5.3%
	Very Good	0 0.0%	0 0.0%	47 16.7%	100% 0.0%
		100% 0.0%	27.7% 72.3%	97.9% 2.1%	83.0% 17.0%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.18 กราฟ Individual Plot ความน่าจะเป็นของ Inception-v3

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปหุ่นในแต่ละประเภทของแบบจำลอง Xception จะแสดงให้เห็นในตารางที่ 4.23 โดยมีค่า %Accuracy อยู่ที่ 79.4% และกราฟ Individual Plot แสดงช่วง และค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล มีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.29-0.99 ดังที่แสดงให้เห็นในรูปที่ 4.19

ตารางที่ 4.23 ผลลัพธ์ Confusion Matrix ของ Xception

Confusion Matrix: Xception					
Output Class	Not Good	169 59.9%	58 20.6%	0 0.0%	74.4% 25.6%
	Good	0 0.0%	7 2.5%	0 0.0%	100% 0.0%
	Very Good	0 0.0%	0 0.0%	48 17.0%	100% 0.0%
		100% 0.0%	10.8% 89.2%	100% 0.0%	79.4% 20.6%
		Not Good	Good	Very Good	
Target Class					




รูปที่ 4.19 กราฟ Individual Plot ความน่าจะเป็นของ Xception

ผลลัพธ์ของค่าความแม่นยำการทำนายรูปหุ่นในแต่ละประเภทของแบบจำลอง GoogLeNet จะแสดงให้เห็นในตารางที่ 4.24 โดยมีค่า %Accuracy อยู่ที่ 59.9% และกราฟ Individual Plot แสดงช่วง และค่าเฉลี่ยของความน่าจะเป็นที่แบบจำลองทำนายได้ในแต่ละประเภทกลุ่มข้อมูล มีค่าเฉลี่ยความน่าจะเป็นอยู่ที่ 0.06-0.85 ดังที่แสดงให้เห็นในรูปที่ 4.20


ตารางที่ 4.24 ผลลัพธ์ Confusion Matrix ของ GoogLeNet

Confusion Matrix: GoogLeNet					
Output Class	Not Good	169 59.9%	65 20.6%	48 17.0%	59.9% 40.1%
	Good	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	Very Good	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
		100% 0.0%	0.0% 100%	0.0% 100%	59.9% 40.1%
		Not Good	Good	Very Good	
Target Class					



รูปที่ 4.20 กราฟ Individual Plot ความน่าจะเป็นของ GoogLeNet

โดยเมื่อนำข้อมูลค่าความแม่นยำ ของแบบจำลอง Deep Learning ทั้ง 5 รูปแบบมาเปรียบเทียบกันจะได้ตามแผนภูมิแท่ง ดังรูปที่ 4.21



รูปที่ 4.21 แผนภูมิแท่งเปรียบเทียบค่าความแม่นยำทดสอบแบบจำลองผู้เชี่ยวชาญและปฏิบัติการด้วยชุดทดสอบเอกซันท์

จากการที่นำชุดทดสอบข้อมูลภาพเอกซันท์ไปทดสอบแบบจำลอง ที่ทำการสร้างจากผู้เชี่ยวชาญจำนวน 3 คน และพนักงานปฏิบัติการ 2 คน พบว่าได้ค่าความแม่นยำน้อยกว่าแบบจำลองที่ได้จากการสร้างจากผู้เชี่ยวชาญ 3 คน โดยค่าความแม่นยำอยู่ที่ 79.4% ถึง 86.9% โดยที่ GoogLeNet ยังไม่สามารถแยกประเภทของรูปพรรณได้เหมือนกับแบบจำลองจำลองที่สร้างจากผู้เชี่ยวชาญ 3 คน โดยมีค่า %Accuracy อยู่ที่ 59.9% นอกจากนี้เมื่อนำแต่ละแบบจำลองมาคำนวณหาค่า Precision, Sensitivity, Specificity และค่า F1-Score ดังที่แสดงในตารางที่ 4.25 4.26 4.27 และ 4.28 เมื่อนำค่า F1-Score เทียบกับแบบจำลองที่สร้างด้วยมติเอกซันท์ของผู้เชี่ยวชาญ 3 คนจะพบว่า ประเภทรูพรรณที่ดีจะมีค่า F1-Score ที่น้อยลงอันเนื่องมาจาก ค่า Sensitivity ที่ลดลงโดยเกิดจากรูภาพรูพรรณประเภทที่ดีถูกประเมินให้เป็นประเภทรูพรรณที่ไม่ดี มากขึ้นอันเนื่องมาจาก พนักงานระดับปฏิบัติการมีแนวโน้มการประเมินไปในทางรูพรรณที่ไม่ดี

ตารางที่ 4.25 ผลลัพธ์ค่า %Precision ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูลเอกฉันท์

Precision (%)			
Model	Not Good	Good	Very Good
ResNet-50	82.4%	96.7%	100.0%
ResNet-101	74.8%	100.0%	100.0%
Inception-v3	78.2%	94.7%	100.0%
Xception	74.4%	100.0%	100.0%
GoogLeNet	59.9%	-	-

ตารางที่ 4.26 ผลลัพธ์ค่า %Sensitivity ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูลเอกฉันท์

Sensitivity (%)			
Model	Not Good	Good	Very Good
ResNet-50	100.0%	44.6%	97.9%
ResNet-101	100.0%	12.3%	100.0%
Inception-v3	100.0%	27.7%	97.9%
Xception	100.0%	10.8%	100.0%
GoogLeNet	100.0%	-	-

ตารางที่ 4.27 ผลลัพธ์ค่า %Specificity ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูลเอกฉันท์

Specificity (%)			
Model	Not Good	Good	Very Good
ResNet-50	67.9%	99.5%	100.0%
ResNet-101	49.6%	100.0%	100.0%
Inception-v3	58.0%	99.5%	100.0%
Xception	48.7%	100.0%	100.0%
GoogLeNet	0.0%	100.0%	100.0%

ตารางที่ 4.28 ผลลัพธ์ค่า %F1-Score ของแบบจำลองผู้เชี่ยวชาญและพนักงานปฏิบัติการ ชุดข้อมูล
เอกฉันท

F1-Score (%)			
Model	Not Good	Good	Very Good
ResNet-50	90.4%	61.1%	98.9%
ResNet-101	85.6%	21.9%	100.0%
Inception-v3	87.8%	42.9%	98.9%
Xception	85.4%	19.4%	100.0%
GoogLeNet	59.9%	-	-

บทที่ 5

บทสรุป และข้อเสนอแนะ

การศึกษาวิจัยการสร้างแบบจำลองการประเมินคุณภาพ Sintering Neck ด้วยภาพถ่าย โครงสร้างทางจุลภาคโดยอิงจากจุดประสงค์ที่กล่าวในบทที่ 1 ทางผู้วิจัยได้แบ่ง ออกเป็น 3 หัวข้อย่อย ดังนี้

- 5.1 สรุปผลการวิจัย
- 5.2 ปัญหาและอุปสรรคในการทำวิจัย
- 5.3 ข้อเสนอแนะงานวิจัย

5.1 สรุปและอภิปรายผลการวิจัย

จากวัตถุประสงค์งานวิจัยที่ต้องการสร้างแบบจำลอง Deep Learning เพื่อใช้การประเมินคุณภาพของ Sintering Neck จากรูพรุนในภาพถ่ายโครงสร้างจุลภาค โดยอาศัยการเรียนรู้จากผู้เชี่ยวชาญ เป็นต้นแบบ สามารถทำได้ซึ่งแบบจำลองที่สร้างโดยผู้เชี่ยวชาญ 3 คน และสร้างจากชุดข้อมูลเอกซันท์ นั้นให้ความแม่นยำมากที่สุด โดยความยากของภาพในการประเมิน และประสบการณ์ของบุคคลที่จะ มาทำการประเมินภาพนั้นส่งผลต่อค่าความแม่นยำที่ได้จากแบบจำลอง ถ้าภาพนั้นมีความยากในการ แบ่งประเภท ความน่าจะเป็นของภาพนั้นจะน้อยลง โดยงานวิจัยนี้แนวโน้มน้ำหนักการประเมินคุณภาพ ของภาพนั้นไปทาง ประเภทรูพรุนที่ไม่ดี โดยสังเกตได้จากภาพประเภทรูพรุนที่ดี มักจะเป็นภาพที่จะ ทำนายผิดไปเป็นประเภทที่ไม่ดีมากกว่าจะไปทางประเภทรูพรุนที่ดีมาก เนื่องจากมีลักษณะของรูพรุน ที่ใกล้เคียงกันมากกว่า และโดยทั่วไปในงานวิศวกรรมการประเมินคุณภาพที่ไม่แน่นอนไปในทางที่ไม่ดี เพื่อไม่ต้องการให้ผลิตภัณฑ์หลุดออกไปจำหน่าย แต่อาจจะส่งผลต่อต้นทุนการผลิตเนื่องจากต้องนำชิ้นงาน ไปทำการหลอมใหม่ เป็นต้น ส่วนประสบการณ์ของบุคคลที่เป็นผู้ประเมินภาพนั้นจะส่งผลต่อความน่าจะเป็น ของภาพโดยตรง โดยถ้าประสบการณ์ของผู้ประเมินนั้นไม่มากเพียงพอ อาจจะประเมินผิดและให้ทำ ความน่าจะเป็นของประเภทภาพที่ควรจะเป็นนั้นน้อยลง โดยทางผู้วิจัยได้ทำการไปสัมภาษณ์ผู้เชี่ยวชาญ และพนักงานปฏิบัติการ หลังจากการทำการประเมินภาพ โดยสรุปภาพในการประเมินและสอบถาม เหตุผลในการประเมินพบว่า ผู้เชี่ยวชาญนั้นสามารถอธิบายถึงเหตุผลในการเลือกภาพได้ดีกว่า พนักงาน ปฏิบัติการที่ในบางครั้งยังมีความไม่มั่นใจในการให้เหตุผลอันเนื่องมาจากประสบการณ์ทำงานที่ยังน้อยกว่า ผู้เชี่ยวชาญ

5.2 ปัญหาและอุปสรรคในการทำวิจัย

5.2.1 ปัญหาและปัจจัยด้านคุณภาพของชุดข้อมูลภาพ

ภาพของรูพรุนประเภทที่ทำให้เกิด Sintering Neck ที่ตีมากตาม Guideline นั้น เป็นประเภทรูพรุนที่หาได้ยาก ทำให้ปริมาณของภาพที่จะนำมาใช้เป็นชุดข้อมูลภาพ ในการทำ Training Model นั้นมีจำนวนน้อยกว่าประเภทอื่นเนื่องจาก ต้องเป็นการขึ้นรูปโลหะผงในงานเฉพาะทาง และต้องการคุมปัจจัยในการผลิตที่มากกว่ารูพรุนประเภทอื่น อาทิ เช่นในเรื่องของอุณหภูมิในกระบวนการ เผาผนึกเป็นต้น นอกจากนี้การหาผู้เชี่ยวชาญเพื่อมาช่วยในการประเมินประเภทของรูปภาพนั้นหาได้ ยาก และในการประเมินภาพที่มีปริมาณมากอาจจะทำให้ผู้ประเมินเกิดความล้าชณะท่ากาประเมิน และทำให้มีโอกาสปะเมินผิดพลาดได้

5.2.2 ปัญหาและปัจจัยด้านอุปกรณ์

เนื่องจากคอมพิวเตอร์ที่ใช้ในการสร้างแบบจำลอง Deep Learning นั้นเป็น Notebook ทำให้ใช้เวลานานในการสร้างแบบจำลอง และกล้องจุลทรรศน์ที่ใช้ในการถ่ายภาพโครงสร้างทางจุลภาค นั้นจำเป็นต้องไปดำเนินการที่ศูนย์วิจัยที่ได้รับการสนับสนุนจาก บริษัท Acme International (Thailand)

5.3 ข้อเสนอแนะงานวิจัย

นอกจากการประเมินคุณภาพ Sintering Neck ในโลหะผง แล้วยังสามารถนำแนวทางการวิจัย ไปใช้กับโลหะที่ผ่านกระบวนการขึ้นรูป ประเภทอื่นที่มีลักษณะภาพใกล้เคียงกันได้ อาทิเช่น การประเมิน รูพรุนในงานโลหะที่ผ่านกระบวนการรีดร้อน หรือการประเมินสิ่งเจือปน (Inclusion) ในงานเชื่อมเป็นต้น

บรรณานุกรม

TNI

บรรณานุกรม

- [1] AMES Group, “Basic Manufacturing Process,” [Online]. Available : <https://ames-sintering.com/basic-manufacturing-process/>. [Accessed : August 29, 2022].
- [2] Grand View Research, “Powder Metallurgy Market Size, Share & Trends Analysis Report,” [Online]. Available : <https://www.grandviewresearch.com/industryanalysis/powder-metallurgy-market/>. [Accessed : August 29, 2022].
- [3] Research and Markets, “Powder Metallurgy Market - Growth, Trends, and Forecast (2020 - 2027),” [Online]. Available : <https://www.researchandmarkets.comreports/4828185/powder-metallurgy-market-growth-trends-covid/>. [Accessed : August 29, 2022].
- [4] Metal Powder Industries Federation, *Material Standards for PM Structural Parts*, New Jersey : Princeton, 2018.
- [5] T. M. Cimino et al., “The effect of microstructure and pore morphology on mechanical and dynamic properties of ferrous PIM materials,” *International Conference on Powder Metallurgy and Particulate Materials*, PM2TEC 1998, Las Vegas, USA, May 31-June 4, 1998, pp. 1-14.
- [6] J. Park et al., “Complex effects of alloy composition and porosity on the phase transformations and mechanical properties of powder metallurgy steels,” *Powder Technology*, vol. 284, no. 53, pp. 459-466, November 2015.
- [7] Höganäs ATEC, *Metallography Theory*, Bangkok : n.p., 2017.
- [8] M. Marin and F. B. Marin, “Quantitative image analysis in some iron powder metallurgy materials,” *IOP Conference Series : Materials Science and Engineering*, vol. 485, no. 11, pp. 120-121, March 2019.
- [9] S. M. Azimi et al., “Advanced steel microstructural classification by deep learning methods,” *Scientific Reports*, vol. 8, no. 2, 128, no page, December 2018.
- [10] D. Datta et al., “Determination of porosity of rock samples from photomicrographs using image analysis,” *IEEE 6th International Conference on Advanced Computing*, IACC 2016, Bhimavaram, India, February 27-28, 2016, pp. 320-325.
- [11] R. L. Coble, “A model for boundary diffusion controlled creep in polycrystalline materials,” *Journal of Applied Physics*, vol. 34, no. 6, pp. 1,679-1,682, June 1963.

- [12] J. Beyerer et al., *Machine Vision*, Berlin : Springer Berlin Heidelberg, 2016.
- [13] W. Burger and M. J. Burge, *Principles of Digital Image Processing: Advanced Methods*, London : Springer London, 2013.
- [14] เอกสิทธิ์ พัทธวงศ์ศักดิ์, *A Little Book of Big Data and Machine Learning*, นนทบุรี : ไอ ดีซี พรีเมียร์ บจก, 2563.
- [15] N. Phongchit, “Convolutional Neural Network (CNN) คืออะไร,” [Online]. Available : <https://medium.com/@natthawatphongchit>. [Accessed : 29 สิงหาคม 2565].
- [16] S. Saha, “A Comprehensive Guide to Convolutional Neural Networks the ELI5 Way,” [Online]. Available : <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks/>. [Accessed : August 29, 2022].
- [17] Muffin, “การวิวัฒนาการของ Image Classification ในยุคสมัยของ Neural Networks,” [Online]. Available : <https://medium.com/super-ai-engineer>. [Accessed : 29 สิงหาคม 2565].
- [18] A. Krizhevsky et al., “ImageNet classification with deep convolutional neural networks,” *Advances in Neural Information Processing Systems 25*, NIPS 2012, Lake Tahoe, USA, December 3-8, 2012, pp. 84-90.
- [19] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *3rd International Conference on Learning Representations*, ICLR 2015, San Diego, USA, May 7-9, 2015, pp. 1-9.
- [20] S. Bangar, “VGG-Net Architecture Explained,” [Online]. Available : <https://medium.com/@siddheshb008/vgg-net-architecture-explained/>. [Accessed : August 29, 2022].
- [21] C. Szegedy et al., “Going deeper with convolutions,” *IEEE Conference on Computer Vision and Pattern Recognition*, CVPR, Boston, USA, June 7-12, 2015, pp. 1-9.
- [22] C. Szegedy et al., “Rethinking the inception architecture for computer vision,” *IEEE Conference on Computer Vision and Pattern Recognition*, CVPR, Las Vegas, USA, June 27-30, 2016, pp. 2,818–2,826.
- [23] S. H. Tsang, “Review: Inception-v3 - 1st Runner up (Image Classification) in ILSVRC 2015,” [Online]. Available : <https://sh-tsang.medium.com/review-inception-v3-1st-runner-up-image-classification-in-ilsvrc-2015-17915421f77c/>. [Accessed : August 29, 2022].
- [24] F. Chollet, “Xception deep learning with depthwise separable convolutions,” *IEEE Conference on Computer Vision and Pattern Recognition*, CVPR, Honolulu, USA, July 21-26, 2017, pp. 1,800-1,807.

- [25] S. H. Tsang, "Xception with Depthwise Separable Convolution, Better than Inception-v3 (Image Classification)," [Online]. Available : <https://towardsdatascience.com/review-xception-with-depthwise-separable-convolution-better-than-inception-v3-image-dc967dd42568/>. [Accessed : August 29, 2022].
- [26] K. He et al., "Deep residual learning for image recognition," *IEEE Conference on Computer Vision and Pattern Recognition, CVPR*, Las Vegas, USA, June 27-30, 2016, pp. 770-778.
- [27] A. Canziani et al., "An Analysis of Deep Neural Network Models for Practical Applications," [Online]. Available : <https://arxiv.org/abs/1605.07678/>. [Accessed : August 29, 2022].
- [28] P. Gatchalee, "Confusion Matrix เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนายใน Machine Learning," [Online]. Available : <https://medium.com/@pagongatchalee> [Accessed : 29 สิงหาคม 2565].
- [29] M. K. Dunstan et al., "The effects of microstructure and porosity on the competing fatigue failure mechanisms in powder metallurgy Ti-6Al-4V," *International Journal of Fatigue*, vol. 116, no. 45, pp. 584-591, November 2018.
- [30] Y. Liu et al., "Research on stainless steel pipes auto-count algorithm based on image processing," *Spring Congress on Engineering and Technology, S-CET 2012*, Xi'an, China, May 27-30, 2012, pp. 1-3.
- [31] S. J. Lee et al., "Localization of slab identification numbers using deep learning," *International Conference on Control Automation and Systems, ICCAS*, Gyeongju, South Korea, October 16-19, 2016, pp. 1,174-1,176.
- [32] Z. Xinman et al., "Steel bar counting method based on image and video processing," *International Symposium on Intelligent Signal Processing and Communication Systems, ISPACS*, Xiamen, China, November 6-9, 2017, pp. 304-309.
- [33] L. Xiaohu and O. Jineng, "Research on steel bar detection and counting method based on contours," *International Conference on Electronics Technology, ICET*, Chengdu, China, May 23-27, 2018, pp. 294-297.
- [34] X. Yan and X. Chen, "Research on the counting algorithm of bundled steel bars based on the features matching of connected regions," *IEEE 3rd International Conference on Image, ICIVC*, Chongqing, China, June 27-29, 2018, pp. 11-15.

- [35] V. Aggarwal and G. Kaur, "A review : deep learning technique for image classification," *ACCENTS Transactions on Image Processing and Computer Vision*, vol. 4, no. 11, pp. 21-25, May 2018.
- [36] D. Bhamare and P. Suryawanshi, "Review on reliable pattern recognition with machine learning techniques," *Fuzzy Information and Engineering*, vol. 10, no. 3, pp. 362-377, July 2018.
- [37] R. Arnay et al., "Soil micromorphological image classification using deep learning: The porosity parameter," *Applied Soft Computing*, vol. 102, no. 48, pp. 107-115, April 2021.
- [38] M. Abedini et al., "Porosity classification from thin sections using image analysis and neural networks including shallow and deep learning in Jahrum formation," *Journal of Mining & Environment*, vol. 9, no. 19, pp. 513-525, January 2018.
- [39] F. Bordignon et al., "Deep learning for grain size and porosity distributions estimation on micro-CT images," *International Congress of the Brazilian Geophysical Society & EXPOGEF*, CISBGf, Rio de Janeiro, Brazil, August 19-22, 2019, pp. 1-6.
- [40] S. Bianco et al., "Benchmark Analysis of Representative Deep Neural Network Architectures," [Online]. Available : <https://arxiv.org/abs/1810.00736/>. [Accessed : August 29, 2022].

ภาคผนวก

TNI

ภาคผนวก ก.

โค้ดโปรแกรม (System Code)

TNI

โค้ด Matlab R.2019 สำหรับการสร้าง Deep Learning Model ด้วยอัลกอริทึม ResNet-50

Model ResNet-50

```
%% MC learning section
%Reference code
%https://blogs.mathworks.com/deep-learning/2020/03/18/deep-learning-for-
medical-imaging-covid-19-detection/?fbclid=IwAR1Cbzv7EPKZHlpKk-
mhX1bH863i_K6o4Wn1umthT1FVRdIAAt-DQcXDrp0Q

% Clear workspace
clear; close all; clc;

% Images Datapath
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\1.Training';

% Image Datastore
imds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

% _____
% _____

% Determine the split up
total_split=countEachLabel(imds);

% Number of Images
num_images=length(imds.Labels);
num_folds=4;
```

```

% Loop for each fold
for fold_idx=1:num_folds

    fprintf('Processing %d among %d folds \n',fold_idx,num_folds);

    % Test Indices for current fold
    test_idx=fold_idx:num_folds:num_images;

    % Test cases for current fold
    imdsTest = subset(imds,test_idx);

    % Train indices for current fold
    train_idx=setdiff(1:length(imds.Files),test_idx);

    % Train cases for current fold
    imdsTrain = subset(imds,train_idx);

    % ResNet-50 Architecture
    net=resnet50;
    lgraph = layerGraph(net);
    clear net;

    % Number of categories
    numClasses = numel(categories(imdsTrain.Labels));

    % New Learnable Layer
    newLearnableLayer = fullyConnectedLayer(numClasses, ...
        'Name','new_fc', ...
        'WeightLearnRateFactor',10, ...
        'BiasLearnRateFactor',10);

    % Replacing the last layers with new layers

```

```

lgraph = replaceLayer(lgraph,'fc1000',newLearnableLayer);
newsoftmaxLayer = softmaxLayer('Name','new_softmax');
lgraph = replaceLayer(lgraph,'fc1000_softmax',newsoftmaxLayer);
newClassLayer = classificationLayer('Name','new_classoutput');
lgraph = replaceLayer(lgraph,'ClassificationLayer_fc1000',newClassLayer);

% Data Augmentation (Augmentation code ??????????????)
augmenter = imageDataAugmenter('RandXReflection',1,...
    'RandYReflection',1,...
    'RandXTranslation',[0 0]);

% Resizing all training images to [224 224] for ResNet architecture
auimds = augmentedImageDatastore([224
224],imdsTrain,'DataAugmentation',augmenter);

% Resizing all testing images to [224 224] for ResNet architecture
augtestimds = augmentedImageDatastore([224 224],imdsTest);

% Training Options, we choose a small mini-batch size due to limited images
options = trainingOptions('adam',...
    'MaxEpochs',8,'MiniBatchSize',32,...
    'Shuffle','once', ...
    'InitialLearnRate',0.01, ...,
    'ValidationData',augtestimds,...
    'ExecutionEnvironment','gpu',...
    'Verbose',false, ...
    'Plots','training-progress');
%% 'learnRateSchedule', 'piecewise',...

% Training
netTransfer = trainNetwork(auimds,lgraph,options);

% Testing and their corresponding Labels and Posterior for each Case

```

```

[predicted_labels(test_idx),posterior(test_idx,:)] =
classify(netTransfer,augtestimds);

% Save the Independent ResNet Architectures obtained for each Fold

save(sprintf('ResNet50_3CLASS_%d_among_%d_folds',fold_idx,num_folds),'netTransfer','test_idx','train_idx');

% Clearing unnecessary variables
clearvars -except fold_idx num_folds num_images predicted_labels posterior
imds netTransfer;

end
save('ResNet50_WS');

%% Confusion matrix

%% _____ Confusion matrix _____

% Actual Labels
actual_labels=imds.Labels;

% Confusion Matrix
figure;
plotconfusion(actual_labels,predicted_labels')
title('Confusion Matrix: ResNet-50');

%% Predict data
% Images Datapath
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\2.Testing';
Predictimds=imageDatastore(datapath, ...

```

```
'IncludeSubfolders',true, ...  
    'LabelSource','foldernames');  
augtestPredict = augmentedImageDatastore([224 224],Predictimds);  
  
[YPred,scores] = classify(netTransfer,augtestPredict);  
  
Actual_Testing = Predictimds.Labels;  
  
% Confusion Matrix  
figure;  
plotconfusion(Actual_Testing,YPred)  
title('Confusion Matrix: ResNet-50')  
  
%-----END-----
```

โค้ด Matlab R.2019 สำหรับการสร้าง Deep Learning Model ด้วยอัลกอริทึม ResNet-101

Model ResNet-101

```
clear; close all; clc;

net = resnet101;

lgraph = layerGraph(net);

net.Layers%% MC learning section

%Reference code
%https://blogs.mathworks.com/deep-learning/2020/03/18/deep-learning-for-
medical-imaging-covid-19-detection/?fbclid=IwAR1Cbzv7EPKZHlpKk-
mhX1bH863i_K6o4Wn1umthT1FVRdIAAt-DQcXDrp0Q

% Clear workspace
clear; close all; clc;

% Images Datapath – Please modify your path accordingly
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\1.Training';

% Image Datastore
imds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

%

% Determine the split up
total_split=countEachLabel(imds);

% Number of Images
```



```
num_images=length(imds.Labels);

num_folds=4;

% Loop for each fold
for fold_idx=1:num_folds
    gpuDevice(1)

    fprintf('Processing %d among %d folds \n',fold_idx,num_folds);

    % Test Indices for current fold
    test_idx=fold_idx:num_folds:num_images;

    % Test cases for current fold
    imdsTest = subset(imds,test_idx);

    % Train indices for current fold
    train_idx=setdiff(1:length(imds.Files),test_idx);

    % Train cases for current fold
    imdsTrain = subset(imds,train_idx);

    % ResNet-101 Architecture
    net=resnet101;
    lgraph = layerGraph(net);
    clear net;

    % Number of categories
    numClasses = numel(categories(imdsTrain.Labels));

    % New Learnable Layer
```

```

newLearnableLayer = fullyConnectedLayer(numClasses, ...
    'Name','new_fc', ...
    'WeightLearnRateFactor',10, ...
    'BiasLearnRateFactor',10);

% Replacing the last layers with new layers
lgraph = replaceLayer(lgraph,'fc1000',newLearnableLayer);
newsoftmaxLayer = softmaxLayer('Name','new_softmax');
lgraph = replaceLayer(lgraph,'prob',newsoftmaxLayer);
newClassLayer = classificationLayer('Name','new_prop');
lgraph = replaceLayer(lgraph,'ClassificationLayer_predictions',newClassLayer);

% Data Augmentation (Augmentation code ??????????????)
augmenter = imageDataAugmenter('RandXReflection',1,...
    'RandYReflection',1,...
    'RandXTranslation', [0 0]);

% Resizing all training images to [224 224] for ResNet architecture
auidms = augmentedImageDatastore([224
224],imdsTrain,'DataAugmentation',augmenter);

% Resizing all testing images to [224 224] for ResNet architecture
augtestimds = augmentedImageDatastore([224 224],imdsTest);

% Training Options, we choose a small mini-batch size due to limited images
options = trainingOptions('adam',...
    'MaxEpochs',8,'MiniBatchSize',32,...
    'Shuffle','once', ...
    'InitialLearnRate',0.01, ...,
    'ValidationData',augtestimds,...
    'ExecutionEnvironment','gpu',...

```

```

'Verbose',false, ...
'Plots','training-progress');

% Training
netTransfer = trainNetwork(auiimds,lgraph,options);

% Testing and their corresponding Labels and Posterior for each Case
[predicted_labels(test_idx),posterior(test_idx,:)] =
classify(netTransfer,augtestimds);

% Save the Independent ResNet Architectures obtained for each Fold
save(sprintf('ResNet101_%d_among_%d_folds',fold_idx,num_folds),'netTransfer','tes
t_idx','train_idx');

% Clearing unnecessary variables
clearvars -except fold_idx num_folds num_images predicted_labels posterior
imds netTransfer;

end
save('ResNet101_WS');
%% Confusion matrix Validation set

total_split=countEachLabel(imds);

%% _____ Confusion matrix _____
% Actual Labels
actual_labels=imds.Labels;

% Confusion Matrix
figure;

```

```

plotconfusion(actual_labels,predicted_labels')
title('Confusion Matrix: ResNet');

%% Predict data
% Images Datapath – Please modify your path accordingly
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\2.Testing';
Predictimds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');
augtestPredict = augmentedImageDatastore([224 224],Predictimds);
[YPred,scores] = classify(netTransfer,augtestPredict);

Actual_Testing = Predictimds.Labels;

% Confusion Matrix
figure;
plotconfusion(Actual_Testing,YPred)
title('Confusion Matrix: ResNet-101')

%-----END-----

```

โค้ด Matlab R.2019 สำหรับการสร้าง Deep Learning Model ด้วยอัลกอริทึม Inception-v3

Model Inception-v3

```
clear; close all; clc;

net = inceptionv3;
lgraph = layerGraph(net);
gpuDevice(1)

net.Layers%% MC learning section

%Reference code
%https://blogs.mathworks.com/deep-learning/2020/03/18/deep-learning-for-
medical-imaging-covid-19-detection/?fbclid=IwAR1Cbzv7EPKZHlpKk-
mhX1bH863i_K6o4Wn1umthT1FVRdIAAt-DQcXDrp0Q

% Clear workspace
clear; close all; clc;

% Images Datapath – Please modify your path accordingly
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\1.Training';

% Image Datastore (??? Sub folder ?????????????? Class ??????????)
imds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

%


---




---



% Determine the split up
total_split=countEachLabel(imds);
```

```
% Number of Images
num_images=length(imds.Labels);

num_folds=4;

% Loop for each fold
for fold_idx=1:num_folds

    gpuDevice(1)

    fprintf('Processing %d among %d folds \n',fold_idx,num_folds);

    % Test Indices for current fold
    test_idx=fold_idx:num_folds:num_images;

    % Test cases for current fold
    imdsTest = subset(imds,test_idx);

    % Train indices for current fold
    train_idx=setdiff(1:length(imds.Files),test_idx);

    % Train cases for current fold
    imdsTrain = subset(imds,train_idx);

    % Inception-v3 Architecture
    net=inceptionv3;
    lgraph = layerGraph(net);
    clear net;

    % Number of categories
    numClasses = numel(categories(imdsTrain.Labels));
```



```

% New Learnable Layer
newLearnableLayer = fullyConnectedLayer(numClasses, ...
    'Name','new_fc', ...
    'WeightLearnRateFactor',10, ...
    'BiasLearnRateFactor',10);

% Replacing the last layers with new layers
lgraph = replaceLayer(lgraph,'predictions',newLearnableLayer);
newsoftmaxLayer = softmaxLayer('Name','new_softmax');
lgraph = replaceLayer(lgraph,'predictions_softmax',newsoftmaxLayer);
newClassLayer = classificationLayer('Name','new_classoutput');
lgraph = replaceLayer(lgraph,'ClassificationLayer_predictions',newClassLayer);

% Data Augmentation
augmenter = imageDataAugmenter('RandXReflection',1,...
    'RandYReflection',1,...
    'RandXTranslation', [0 0]);

% Resizing all training images to [299 299] for Inception-v3 architecture
auidms = augmentedImageDatastore([299
299],imdsTrain,'DataAugmentation',augmenter);

% Resizing all testing images to [299 299] for Inception-v3 architecture
augtestimds = augmentedImageDatastore([299 299],imdsTest);

% Training Options, we choose a small mini-batch size due to limited images
options = trainingOptions('adam',...
    'MaxEpochs',8,'MiniBatchSize',32,...
    'Shuffle','once', ...
    'InitialLearnRate',0.01, ...,
    'ValidationData',augtestimds,...

```

```

'ExecutionEnvironment','gpu',...
'Verbose',false, ...
'Plots','training-progress');

% Training
netTransfer = trainNetwork(auimds,lgraph,options);

% Testing and their corresponding Labels and Posterior for each Case
[predicted_labels(test_idx),posterior(test_idx,:)] =
classify(netTransfer,augtestimds);

% Save the Independent ResNet Architectures obtained for each Fold
save(sprintf('InceptionV3_3CLASS%d_among_%d_folds',fold_idx,num_folds),'netTransfer','test_idx','train_idx');

% Clearing unnecessary variables
clearvars -except fold_idx num_folds num_images predicted_labels posterior
imds netTransfer;

end
save('Inception_V3WS');
%% Confusion matrix

total_split=countEachLabel(imds);

%% _____ Confusion matrix _____

% Actual Labels
actual_labels=imds.Labels;

% Confusion Matrix

```

```

figure;
plotconfusion(actual_labels,predicted_labels')
title('Confusion Matrix: Inception v3');

%% Predict data
% Images Datapath – Please modify your path accordingly
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\2.Testing';
Predictimds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');
augtestPredict = augmentedImageDatastore([299 299],Predictimds);

[YPred,scores] = classify(netTransfer,augtestPredict);

Actual_Testing = Predictimds.Labels;

% Confusion Matrix
figure;
plotconfusion(Actual_Testing,YPred)
title('Confusion Matrix: Inception v3')

%-----END-----

```

โค้ด Matlab R.2019 สำหรับการสร้าง Deep Learning Model ด้วยอัลกอริทึม Xception

Model Xception

```
clear; close all; clc;

net = xception;

lgraph = layerGraph(net);

gpuDevice(1)

net.Layers%% MC learning section

%Reference code
%https://blogs.mathworks.com/deep-learning/2020/4/18/deep-learning-for-
medical-imaging-covid-19-detection/?fbclid=IwAR1Cbzv7EPKZHlpKk-
mhX1bH863i_K6o4Wn1umthT1FVRdIAAt-DQcXDrp0Q

% Clear workspace
clear; close all; clc;

% Images Datapath – Please modify your path accordingly
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\1.Training';

% Image Datastore
imds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

%

% Determine the split up
total_split=countEachLabel(imds);
```

```
% Number of Images
num_images=length(imds.Labels);

num_folds=4;

% Loop for each fold
for fold_idx=1:num_folds

    gpuDevice(1)

    fprintf('Processing %d among %d folds \n',fold_idx,num_folds);

    % Test Indices for current fold
    test_idx=fold_idx:num_folds:num_images;

    % Test cases for current fold
    imdsTest = subset(imds,test_idx);

    % Train indices for current fold
    train_idx=setdiff(1:length(imds.Files),test_idx);

    % Train cases for current fold
    imdsTrain = subset(imds,train_idx);

    % Xception Architecture
    net=xception;
    lgraph = layerGraph(net);
    clear net;

    % Number of categories
    numClasses = numel(categories(imdsTrain.Labels));
```

```

% New Learnable Layer
newLearnableLayer = fullyConnectedLayer(numClasses, ...
    'Name','new_fc', ...
    'WeightLearnRateFactor',10, ...
    'BiasLearnRateFactor',10);

% Replacing the last layers with new layers
lgraph = replaceLayer(lgraph,'predictions',newLearnableLayer);
newsoftmaxLayer = softmaxLayer('Name','new_softmax');
lgraph = replaceLayer(lgraph,'predictions_softmax',newsoftmaxLayer);
newClassLayer = classificationLayer('Name','new_classoutput');
lgraph = replaceLayer(lgraph,'ClassificationLayer_predictions',newClassLayer);

% Data Augmentation
augmenter = imageDataAugmenter('RandXReflection',1,...
    'RandYReflection',1,...
    'RandXTranslation', [0 0]);

% Resizing all training images to [299 299] for xception architecture
auidms = augmentedImageDatastore([299
299],imdsTrain,'DataAugmentation',augmenter);

% Resizing all testing images to [299 299] for Nxception architecture
augtestimds = augmentedImageDatastore([299 299],imdsTest);

% Training Options, we choose a small mini-batch size due to limited images
options = trainingOptions('adam',...
    'MaxEpochs',8,'MiniBatchSize',32,...
    'Shuffle','once', ...
    'InitialLearnRate',0.01, ...,
    'ValidationData',augtestimds,...

```



```

'ExecutionEnvironment','gpu',...
'Verbose',false, ...
'Plots','training-progress');

% Training
netTransfer = trainNetwork(auimds,lgraph,options);

% Testing and their corresponding Labels and Posterior for each Case
[predicted_labels(test_idx),posterior(test_idx,:)] =
classify(netTransfer,augtestimds);

% Save the Independent ResNet Architectures obtained for each Fold
save(sprintf('Xception3Class_%d_among_%d_folds',fold_idx,num_folds),'netTransfer
','test_idx','train_idx');

% Clearing unnecessary variables
clearvars -except fold_idx num_folds num_images predicted_labels posterior
imds netTransfer;

end
save('XceptionV3WS');
%% Confusion matrix

total_split=countEachLabel(imds);

%% _____ Confusion matrix _____

% Actual Labels
actual_labels=imds.Labels;

% Confusion Matrix

```

```

figure;
plotconfusion(actual_labels,predicted_labels')
title('Confusion Matrix: Xception');

%% Predict data
% Images Datapath – Please modify your path accordingly (????????????????????)
Training)
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\2.Testing';
Predictimds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');
augtestPredict = augmentedImageDatastore([299 299],Predictimds);

[YPred,scores] = classify(netTransfer,augtestPredict);

Actual_Testing = Predictimds.Labels;

% Confusion Matrix
figure;
plotconfusion(Actual_Testing,YPred)
title('Confusion Matrix: Xception')

%% Change color
classl = 1;
Endloops = length(Predictimds.Labels);
for l = 1:Endloops
    img = readimage(Predictimds,classl);
    imshow(img);

```

```

temptb = table(YPred);
posa = temptb{classl,:};

if posa == "1Notgood"
    img2 = rgb2gray(img);
    T = graythresh(img2);
    bw = im2bw(img2,T);
    grayImage = uint8(255 * bw);

    background = grayImage == 0; % Find black pixels.
    redChannel = grayImage;
    redChannel(background) = 255; % Set black pixels to max value.
    % Create true color image.
    rgbImage = cat(3, redChannel, grayImage, grayImage);
    imshow(rgbImage); % Display it.
    imwrite(rgbImage, strcat(num2str(classl),'.jpg'), 'jpg');

    % subfolderindex = "D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity
classification project\0.Dataset\Machine Learning seperate";
    % folderindex = num2str(classl);
    % fullfolder = fullfile(subfolderindex, folderindex);
    % mkdir (fullfolder)
    % imwrite(rgbImage, strcat('/', folderindex, "Image", num2str(classl), '.jpg'), 'jpg');

elseif posa == "2Good"

    img2 = rgb2gray(img);
    T = graythresh(img2);
    bw = im2bw(img2,T);
    grayImage = uint8(255 * bw);

```

```

background = grayImage == 0; % Find black pixels.
blueChannel = grayImage;
blueChannel(background) = 255; % Set black pixels to max value.
% Create true color image.
rgbImage = cat(3, grayImage, grayImage, blueChannel);
imshow(rgbImage); % Display it.
imwrite(rgbImage, strcat(num2str(classl), '.jpg'), 'jpg');

else
    img2 = rgb2gray(img);
    T = graythresh(img2);
    bw = im2bw(img2, T);
    grayImage = uint8(255 * bw);

    background = grayImage == 0; % Find black pixels.
    greenChannel = grayImage;
    greenChannel(background) = 255; % Set black pixels to max value.
    % Create true color image.
    rgbImage = cat(3, grayImage, greenChannel, grayImage);
    imshow(rgbImage); % Display it.
    imwrite(rgbImage, strcat(num2str(classl), '.jpg'), 'jpg');

end
classl = classl+1;
end

%% Predict data -----ALL-----
% Images Datapath – Please modify your path accordingly (??????????????????
Training)
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data

```

```
setALL_TRAINING_3_INCAUG\3.Testing_All';
Predictimds_all =imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');
augtestPredict_all = augmentedImageDatastore([299 299],Predictimds_all);

[YPred_All,scores_All] = classify(netTransfer,augtestPredict_all);

Actual_Testing_all = Predictimds_all.Labels;

% Confusion Matrix
figure;
plotconfusion(Actual_Testing_all,YPred_All)
title('Confusion Matrix: Xception')

%-----END-----
```

โค้ด Matlab R.2019 สำหรับการสร้าง Deep Learning Model ด้วยอัลกอริทึม GoogLeNet

```
clear; close all; clc;

net = googlenet;
lgraph = layerGraph(net);
net.Layers%% MC learning section
%Reference code
%https://blogs.mathworks.com/deep-learning/2020/03/18/deep-learning-for-
medical-imaging-covid-19-detection/?fbclid=IwAR1Cbzv7EPKZHlpKk-
mhX1bH863i_K6o4Wn1umthT1FVRdIAAt-DQcXDrp0Q

% Clear workspace
clear; close all; clc;

% Images Datapath – Please modify your path accordingly (?????????????????)
Training)
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\1.Training';

% Image Datastore (??? Sub folder ?????????????? Class ??????????)
imds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

%
%
%
% Determine the split up
total_split=countEachLabel(imds);
```



```
% Number of Images
num_images=length(imds.Labels);

num_folds=4;

% Loop for each fold
for fold_idx=1:num_folds

    gpuDevice(1)

    fprintf('Processing %d among %d folds \n',fold_idx,num_folds);

    % Test Indices for current fold
    test_idx=fold_idx:num_folds:num_images;

    % Test cases for current fold
    imdsTest = subset(imds,test_idx);

    % Train indices for current fold
    train_idx=setdiff(1:length(imds.Files),test_idx);

    % Train cases for current fold
    imdsTrain = subset(imds,train_idx);

    % GoogLeNet Architecture
    net=googlenet;
    lgraph = layerGraph(net);
    clear net;

    % Number of categories
    numClasses = numel(categories(imdsTrain.Labels));
```

```

% New Learnable Layer
newLearnableLayer = fullyConnectedLayer(numClasses, ...
    'Name','new_fc', ...
    'WeightLearnRateFactor',10, ...
    'BiasLearnRateFactor',10);

% Replacing the last layers with new layers
lgraph = replaceLayer(lgraph,'loss3-classifier',newLearnableLayer);
newsoftmaxLayer = softmaxLayer('Name','new_softmax');
lgraph = replaceLayer(lgraph,'prob',newsoftmaxLayer);
newClassLayer = classificationLayer('Name','new_classoutput');
lgraph = replaceLayer(lgraph,'output',newClassLayer);

% Data Augmentation (Augmentation code ??????????????)
augmenter = imageDataAugmenter('RandXReflection',1,...
    'RandYReflection',1,...
    'RandXTranslation', [0 0]);

% Resizing all training images to [224 224] for GoogleNet architecture
auidms = augmentedImageDatastore([224
224],imdsTrain,'DataAugmentation',augmenter);

% Resizing all testing images to [224 224] for GoogleNet architecture
augtestimds = augmentedImageDatastore([224 224],imdsTest);

% Training Options, we choose a small mini-batch size due to limited images
options = trainingOptions('adam',...
    'MaxEpochs',8,'MiniBatchSize',32,...
    'Shuffle','once', ...
    'InitialLearnRate',0.01, ...,
    'ValidationData',augtestimds,...

```

```

'ExecutionEnvironment','gpu',...
'Verbose',false, ...
'Plots','training-progress');

% Training
netTransfer = trainNetwork(auidms,lgraph,options);

% Testing and their corresponding Labels and Posterior for each Case
[predicted_labels(test_idx),posterior(test_idx,:)] =
classify(netTransfer,augtestimds);

% Save the Independent ResNet Architectures obtained for each Fold
save(sprintf('GoogLeNet_%d_among_%d_folds',fold_idx,num_folds),'netTransfer','tes
t_idx','train_idx');

% Clearing unnecessary variables
clearvars -except fold_idx num_folds num_images predicted_labels posterior
imds netTransfer;

end
save('GoogLeNet_WS');
%% Confusion matrix

total_split=countEachLabel(imds);

%% _____ Conduction matrix _____

% Actual Labels
actual_labels=imds.Labels;

% Confusion Matrix

```

```

figure;
plotconfusion(actual_labels,predicted_labels')
title('Confusion Matrix: GoogleNet');

%% Confusion matrix

total_split=countEachLabel(imds);

%% Confusion matrix
% Actual Labels
actual_labels=imds.Labels;

% Confusion Matrix
figure;
plotconfusion(actual_labels,predicted_labels')
title('Confusion Matrix: GoogleNet');

%% Predict data
% Images Datapath – Please modify your path accordingly (???????????????????)
Training)
datapath='D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity classification
project\0.Dataset\0.Experiment result\3 Class Data
set\ALL_TRAINING_3_INCAUG\2.Testing';
Predictimds=imageDatastore(datapath, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');
augtestPredict = augmentedImageDatastore([224 224],Predictimds);

[YPred,scores] = classify(netTransfer,augtestPredict);

Actual_Testing = Predictimds.Labels;

```

```
% Confusion Matrix  
figure;  
plotconfusion(Actual_Testing,YPred)  
title('Confusion Matrix: GoogleNet')
```



โค้ด Matlab R.2019 สำหรับการสร้างการทำ Image Processing เพื่อทำภาพ Binarization

Image processing code

```
clc;
A = 221;
B = 242;

while A<=B

    Impimage = imread(A+".JPG");
    Greyimage = rgb2gray(Impimage);
    Adpvalue = adaptthresh(Greyimage,1);

    BWImage = imbinarize(Greyimage,Adpvalue);
    subfolderindex = "D:\1.Work\2.Master_degree_MIT\0.Thesis\1.Porosity
classification project\0.Dataset\Sub_Image_Folder\RES896";
    folderindex = num2str(A);
    fullfolder = fullfile(subfolderindex,folderindex);
    mkdir (fullfolder)

    imwrite(Greyimage,strcat(folderindex,'/',folderindex,'Grey.jpg'),'jpg');
    imwrite(BWImage,strcat(folderindex,'/',folderindex,'Adp.jpg'),'jpg');
    histfigure = figure;
    imhist(Greyimage);
    saveas(histfigure,strcat(folderindex,'/',folderindex,'Hist.jpg'),'jpg');

    %----- Change BW to gray scale for 3 layer in ML -----

    BWImage3layer = uint8(255 * BWImage);
    I = BWImage3layer;
```



```

Image = cat(3,I,I,I);

%Image = exposure500BW;

[Image_Height,Image_Width,Number_Of_Colour_Channels] = size(Image);

%----- Define sub image size for ML-----

Block_Size = 896;
Number_Of_Blocks_Vertically = floor(Image_Height/Block_Size);
Number_Of_Blocks_Horizontally = floor(Image_Width/Block_Size);
Image_Blocks = struct('Blocks',[]);

Index = 1;
for Row = 1: +Block_Size: Number_Of_Blocks_Vertically*Block_Size
    for Column = 1: +Block_Size: Number_Of_Blocks_Horizontally*Block_Size

        Row_End = Row + Block_Size - 1;
        Column_End = Column + Block_Size - 1;

        if Row_End > Image_Height
            Row_End = Image_Height;
        end

        if Column_End > Image_Width
            Column_End = Image_Width;
        end

        Temporary_Tile = Image(Row:Row_End,Column:Column_End,:);

        %Storing blocks/tiles in structure for later use%
        Image_Blocks(Index).Blocks = Temporary_Tile;
    end
end

```

```
subplot(Number_Of_Blocks_Vertically,Number_Of_Blocks_Horizontally,Index);
imshow(Temporary_Tile);
Index = Index + 1;

end

end

for Block_Index = 1: length(Image_Blocks)

imwrite(Image_Blocks(Block_Index).Blocks, strcat(folderindex, '/', folderindex, "Image", num2str(Block_Index), '.jpg'), 'jpg');

end
A = A+1;
end
```

ภาคผนวก ข.

การตีพิมพ์ผลงานวิจัย

TNI

ได้เข้าร่วมและตีพิมพ์งานวิจัยในงานประชุมวิชาการ IEEECON 2022

**The 2022 International
Electrical Engineering Congress**

IEEECON 2022

**9-11 March 2022
Khon Kaen, Thailand**

Avani Khon Kaen Hotel & Convention Centre

Sponsors and Partners:

- Kumwell
- iRCT
- ESSCO
- Hitachi Energy
- NRCT
- AD AUTO DIDACTIC CO., LTD.
- EGAT
- THAIPLCCENTER
- THAI INSTITUTE OF TECHNOLOGY
- THAI ENGINEERING ASSOCIATION (THAEEA)
- THAI-GERMAN FACULTY OF ENGINEERING
- ENGINEERING CHANG MAI UNIVERSITY
- IEEE PHOTONICS SOCIETY THAILAND CHAPTER
- TOPS THAILAND OPTICS & PHOTONICS SOCIETY
- IEEE PES POWER & ENERGY SOCIETY THAILAND CHAPTER
- 40th ANNIVERSARY IEEE THAILAND SECTION

Computer and Information Technology

Paper ID: P01653

Powder Metallurgy Microstructure Classification Using Image Processing and Deep Learning Techniques

Khattipong Usamran¹ Sapransit Mruetusatorn²
Thai-Nichi Institute of Technology
E-mail: ¹us.khattipong_st@tni.ac.th ²sapransit@tni.ac.th

Abstract

Evaluation of the fusion characteristic of the sintering neck is important to indicate the quality of metal workpieces forming with powder metallurgy. The quality is analyzed by microstructure images after forming. Currently, quality evaluation is primarily performed by experts without a clear standard; as a result, the goal of this study aims to present the application of image processing and deep learning based on the CNN (Convolution neural network) to develop a model to evaluate sintering neck using the characteristics of pores in microstructure images. Images evaluated by three metallurgical experts were utilized in a prototype for creating the deep learning model. The research measured the results of accuracy and time used in creating the model using five different algorithms. As the result, the accuracy range of 94-98% was obtained, except for the model generated by GoogLeNet which was unable to classify image types of pores, and ResNet-50 spent the shortest time constructing the deep learning model among all four models.

Keywords—Powder metallurgy, Image processing, Convolutional Neural Network



92 IEEECON The 2022 International
2022 Electrical Engineering Congress

TNI

Powder Metallurgy Microstructure Classification Using Image Processing and Deep Learning Techniques

Khattipong Usanran¹ Sapransit Mruetusatorn²

Thai-Nichi Institute of Technology

E-mail: ¹us.khattipong_st@tni.ac.th ²sapransit@tni.ac.th

Abstract

Evaluation of the fusion characteristic of the sintering neck is important to indicate the quality of metal workpieces forming with powder metallurgy. The quality is analyzed by microstructure images after forming. Currently, quality evaluation is primarily performed by experts without a clear standard; as a result, the goal of this study aims to present the application of image processing and deep learning based on the CNN (Convolution neural network) to develop a model to evaluate sintering neck using the characteristics of pores in microstructure images. Images evaluated by three metallurgical experts were utilized in a prototype for creating the deep learning model. The research measured the results of accuracy and time used in creating the model using five different algorithms. As the result, the accuracy range of 94-98% was obtained, except for the model generated by GoogLeNet which was unable to classify image types of pores, and ResNet-50 spent the shortest time constructing the deep learning model among all four models.

Keywords: Powder metallurgy, Image processing, Convolutional Neural Network

1. Introduction

Powder metallurgy is a type of workpiece forming method used in the metal industry. The process begins with taking metal powder into compacting process using a die, followed by the sintering of the workpiece to obtain the desired workpiece. The overall process is called compacted sintering of powder metallurgy. Metal forming quality inspection is conducted using mechanical property testing. Image analysis of the microstructure of the workpiece that passes the forming process using powder metallurgy is evaluated in several features such as metal phase after forming and fusing characteristic of sintering neck is analyzed from the shape of pores in the microstructure images. The characteristic of microstructure can indicate density, production process, the quality of the workpiece including the strength of the workpiece passed forming process. [1]

Currently, there is no certain standard for the quality evaluation procedure for the quality of the sintering neck. The quality evaluation procedure relies on metal experts who use microstructure photographs to determine if the quality of the sintering neck received after forming is good or bad. Currently, image processing techniques are used in the research to analyze microstructures, such as research that compared amount measurement of pores using the ImageJ program to find the metal density, then compared the value to a traditional measurement by

weighting [2] or research that created a model to analyze the type of metal texture from images by combining image processing with FCNN (Fully Convolutional Neural Network) [3]. In addition to metal researches, there was geoscience research that used image processing techniques to analyze pores such as research that used CNN to create a machine learning model by image dataset to classify types of soil horizons.

Because of the aforementioned factors, a deep learning model is aimed and created, which can analyze the sintering neck using an expert evaluation as a reference.

2. Relevant Researches

In this part, some related researches were studied and divided into two topics: researches related to the application of image processing techniques and deep learning in metal works as well as geological research with similar image datasets. Currently, image processing and deep learning techniques have been used in metal works for convenience purposes, such as counting product quantity using image processing [4][5], metal texture analysis using CNN (Convolution neural network) to create a machine learning model [3], and analysis of pore quantity in metal texture using microstructure to process because the quantity and shape of pores directly affect the strength [6] or fatigue resistance of metal powder [7]. According to the aforementioned researches, the use of image processing and deep learning techniques in the metal industry is on the rise.

In addition to metallurgical researches, there were geological researches that analyzed images of soil horizons for pore evaluation. Deep learning was used to evaluate what types of soil were present in the images. The shape and size of the pores in images were used to analyze the soil types. Rafael [8] applied CNN to create a machine learning model. The model was created by using microstructure images of various types of soil horizons to classify soil horizons. Fernando's research [9] employed computer-generated simulation images of pores in soil horizons to create a learning dataset in the model, then used actual geological images as a testing set to evaluate the model's correctness. In addition, some researches compared mechanisms using deep learning in terms of accuracy performance and resources used to create the machine learning model [10].

In this paper, five architectures of deep learning were chosen by the criteria of low computational cost, which includes ResNet-50, ResNet-101, Inception-v3, Xception and GoogLeNet. In addition, the first four gave relatively high accuracy. However, the last one used the least resource.




Figure 1 Diagram of the Methodology.

From the review, some geological works analyzed the microstructure of soil horizon using the deep learning model of CNN. The structure of the soil horizon can be considered similar to the pores in powder metallurgy. Therefore this research presents the method using CNN to evaluate the quality of sintering neck based on the characteristic of pores in microstructure images of which quality was evaluated and classified by metallurgy experts.

3. Dataset and Methodology

The image processing techniques were applied and the deep learning model was created by taking a microstructure image dataset to process image data to remove the images unneeded composition. After that, submitted into the deep learning process, as seen in Figure 1.

3.1 Image Dataset

Acme International (Thailand) Ltd donated the image dataset consisting of 175 microstructure images of a metal workpiece low carbon steel type formed by powder metallurgy in the forming procedure. The photos were magnified 100 times (100X), with a resolution of 3656x2740 pixels and a DPI value (Dots per inch) of 96 DPI. The composition of microstructure images consisted of pores (black), metal texture (white), and noise occurring from the workpiece preparation process such as water stain, grinding mark of sandpaper, and reflection from the lights in the room that took images, as shown in Figure 2. If there is an anomaly in the images, image processing must be used to remove the images' unneeded composition.

3.2 Image Processing

In the image processing, abnormal composition images were eliminated by converting the images to binary images with the adaptive thresholding process.

The intensity value of general abnormalities is lower than pores. Therefore, when the microstructure images with abnormal composition were taken into the adaptive thresholding process, those abnormalities were evaluated as a metal texture, which corresponded to the fact that abnormalities would emerge on a metal phase, not on pores.

Example: Water stain arose from the workpiece preparation process for taking microstructure images.




Figure 2 Before-After Images of Binarization.

3.3 Dataset Preparation

In this process, microstructure images with the resolution of 3650x2740 pixels were cropped to 3584x2688 pixels and then segregated the images from sub-images into 12 images with the resolution of 896x896 pixels and allowed three experts to conduct labeling that which classes those images were in. The classes were divided into 3 classes: pore types that were Not Good, Good, and Very Good. Microstructure images in this research were classified according to example guidelines from Honganes company shown in Figure 3 to be used as a dataset to create a deep learning model in the following step.




Figure 3 Example Images (Guideline) used to evaluate pores.

3.4 Creation Process of Deep Learning Model

The image results that were conducted the labeling by experts are in Table 1. The images that three experts gave the same opinion would be used to create a deep learning model. These images will be conducted in augmentation at 90°, 180°, and 270°. The total number of images after the augmentation procedure was 2864. These images would be used to create a deep learning model.

Table 1 Number of Images used in Training Model.

Class	Expert 1	Expert 2	Expert 3	Same vote	Data Augmented
1.Not Good	478	1758	1274	463	1852
2.Good	1538	258	685	169	676
3.Very Good	84	84	141	84	336
Total	2100	2100	2100	716*	2864*

Note : 716 Images are augmented to 2864 images

After that, the images from which three experts had the same opinion after Augmentation would be submitted into the deep learning process. According to the [10] "Benchmark Analysis of Representative Deep Neural Network Architectures", ResNet-50, ResNet-101, Inception-v3, Xception show high accuracy and not too much memory for creating training models. GoogLeNet is chosen from utilizing low memory for checking in the coding process but GoogLeNet accuracy result is lower and layers are fewer than other models. The learning rate was set to 0.01, and the mini-batch size value was set to 32. The dataset divided learning into 4 sets 3 sets for Training and 1 set for random validation and then the training model was conducted four times using K-Fold cross validation[11] to reduce the possible bias of the training set, as shown in Figure 4. ReLu (rectified linear unit) activation function is utilized in all model as shown in Figure 5.




Figure 4 Number of Procedures for Creating Training Model.

978-1-6654-0206-4/22/\$31.00 © 2022 IEEE




Figure 5 Deep learning model architecture

3.5 Evaluation Process

Evaluation of deep learning results was conducted by accuracy values, Confusion Matrix[12], and time spent creating the learning in each mechanism of the deep learning model. The accuracy values were obtained by using the testing set, which included 282 pore images that were evaluated by three experts, all of whom gave the same opinion. There were 169 images of Not Good pores, 65 images of Good pores, and 48 images of Very Good pores among the pore images.

4. Results

The outcomes of the accuracy values acquired from testing the dataset are shown in the graph in Figure 6. The average accuracy of presuming the characteristic of each type of pores (Recall) is shown in the graphs in Figures 7 and 8. The time spent creating the deep learning model (minute) is shown in Table 2. The durations were arranged from the most spent time to the least spent time.




Figure 6 The Overall Accuracy Values in Each Deep Learning Model.




Figure 7 Accuracy Values Classified by Classes in Each Validation Set.




Figure 8 Accuracy Values Classified by Classes in Each Testing Set.

Table 2 The Time Spent Creating the Deep Learning Model (Minute).

Model	Fold 1	Fold 2	Fold 3	Fold 4	Total
Xception	56	56	56	57	225
ResNet-101	35	39	39	40	156
Inception-v3	18	19	19	19	75
ResNet-50	11	12	11	11	45
GoogLeNet	5	5	5	5	20

Confusion Matrix : GoogLeNet (Validation set)				
Output Class	Not Good	1852 64.7%	676 23.6%	336 11.7%
	Good	0 0.0%	0 0.0%	0 0.0%
	Very Good	0 0.0%	0 0.0%	0 0.0%
	Accuracy	100% 0.0%	0% 100.0%	0% 100.0%
Target Class				
	Not Good	Good	Very Good	Accuracy

Figure 9 Confusion Matrix of GoogLeNet of Validation Set.

Confusion Matrix: GoogLeNet (Testing set)				
Output Class	Not Good	169 59.9%	65 23.0%	48 17.0%
	Good	0 0.0%	0 0.0%	0 0.0%
	Very Good	0 0.0%	0 0.0%	0 0.0%
	Accuracy	100% 0.0%	0% 100.0%	0% 100.0%
Target Class				
	Not Good	Good	Very Good	Accuracy

Figure 10 Confusion Matrix of GoogLeNet of Testing Set.

5. Discussion and Conclusion

The testing result of the deep learning model in terms of classification of pores is shown in Figure 6. The results had accuracy values in the validation process at 96.6% to 97.9% except for GoogLeNet, which had the accuracy value in the validation process at 64.7%. Because the model could not classify the types of pores as shown on the Confusion matrix, so all images were seen as Not Good pores, as shown in the graph in Figure 7. The ResNet-50 model provided a maximum accuracy value of 97.9%.

As shown in Figure 6, the accuracy values obtained from the testing set are at 94.0% to 98.9%. The GoogLeNet model was unable to classify the different types of pores as the same as an image dataset used in the validation process as shown in Figures 9 and 10. The model with maximum accuracy value that used testing data was Inception-v3. It provided the accuracy value of the model at 98.9%, as shown in Figure 6.

From the accuracy-test data of both validation and testing datasets, it could be concluded that ResNet-50 and Inception-v3 models provided similar accuracy values between 96% to 98%; nevertheless, they were not significantly different from other models. Their durations spent creating the deep learning model were 45 and 75 minutes as shown in Table 2, respectively. The GoogLeNet model was a model that could not classify between different types of pores.

6. Future Improvement

Table 1 shows that the opinions of the three experts in terms of pore evaluation were different. The different opinions between Not Good pores and Good pores were very close; thus, in accuracy classification became more difficult. This was due to the different work experiences of the experts, which resulted in different evaluations of pores. Future research should have more experts to increase the weight and the obviousness of the probability of pore images. Furthermore, this research considered creating a deep learning model from an image dataset that experts provided the same opinion and created a basic deep learning model. It should, however, take into account the dataset that experts provided different opinions in the future.

Acknowledgment

The authors would like to thank Acme International (Thailand) for supporting and providing the image dataset used in this research and three evaluation experts whom the company coordinated.

Reference

- [1] Metal powder industries federation, MPIF STANDARD 35-SP 2018 Edition Materials standards for PM structural parts. 2018.
- [2] M. Marin and F. B. Marin, "Quantitative image analysis in some iron powder metallurgy materials," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 485, p. 012011, Mar. 2019, doi: 10.1088/1757-899X/485/1/012011.

- [3] S. M. Azimi, D. Britz, M. Engstler, M. Fritz, and F. Mücklich, "Advanced Steel Microstructural Classification by Deep Learning Methods," *Sci. Rep.*, vol. 8, no. 1, p. 2128, Dec. 2018, doi: 10.1038/s41598-018-20037-5.
- [4] Zhang Xinman, Ma Mei, He Tingting, and Xu Xuebin, "Steel bar Counting method based on image and video processing," presented at the 2017 International Symposium on Intelligent Signal Processing and Communication Systems, November 6-9, 2017, Xiamen, China, Jun. 2017.
- [5] X. Yan and X. Chen, "Research on the Counting Algorithm of Bundled Steel Bars Based on the Features Matching of Connected Regions," in 2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC), Chongqing, Jun. 2018, pp. 11–15, doi: 10.1109/ICIVC.2018.8492784.
- [6] T. M. Cimino, A. H. Graham, and T. F. Murphy, "The effect of microstructure and pore morphology on mechanical and dynamic properties of ferrous PIM materials," p. 14, Jun. 1998.
- [7] J. Park et al., "Complex effects of alloy composition and porosity on the phase transformations and mechanical properties of powder metallurgy steels," *Powder Technol.*, vol. 284, pp. 459–466, Nov. 2015, doi: 10.1016/j.powtec.2015.07.029.
- [8] R. Amay, J. Hernández-Aceituno, and C. Mallof, "Soil micromorphological image classification using deep learning: The porosity parameter," *Appl. Soft Comput.*, vol. 102, p. 107093, Apr. 2021, doi: 10.1016/j.asoc.2021.107093.
- [9] F. Bordignon, L. de Figueiredo, R. Exterkoetter, B. Rodrigues, and M. Duarte, "Deep Learning for Grain Size and Porosity Distributions Estimation on micro-CT Images," in *Proceedings of the 16th International Congress of the Brazilian Geophysical Society&Expogef*, 2019, pp. 1–6, doi: 10.22564/16cisbgf2019.209.
- [10] S. Bianco, R. Cadene, L. Celona, and P. Napoletano, "Benchmark Analysis of Representative Deep Neural Network Architectures," *IEEE Access*, vol. 6, pp. 64270–64277, 2018, doi: 10.1109/ACCESS.2018.2877890.
- [11] Y. Jung and J. Hu, "A K-fold averaging cross-validation procedure," *J. Nonparametric Stat.*, vol. 27, no. 2, pp. 167–179, Apr. 2015, doi: 10.1080/10485252.2015.1010532.
- [12] S. Visa, B. Ramsay, and A. Ralescu, "Confusion Matrix-based Feature Selection," p. 9., 2011.



ภาคผนวก ค.

รายละเอียดเอกสารประกอบการนำเสนอสอบป้องกันวิทยานิพนธ์

TNI

Slide no. 1

Powder Metallurgy Microstructure Classification Using Image Processing and Deep Learning Techniques

การคัดแยกโครงสร้างทางจุลภาคของโลหะที่ผ่านกรรมวิธีผงด้วยเทคนิค การประมวลผลข้อมูลภาพ และการเรียนรู้เชิงลึก

Khattipong Usamran

ID : 1963150089

Slide no. 2

Outline



Chapter 1

Introduction

- Background
- Objective
- Problem statement
- Benefit
- Scope



Chapter 2

Literature review

- Powder metallurgy researches
- Image processing researches
- Machine learning researches



Chapter 3

Research Methodology

- Data set preparation and image processing
- Labeling process
- Deep learning model creation
- Evaluation process



Chapter 4

Result and Analysis

- Main scope result
- Additional scope result



Chapter 5

Conclusion

- Conclusion

Slide no. 3

Chapter 1

Introduction




Slide no. 4

Background

Powder metallurgy : เป็นศาสตร์การขึ้นโลหะประเภทหนึ่ง
ในปัจจุบัน ที่นำผงโลหะ --> เฝ้านี้ก --> ออกมาเป็นชิ้นงาน

Metal powder Sintering Product




ภาพกระบวนการการขึ้นรูปโลหะผง



ตัวอย่างภาพชิ้นงาน Final product

Background

Trend การเติบโตของอุตสาหกรรมโลหะผง โดยการเติบโตสูงสุดเป็นอุตสาหกรรม Aerospace และ Defense



Benefit :

- สามารถขึ้นรูปชิ้นงานที่ซับซ้อนได้ง่าย



- สามารถควบคุมส่วนผสมทางเคมีได้ง่าย



Background

- Material testing :
- Mechanical testing (Tensile strength, Hardness testing, etc)
 - Microstructure analysis (Sintering neck analysis, Phase analysis)

ตัวอย่างการทดสอบทางกล (Mechanical property testing)



กระบวนการทดสอบความแข็งแรงของโลหะ (Hardness testing)



กระบวนการทดสอบความแข็งแรง (Tensile strength testing)

ตัวอย่างการตรวจสอบทางจุลภาค (Microstructure analysis)




Figure4 : กระบวนการวิเคราะห์เนื้อโลหะด้วยกล้องจุลทรรศน์ (Optical microscope)


Background

Slide no. 7

What is sintering neck? : รูปร่างที่แสดงถึงการหลอมหลวมของเม็ดโลหะผง

Why we need to evaluate sintering neck? : เพื่อดูประสิทธิภาพของกระบวนการเผาขึ้น

How to evaluate sintering neck? : ดูจากลักษณะ รูปร่าง ภาพถ่าย Microstructure โดยผู้เชี่ยวชาญ



Problem statement

Slide no. 8


Microstructure picture



ไม่ดี



ผู้เชี่ยวชาญ A




Case 1 : 7 Days later

ไม่ดี



ผู้เชี่ยวชาญ A




Case 2 : Change human

ไม่ดี



ผู้เชี่ยวชาญ B



Key problem :

1.) ไม่มีมาตรฐานกำหนดที่แน่นอน

2.) เป็นเชิงการวิเคราะห์ที่ใช้ประสบการณ์ของมนุษย์

Slide no. 9

Objective

เพื่อคัดแยกชนิดของรูพรุนที่ทำให้เกิด Sintering neck ที่ดีและไม่ดีโดยใช้เทคนิคการประมวลผลข้อมูลภาพ (Image processing) และการเรียนรู้ด้วยเครื่อง (Deep learning)



Slide no. 10

Benefit & Scope

Benefit :

- ได้โปรแกรม หรือ อัลกอริทึมที่สามารถปรับปรุงประสิทธิภาพการทำงานดังนี้

Man :

- ไม่ต้องใช้คนที่มีประสบการณ์สูงในการวิเคราะห์
- ลดความไม่แน่นอนจากการประเมินด้วยมนุษย์



Method :

- ลดเวลาจากการประเมินด้วยการใช้เครื่องจักร
- ได้ Output ที่เหมือนเดิมทุกครั้งในการประเมิน



Scope :

- การวิเคราะห์รูพรุนในงานวิจัยใช้กับโครงสร้างทางจุลภาคของโลหะผง
- ข้อมูล (Data set) ที่ใช้ในงานวิจัยได้รับมาจากบริษัท Acme International (Thailand)
- ภาพโครงสร้างทางจุลภาคเป็นของเหล็กกล้าคาร์บอนต่ำ (Low carbon steel)



Chapter 2

Literature review



Literature review



Powder
metallurgy



Machine
learning




Image processing
In metallurgy



Resemble
research




Powder metallurgy


Slide no. 13

Related theory :

รูพรุนเกิดมาได้อย่างไร? เกี่ยวข้องกับ Sintering neck อย่างไร?



Sintering neck : สามารถบอกถึงความสามารถของกระบวนการหลอมรวมเม็ดโลหะผง โดยสามารถประเมินได้จาก ลักษณะรูปร่างของรูพรุน



Powder metallurgy

Slide no. 14



Topic : Complex effects of alloy composition and porosity on the phase transformations and mechanical properties of powder metallurgy steels (2015)

Author : Jooyoung

Objective :

- ศึกษาผลกระทบของรูพรุนต่อความหนาแน่นและความแข็งแรงของเหล็กกล้า

Result :

- ขนาด และ ปริมาณของรูพรุนนั้นส่งผลต่อความหนาแน่น และความแข็งแรงของโลหะ




Fig. 8. Comparison of the yield stress of the steel obtained from model equations with the experimental values for (a) 15 and (b) 20 C content.

Contribution :

- รูพรุนนั้นส่งผลต่อคุณสมบัติทางกลของเหล็กซึ่งเป็นไปตามทฤษฎี



Topic : The effects of microstructure and porosity on the competing fatigue failure mechanisms in powder metallurgy Ti-6Al-4V (2018)

Author : Matthew K. Dunstan

Objective :

- ศึกษาผลกระทบ ขนาด, รูปร่าง ของรูพรุนต่อความล้าของ Titanium Alloy

Result :

- ขนาดของรูพรุนมีผลต่อความล้าของวัสดุโดยเฉพาะ โลหะที่มีขนาดเนื้อโลหะ (Grain) ขนาดใหญ่

Table 4
Predicted minimum pore size compared with the smallest pore observed in case failure in all analyzed samples.

Microstructure	Minimum Predicted Pore Size		Smallest Observed Pore Size	
	Δ , surface (nm)	Δ , interior (nm)	Δ , surface (nm)	Δ , interior (nm)
HIP1	43.0	52.7	43.0	56.2
HIP1 + PC	29.9	58.5	188.4	58.9
HIP1 + PC + Bimodal	46.4	78.8	-	79.0
HIP1 + PC + Cellular	33.7	57.0	-	57.5
HIP1 + PC + β -phase	223	277	-	-
VAC	548	993	-	-
VAC + PC	588	993	-	-



Image processing In metallurgy

Slide no. 15

Topic : Quantitative image analysis in some iron powder metallurgy materials (2019)

Author : M Marin and F B Marin

Objective :

- ศึกษาความสัมพันธ์ วัสดุพูนจากภาพโครงสร้าง เพื่อหาความหนาแน่นของวัสดุ เทียบกับวิธีดั้งเดิม (ชั่งน้ำหนัก)





Figure 1. Microstructure of sample P1 at 1120°C for 60 minutes (a) initial image and (b) after software rendering.




Figure 2. Microstructure of sample P1 at 1120°C for 60 minutes (a) initial image and (b) after software rendering.




Figure 3. Microstructure of sample P1 at 1120°C for 90 minutes (a) initial image and (b) after software rendering.




Figure 4. Microstructure of sample P1 at 1120°C for 90 minutes (a) initial image and (b) after software rendering.

Table 4. Percentage porosity of analyzed alloys obtained from conventional method and from image analysis using Image J.

Powder type	Porosity from conventional method, (%)		Porosity from image analysis, (%)	
	Sintered at 1120° C for 60 minutes	Sintered at 1120° C for 90 minutes	Sintered at 1120° C for 60 minutes	Sintered at 1120° C for 90 minutes
P ₁	13.11	13.00	13.83	13.40
P ₂	12.90	12.40	13.97	13.94

Contribution :

- เป็นการพิสูจน์ว่าการประเมินรูพรุนของภาพโครงสร้างทางจุลภาคนั้น สัมพันธ์กับธรรมชาติของโลหะผง



Machine learning

Slide no. 16

Topic : Localization of slab identification numbers using deep learning (2016)

Author : Sang Jun Lee

Objective : เพื่อใช้ระบุรหัส Product แบบ Auto

Method : DCNN

Result : 97.98%




Fig. 1. Results images of the proposed algorithm. For each subfigure, left images show raw factory scenes, middle images show segmented images of the algorithm, and right images show the extracted identification regions after a simple post-processing.

Topic : Localization of slab identification numbers using deep learning (2016)

Author : Sang Jun Lee

Objective : เพื่อใช้ในการตรวจจับ Defect เหล็ก

Method : Siamese Neural Network + CNN

Result : 86.5%




Fig. 3. Example of 9 class of steel surface defects. Images corresponds to each class of 1 - 9 from upper left to lower right.

Contribution :

- มีการใช้การใช้ CNN ในงานโลหะที่ใช้ Data set การเรียนรู้จากภาพ โดยเป็นการทำ Classification ประเภทของรูป



Resemble research

Slide no. 17

My research




Soil micromorphological image classification using deep learning: The porosity parameter (2021)

Author : Rafael Aray

Porosity classification from thin sections using image analysis and neural networks including shallow and deep learning in Jahrum formation

Author : M. Abedini

Dataset



Binarization



None



Number of Data set

Testing : 282 pcs
Training : 2,864 pcs
3 Class

Testing : 1500 pcs
Training : 1500 pcs
6 Class

Testing : 682 pcs
Training : 278 pcs
6 Class

CNN Result

None

Table 5
Training and testing accuracy in the second experiment.

Model	Train acc.	Test acc.
Scripture	98.999485	95.158195
VGG 16	97.714226	93.512185
VGG 19	96.340275	92.411275
ResNet50	98.670105	95.427405
Inception v3	98.819005	95.168885
Inception ResNet v2	98.076185	93.618075
MobileNet	97.819005	93.618075
MobileNet-Mob	96.347628	91.815528
MobileNet v2	97.171435	93.995345

BPN : 94.60% SAE : 96.04%

Contribution :

- สามารถคัดกรองอัลกอริทึมของ Machine learning เพื่อมาต่อยอดในงานวิจัย

Summary

Slide no. 18

Powder metallurgy

- รูปพรุนส่งผลต่อความแข็งแรงของเหล็ก
- รูปพรุนส่งผลต่อคุณสมบัติความหล่อของเหล็ก



Image processing

- การประยุกต์ใช้ Image processing วัดรูปพรุน



Machine learning

- แนวโน้มของการใช้ Machine learning

ในการวิเคราะห์งานโลหะ



Resemble

- ความเป็นไปได้ที่จะประยุกต์ใช้

Deep learning กับ Dataset ที่ใกล้เคียงกัน



Slide no. 19

Chapter 3


Research Methodology




Slide no. 20

Sample preparation


กระบวนการเตรียมชิ้นงานก่อนทำการส่องกล้องจุลทรรศน์




พนักงานปฏิบัติการ



a.) ลักษณะรอยขีดจากการเตรียมชิ้นงาน




b.) คราบน้ำจากกระบวนการขัด



c.) ความไม่ชัดของขอบเนื่องจากความไม่ระนาบ


Slide no. 21

Overall process



Slide no. 22

Data set preparation and image processing



Slide no. 23

Data set preparation and image processing—

Importance object :



- เนื้อเหล็ก (สีขาว)
- รูพรุน (สีดำ)

Binarization :

- Adaptthresh
sensitivity (1)



Example: Water stain arose from the workpiece preparation process for taking microstructure images.



ภาพก่อนการทำ Binarization

ภาพหลังการทำ Binarization


Ref: <https://www.mathworks.com/help/images/ref/adaptthresh.html>

Objective :

- เพื่อปรับปรุงภาพให้มี Abnormality น้อยที่สุด

Slide no. 24

Labeling process




175 images
x
12
= 2100 sub images



Scale ที่เหมาะสมสำหรับการประเมิน

Example evaluating guideline

Ref. บริษัท Honganes



ผู้เชี่ยวชาญ 1
พนักงาน 1

ผู้เชี่ยวชาญ 2
พนักงาน 2

ผู้เชี่ยวชาญ 3

Optional Scope

Ref. ผู้เชี่ยวชาญที่ 3 ท่าน + ในบริษัท Honganes

Objective :

- เพื่อให้ผู้เชี่ยวชาญประเมินได้ง่าย และ แม่นยำที่สุด

Slide no. 27

Evaluation

Confusion matrix (Yes) :

Prediction/Actual	Yes	No
Yes	TP	FP
No	FN	TN



- Accuracy
- Precision
- Recall
- Specificity
- F1-Score



Objective:

- ประเมินประสิทธิภาพของ Model
- เพื่อใช้ในการวิเคราะห์ข้อมูล

ชุดข้อมูลทดสอบเอกฉันท์ (Main Scope) :

Type (Probability)	Not Good	Good	Very Good
ความเห็นเอกฉันท์ (1)	169	65	48
Total	169	65	48

ชุดข้อมูลทดสอบความเห็นส่วนมาก (Optional Scope) :


Type (Probability)	Not Good	Good	Very Good
ความเห็นเอกฉันท์ (1)	169	65	48
ความเห็นส่วนมาก (0.66)	307	214	1
Total	476	279	49

Objective :

- เพื่อใช้ในการประเมินประสิทธิภาพของแบบจำลอง และ ใช้ในการวิเคราะห์ข้อมูล

Slide no. 28

Summary

Scope	Model	Testing set	Objective
Main scope	ผู้เชี่ยวชาญ 3 คน  ผู้เชี่ยวชาญ 1, ผู้เชี่ยวชาญ 2, ผู้เชี่ยวชาญ 3	ชุดข้อมูลเอกฉันท์	ศึกษาประสิทธิภาพของแบบจำลอง และ ความสามารถในการคัดแยกภาพรูป
Optional 1	ผู้เชี่ยวชาญ 3 คน  ผู้เชี่ยวชาญ 1, ผู้เชี่ยวชาญ 2, ผู้เชี่ยวชาญ 3	ชุดข้อมูลความเห็นส่วนมาก	ศึกษาอิทธิพลของ ภาพที่ความยากในการประเมิน ว่าส่งผลต่อแบบจำลองหรือไม่
Optional 2	ผู้เชี่ยวชาญ 3 คน และพนักงาน 2 คน  ผู้เชี่ยวชาญ 1, ผู้เชี่ยวชาญ 2, ผู้เชี่ยวชาญ 3, พนักงาน 1, พนักงาน 2	ชุดข้อมูลเอกฉันท์	ศึกษาอิทธิพลของ ประสบการณ์มนุษย์ ที่มาเป็นต้นแบบ ว่าส่งผลต่อแบบจำลองหรือไม่


Chapter 4

Result and Analysis



Main objective result

Details : แบบจำลองผู้เชี่ยวชาญ 3 คน ทดสอบ ด้วย ชุดทดสอบเอกฉันท์




Objective :

- Inception V.3 ให้ค่าความแม่นยำมากที่สุดจาก Model ที่ได้ทำการเลือกมา

Main objective result

ผล Individual plot ค่า Probability ที่แบบจำลองทำนายได้



Result :

- ไม่มีการข้าม Class กันระหว่างรูปพรุนที่ไม่ดี และ รูปพรุนที่ดีมาก
- ค่าความน่าจะเป็นที่ทำนายได้ถูกต้องโดยส่วนมากมีค่ามากกว่า 0.7 ในแบบจำลอง Inception v.3 และ Xception
- ประเภทภาพรูปพรุนที่ดี (Good) เป็น Class ที่มีการกระจายตัวของความน่าจะเป็นมากที่สุด

Main objective result

ตารางเปรียบเทียบค่า Precision, Sensitivity, Specificity, F1-Score

Precision (%)			
Model	Not Good	Good	Very Good
ResNet-50	98.8%	96.9%	100.0%
ResNet-101	93.3%	98.1%	100.0%
Inception-v3	98.3%	100.0%	100.0%
Xception	91.8%	96.2%	100.0%
GoogLeNet	59.9%	-	-

Recal/Sensitivity (%)			
Model	Not Good	Good	Very Good
ResNet-50	98.8%	96.9%	100.0%
ResNet-101	99.4%	81.5%	100.0%
Inception-v3	100.0%	95.4%	100.0%
Xception	100.0%	76.9%	95.8%
GoogLeNet	100.0%	-	-

Specificity (%)			
Model	Not Good	Good	Very Good
ResNet-50	98.2%	99.1%	100.0%
ResNet-101	89.4%	99.5%	100.0%
Inception-v3	97.3%	100.0%	100.0%
Xception	86.5%	99.1%	100.0%
GoogLeNet	0.0%	100.0%	100.0%

F1-Score			
Model	Not Good	Good	Very Good
ResNet-50	98.8%	96.9%	100.0%
ResNet-101	96.3%	89.1%	100.0%
Inception-v3	99.1%	97.6%	100.0%
Xception	95.8%	85.5%	97.9%
GoogLeNet	74.9%	-	-

รูปพรุนที่แย่ (Not good) :

- มีค่า Precision ที่ต่ำเนื่องจากแบบจำลองจะมองรูปพรุนประเภทที่ดีมาเป็นส่วนหนึ่งของประเภทรูปพรุนที่แย่ด้วย

รูปพรุนที่ดี (Good) :

- มีค่า Sensitivity ที่ต่ำกล่าวคือแบบจำลองจะมีโอกาสที่จะประเมินรูปพรุนที่ดีเป็นรูปพรุนประเภทอื่น


รูปพรุนที่ดีมาก (Very good) :

- เป็นรูปพรุนที่มีค่า F1-Score และ Specificity ที่สูงเนื่องจากเป็นรูปพรุนที่แบบจำลองสามารถคัดแยกได้โดยง่าย

Slide no. 33

Additional result 1

Details : แบบจำลองผู้เชี่ยวชาญ 3 คน ทดสอบ ด้วย ชุดทดสอบความเห็นส่วนมาก



Objective :

- Xception ให้ค่าความแม่นยำมากที่สุดจาก Model ที่ได้ทำการเลือกมา

Slide no. 34

Additional result 1

ผล Individual plot ค่า Probability ที่แบบจำลองทำนายได้





Result :

- ไม่มีการข้าม Class กันระหว่างรูปทรงที่ไม่ดี และ รูปทรงที่ดีมาก

Slide no. 35

Additional result 1



Result :

- ไม่มีการข้าม Class กันระหว่างรูปหุ่นที่ไม่ดี และ รูปหุ่นที่ดี

Slide no. 36

Additional result 1

ตารางเปรียบเทียบค่า Precision, Sensitivity, Specificity, F1-Score

Precision (%)			
Model	Not Good	Good	Very Good
ResNet-50	93.2%	66.8%	86.0%
ResNet-101	83.8%	71.5%	89.1%
Inception-v3	90.8%	68.8%	100.0%
Xception	85.7%	73.8%	97.9%
GoogLeNet	59.2%	-	-

Recall/Sensitivity (%)			
Model	Not Good	Good	Very Good
ResNet-50	74.4%	87.8%	100.0%
ResNet-101	83.6%	70.3%	100.0%
Inception-v3	76.9%	86.7%	100.0%
Xception	84.7%	75.6%	95.9%
GoogLeNet	100.0%	-	-

Specificity (%)			
Model	Not Good	Good	Very Good
ResNet-50	91.9%	76.8%	98.7%
ResNet-101	76.1%	85.1%	99.0%
Inception-v3	88.7%	79.0%	100.0%
Xception	79.4%	85.7%	99.8%
GoogLeNet	0.0%	100.0%	100.0%

F1-Score			
Model	Not Good	Good	Very Good
ResNet-50	82.7%	75.9%	92.5%
ResNet-101	83.7%	70.9%	94.2%
Inception-v3	83.3%	76.7%	100.0%
Xception	85.2%	74.7%	96.9%
GoogLeNet	74.4%	-	-

รูปหุ่นที่แย่ (Not good) :

- มีค่า Recall ที่ต่ำเนื่องจากรูปหุ่นถูกประเมินไปเป็นรูปหุ่นที่ดีส่วนหนึ่ง

รูปหุ่นที่ดี (Good) :

- มีค่า Precision และ Sensitivity ที่ต่ำเนื่องจากถูกทำนายไป Class อื่นเยอะโดยเฉพาะรูปหุ่นที่แย่

รูปหุ่นที่ดีมาก (Very good) :

- เป็นรูปหุ่นที่มีค่า F1-Score และ Specificity ที่สูงเนื่องจากเป็นรูปหุ่นที่แบบจำลองสามารถคัดแยกได้โดยง่าย เหมือนกับชุดข้อมูลเอคกันท์

Slide no. 37


Comparison

No.	Topic	ชุดข้อมูลทดสอบ เอกฉันท	ชุดข้อมูลทดสอบ ความเห็นส่วนมาก
1	%Accuracy	94.0%-98.9%	80.0-82.2%
2	Most Accuracy Architecture	Inception -v.3 (98.9%)	Xception (82.2%)
3	GoogLeNet	ไม่สามารถคัดแยกรูปได้	ไม่สามารถคัดแยกรูปได้
4.	รูปที่ไม่ดี (Not Good)	ค่า Precision ต่ำกว่าค่าอื่น(90%) เนื่องจากมีการทำนายบางส่วนไปเป็นรูปที่ดี	มีค่า Sensitivity ที่ต่ำเนื่องจากรูปถูกประเมินไปเป็นรูปที่ดีส่วนหนึ่ง
5.	รูปที่ดี (Good)	มีค่า Sensitivity ที่ต่ำกล่าวคือแบบจำลองจะมีโอกาสที่จะประเมินรูปที่ดีเป็นรูปประเภทอื่น	มีค่า Precision และ Sensitivity ที่ต่ำเนื่องจากถูกทำนายไป Class อื่นเยอะโดยเฉพาะรูปที่แย
6.	รูปที่ดีมาก (Very Good)	F1 Score มีค่าที่สูงทำนายได้แม่นยำ	F1 Score มีค่าที่สูงทำนายได้แม่นยำ
Summary		ชุดข้อมูลความเห็นส่วนมาก นั้นจะได้ค่า %Accuracy ที่ต่ำกว่า ชุดข้อมูลเอกฉันทเนื่องจาก ปัจจัยของความไม่แน่นอน หรือ ความยากในการประเมินตัวภาพมาเกี่ยวข้อง โดยดูได้จากค่า F1 Score ของ รูปที่ดี และ ไม่ดีนั้นต่ำลง	

Slide no. 38

Additional result 2

Details : แบบจำลองผู้เชี่ยวชาญ 3 คน และพนักงาน 2 คน ทดสอบ ด้วย ชุดทดสอบเอกฉันท







Objective :

- ResNet-50 เป็น Architecture ที่มีค่า %Accuracy สูงที่สุด

Slide no. 39

Additional result 2

ผล Individual plot ค่า Probability ที่แบบจำลองทำนายได้



Result :

- ไม่มีการข้าม Class กันระหว่างรูปพรุนที่ไม่ดี และ รูปพรุนที่ดีมาก
- รูปพรุนประเภทที่มีค่าความน่าจะเป็นอยู่ช่วง 0.4-0.6 โดยมีโอกาสที่จะเป็นรูปพรุนที่แย่มาก
- ใน Zone ที่ ค่าความน่าจะเป็น >0.5 ของ ประเภทรูปพรุนที่ดี ResNet-50 เป็น Architecture เดียวที่สามารถทำนายได้ถูกต้อง

Slide no. 40

Additional result 2

ตารางเปรียบเทียบค่า Precision, Sensitivity, Specificity, F1-Score

Precision (%)			
Model	Not Good	Good	Very Good
ResNet-50	82.4%	96.7%	100.0%
ResNet-101	74.8%	100.0%	100.0%
Inception-v3	78.2%	94.7%	100.0%
Xception	74.4%	100.0%	100.0%
GoogLeNet	59.9%	-	-

Recal/Sensitivity (%)			
Model	Not Good	Good	Very Good
ResNet-50	100.0%	44.6%	97.9%
ResNet-101	100.0%	12.3%	100.0%
Inception-v3	100.0%	27.7%	97.9%
Xception	100.0%	10.8%	100.0%
GoogLeNet	100.0%	-	-

Specificity (%)			
Model	Not Good	Good	Very Good
ResNet-50	67.9%	99.5%	100.0%
ResNet-101	49.6%	100.0%	100.0%
Inception-v3	58.0%	99.5%	100.0%
Xception	48.7%	100.0%	100.0%
GoogLeNet	0.0%	100.0%	100.0%

F1-Score			
Model	Not Good	Good	Very Good
ResNet-50	90.4%	61.1%	98.9%
ResNet-101	85.6%	21.9%	100.0%
Inception-v3	87.8%	42.9%	98.9%
Xception	85.4%	19.4%	100.0%
GoogLeNet	59.9%	-	-

รูปพรุนที่แย่มาก (Not good) :

- มีค่า Precision ที่ต่ำเนื่องจากแบบจำลองจะมองรูปพรุนประเภทที่ดีเป็นส่วนหนึ่งของประเภทรูปพรุนที่แย่มาก

รูปพรุนที่ดี (Good) :

- มีค่า Specificity ที่สูง และ Sensitivity ที่ต่ำเนื่องจากสามารถถูกทำนายไปเป็น Class อื่นได้ง่าย

รูปพรุนที่ดีมาก (Very good) :

- เป็นรูปพรุนที่มีค่า F1-Score และ Specificity ที่สูงเนื่องจากเป็นรูปพรุนที่แบบจำลองสามารถคัดแยกได้โดยง่าย

Slide no. 41

Additional result 2

- ใช้ชุดข้อมูลทดสอบเอกชนันท์

No.	Topic	แบบจำลองผู้เชี่ยวชาญ	แบบจำลองที่สร้างโดยผู้เชี่ยวชาญ และพนักงาน
1	%Accuracy	94.0%-98.9%	79.4%-86.9%
2	Most Accuracy Architecture	Inception -v.3 (98.9%)	ResNet-50 (86.9%)
3	GoogLeNet	ไม่สามารถคัดแยกรูปพรุนได้	ไม่สามารถคัดแยกรูปพรุนได้
4.	รูปพรุนที่ไม่ดี (Not Good)	ค่า Precision ต่ำกว่าค่าอื่น(90%) เนื่องจากมีการทำนายบางส่วนไปเป็นรูปพรุนที่ดี	มีค่า Precision ที่ต่ำเนื่องจากแบบจำลองจะมองรูปพรุนประเภทที่ตีมาเป็นส่วนหนึ่งด้วย
5.	รูปพรุนที่ดี (Good)	มีค่า Sensitivity ที่ต่ำกล่าวคือแบบจำลองจะมีโอกาสที่จะประเมินรูปพรุนที่ดีเป็นรูปพรุนประเภทอื่น	มีค่า Specificity ที่สูง และ Sensitivity ที่ต่ำเนื่องจากสามารถถูกทำนายไปเป็น Class อื่นได้ง่าย
6.	รูปพรุนดีมาก (Very Good)	F1 Score มีค่าที่สูงทำนายได้แม่นยำ	F1 Score มีค่าที่สูงทำนายได้แม่นยำ
Summary		แบบจำลองที่สร้างโดยผู้เชี่ยวชาญ เพียงอย่างเดียวมีค่า %Accuracy ที่สูงกว่าแบบจำลองที่มีพนักงานปฏิบัติการร่วม ด้วย โดยความแตกต่างที่เห็นได้ชัด คือประเภทรูปพรุนที่ดี(Good) ค่า Probability จะเอนเอียงไปทางรูปพรุนที่แย่ ตามการประเมินของพนักงานปฏิบัติการ	

Slide no. 42

Chapter 5

Conclusion



TNI

Slide no. 43

Conclusion

วัตถุประสงค์ของการทำงาน

Objective :

เพื่อคัดแยกชนิดของรูพรุนที่ทำให้เกิด Sintering neck ที่ดีและไม่ดีโดยใช้เทคนิคการประมวลผลข้อมูลภาพ (Image processing) และ การเรียนรู้ด้วยเครื่อง (Deep learning)

Benefit :

- ได้โปรแกรม หรือ อัลกอริทึมที่สามารถปรับปรุงประสิทธิภาพการทำงานดังนี้
 - Man :
 - ไม่ต้องใช้คนที่มีประสบการณ์สูงในการวิเคราะห์
 - ลดความไม่แน่นอนจากการประเมินด้วยมนุษย์
 - Method :
 - ลดเวลาจากการประเมินด้วยการใช้เครื่องจักร
 - ได้ Output ที่เหมือนเดิมทุกครั้งในการประเมิน

Conclusion :

- สามารถสร้างแบบจำลองการเรียนรู้การประเมิน Sintering neck จากรูปภาพรูพรุน โดยแบ่งออกเป็น 3 Sintering neck ที่ดี --> (รูพรุนที่ดี / ดีมาก) Sintering neck ที่ไม่ดี --> (รูพรุนที่ไม่ดี)
- Man objective: ลดความไม่แน่นอนจากมนุษย์ เนื่องจาก เารูปเดิมเข้า Model ก็ยังทำนายได้เหมือนเดิม
- Method objective: รวดเร็วกว่ามนุษย์ ในการประเมิน

Slide no. 44

Conclusion

เชิงการสร้างแบบจำลอง

Main scope :

- แบบจำลองที่สร้างโดย ผู้เชี่ยวชาญ 3 คนที่มีประสบการณ์ทำงานมาก ได้ความแม่นยำมากที่สุด
- ค่า %Accuracy อยู่ที่ 94.0%-98.9% ยกเว้น GoogLeNet ที่ไม่สามารถ แยกประเภทของรูพรุนได้
- Very good Class เป็น Class ที่สามารถแยกได้ง่ายที่สุด เนื่องจากมีค่า F1-Score ที่สูง
- Not Good และ Good Class ยังมีความคล้ายกันอยู่ทำให้ค่า F1-Score น้อยกว่า Very good

Additional scope :

- ความยากของภาพในการประเมิน มีผลต่อ แบบจำลอง โดยค่าความน่าจะเป็นยังใกล้เคียงกับที่คนประเมิน โดยดูได้จากผลการทดลอง Testing set ความเห็นส่วนมาก ที่มี Accuracy ที่ต่ำลง
- ประสิทธิภาพของผู้ประเมิน มีผลต่อ แบบจำลองโดยตรงโดยผู้ที่มีประสบการณ์น้อย อาจจะทำให้ Accuracy ของแบบจำลองนั้นต่ำลง ดูได้จากแบบจำลองที่สร้างจาก ผู้เชี่ยวชาญ และ พนักงานปฏิบัติการ

Slide no. 45

Appendix

Conference Certificated IEECON 2022



Slide no. 46

Thanks

Do you have any questions?

Khattipong Usamran

Tel : 085-100-6162

Email : us.Khattipong_st@tni.ac.th

CREDITS: This presentation template was created by **Slidesgo**, including icons by **Flaticon**, infographics & images by **Freepik**

Please keep this slide for attribution