

การศึกษาการตรวจหาเชื้อไวรัสโรคจากภาพย้อมสีทึบกรวดโดยใช้การเรียนรู้เชิงลึกด้วยเทคนิคการจำแนก
และการตรวจจับวัตถุ



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาระบบกายภาพที่เชื่อมประสานด้วยเครือข่ายไซเบอร์ ภาควิชาวิศวกรรมเครื่องกล
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2566

The Study of Tuberculosis Detection from Acid-Fast Stain Images Using Deep Learning
Classification and Object Detection



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Cyber-Physical System

Department of Mechanical Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2023

ธีรศรา มิคาระเศรษฐ์ : การศึกษาการตรวจหาเชื้อวัณโรคจากภาพย้อมสีทึบกรดโดยใช้
การเรียนรู้เชิงลึกด้วยเทคนิคการจำแนกและการตรวจจับวัตถุ. (The Study of
Tuberculosis Detection from Acid-Fast Stain Images Using Deep Learning
Classification and Object Detection) อ.ที่ปรึกษาหลัก : รศ. ดร.กฤษฎา พนมเชิง

การศึกษานี้เป็นการวิเคราะห์ Deep Learning สำหรับตรวจหาเชื้อวัณโรคด้วยวิธีการ
Modified Classification และ Object Detection โดยใช้ Pre-Trained Model คือ Enhanced
ResNet50 และ AlexNet ในการวิเคราะห์ ซึ่งวิธี Modified Classification มีการนำ Image
Processing มาประยุกต์ใช้กับการทดลอง เมื่อ Training ข้อมูล พบว่า ResNet50 เป็น Model ที่มี
ประสิทธิภาพสูงสุดได้ค่า Accuracy เท่ากับ 92.71% และ Precision เท่ากับ 92.7% เมื่อจัดกลุ่ม
ใหม่สำหรับการวิเคราะห์ แบบ Suspected Positive Low Confidence และ Suspected
Positive High Confidence ผลการทดลองพบว่า ResNet50 ยังคงมีประสิทธิภาพที่ดีที่สุด มีค่า
Accuracy เท่ากับ 98.06% ค่า Precision เท่ากับ 98.59% ส่วน Suspected Positive High
Confidence มีค่า Accuracy เท่ากับ 94.38% และค่า Precision เท่ากับ 91.41% และในการ
วิเคราะห์ Deep Learning วิธี Object Detection ได้ค่า Precision เท่ากับ 82.81% และ Mean
AP เท่ากับ 36.79% จากการเปรียบเทียบการวิเคราะห์ทั้ง 2 Models พบว่า วิธีวิเคราะห์แบบ
Modified Classification ได้ผลลัพธ์ดีกว่า จึงนำไปตรวจร่วมกับวิธีการตรวจของแพทย์ (Doctor
Screening with Suspected Positive High Confidence) เพื่อเปรียบเทียบกับ การตรวจด้วย
Light Microscopy พบว่าข้อมูลในกลุ่ม Positive เคส วิธี Doctor Screening with Suspected
Positive High Confidence มีความถูกต้องมากกว่า Light Microscopy

สาขาวิชา ระบบกายภาพที่เชื่อมประสาน ลายมือชื่อนิสิต

ด้วยเครือข่ายไซเบอร์

ปีการศึกษา 2566 ลายมือชื่อ อ.ที่ปรึกษาหลัก

6472038321 : MAJOR CYBER-PHYSICAL SYSTEM

KEYWORD: Deep learning, convolutional neural network (CNN), Tuberculosis,
Classification, Object Detection, Modified Classification

Terisara Micaraseth : The Study of Tuberculosis Detection from Acid-Fast
Stain Images Using Deep Learning Classification and Object Detection.

Advisor: Assoc. Prof. Gridsada Phanomchoeng, Ph.D.

This study is a Deep Learning analysis for detecting tuberculosis using the Modified Classification and Object Detection methods using pre-trained models such as Enhanced ResNet50 and AlexNet. The Modified Classification method has Image Processing applied to the process and when training the data, it was found that ResNet50 is the most efficient model with an accuracy 92.71% and a precision 92.7%. When reclassified for analysis, using Suspected Positive Low Confidence and Suspected Positive High confidence, ResNet50 continues to exhibit the highest performance. It achieves an accuracy 98.06% and a precision 98.59%. For Suspected Positive High Confidence, an accuracy is 94.38% and a precision is 91.41%. In Deep Learning using Object Detection method, a precision 82.81% and mean AP 36.79%. After comparing the analysis of the two models, it was determined that the Modified Classification analysis method is superior. Consequently, this model was employed alongside the Doctor Screening with Suspected Positive High Confidence method. When compared with Light Microscopy, it was found that in the positive case group, Doctor Screening with Suspected Positive High Confidence proved to be more accurate than Light Microscopy.

Field of Study: Cyber-Physical System

Student's Signature

Academic Year: 2023

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้เสร็จสมบูรณ์ด้วยดีเนื่องจากได้รับความกรุณาให้คำปรึกษาและช่วยแนะนำ
แก้ไขข้อบกพร่องต่างๆอย่างดียิ่งจาก รองศาสตราจารย์ ดร.กฤษฎา พนมเชิง อาจารย์ที่ปรึกษา
วิทยานิพนธ์ ขอขอบพระคุณ ศาสตราจารย์ นพ.ชนพ ชวงโชติ อาจารย์ พญ.ณัชชา วรรณปิยะรัตน์ และ
รองศาสตราจารย์ นพ.บุญชูวิษฐ์ จันทรานูวัฒน์ ภาควิชา พยาธิวิทยา คณะแพทยศาสตร์ จุฬาลงกรณ์
มหาวิทยาลัย ที่ให้คำปรึกษาข้อมูลทางการแพทย์ ข้อมูลทางการตรวจหาเชื้อไวรัส ทำให้ผู้วิจัย
ได้รับแนวทางในการศึกษา ข้อมูลสำหรับงานวิจัย การค้นคว้าหาความรู้ และประสบการณ์อย่าง
กว้างขวางในการทำวิทยานิพนธ์ ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ทุกท่านที่ช่วยชี้แนะ
แก้ไขข้อบกพร่องต่างๆ และขอขอบคุณ นายชยธร ภูเกียรติกุล ที่ให้คำแนะนำ การเตรียมภาพชุดข้อมูล
การใช้เครื่องมือ ระบบโปรแกรมต่างๆ ซึ่งเป็นประโยชน์อย่างยิ่งต่อการวิจัยครั้งนี้ ผู้วิจัยขอขอบพระคุณ
อย่างสูงมา ณ โอกาสนี้

ธีรศรา มิคาระเศรษฐ์

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฎ
บทที่ 1.....	1
บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์.....	4
1.3 ขอบเขตงานวิจัย.....	4
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	4
1.5 วิธีดำเนินการวิจัย.....	4
บทที่ 2.....	6
ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	6
2.1 Acid-Fast Stain.....	6
2.1.1 วิธีการย้อมสีเชื้อ Acid-Fast Stain.....	7
2.1.2 กล้องที่ใช้สำหรับตรวจดูเชื้อวัณโรค.....	7
2.2 ระบบสี Color Model.....	10

2.3 การประมวลผลภาพ (Image Processing)	10
2.3.1 เทคนิค Basic Enhancement and Restoration.....	11
2.3.1.1 Unsharp Masking	11
2.3.1.2 Noise Suppression.....	11
2.3.1.3 Distortion Suppression.....	12
2.3.2 Segmentation	12
2.3.2.1 Pixel-Based Segmentation	13
2.3.2.2 Edge-Based Segmentation	13
-Bias by Uneven Illumination.....	13
- Edge Tracking	14
-Region-Based Segmentation	14
2.3.2.3 Model-Based Segmentation	14
-Parameter Space; Hough Transform	14
2.4 Convolutional Neural Network (CNN).....	15
2.4.1 รูปแบบการวิเคราะห์ Deep Learning.....	16
2.4.1.1 Classification.....	16
2.4.1.2 Object Detection.....	17
2.4.1.3 Semantic Segmentation.....	18
2.4.2 Pretrained Model.....	20
2.4.2.1 Enhanced	20
2.4.2.2 ResNet50 หรือ Residual Neural Networks	20
2.4.2.3 AlexNet.....	20
2.4.3 ตัวชี้วัดประสิทธิภาพของ Model.....	20
2.5 Program	21

2.5.1 Halcon via the MVTec Software.....	21
2.5.2 MVTec Deep Learning Tool.....	22
2.6 งานวิจัยที่เกี่ยวข้อง	22
บทที่ 3	30
วิธีการดำเนินงาน	30
3.1 การเตรียมชุดข้อมูล	30
3.2 การเตรียมชุดข้อมูลด้วย Image Processing สำหรับการวิเคราะห์ Deep Learning ด้วยวิธี Modified Classification.....	30
3.3 การวิเคราะห์ด้วย MVTec Deep Learning Tool ด้วยวิธี Modify Classification.....	32
3.4 การวิเคราะห์ด้วย Deep Learning ด้วยวิธี Object Detection.....	34
3.5 การเปรียบเทียบความสามารถในการยืนยันผลโดยใช้ Model ร่วมกับแพทย์เพื่อตรวจหาเชื้อไวรัสโคโรกับการให้แพทย์ตรวจหาเชื้อไวรัสโคโรโดยตรงผ่าน Light Microscopy.....	35
บทที่ 4	37
ผลการทดลองและการอภิปรายผล.....	37
4.1 การวิเคราะห์ Deep Learning วิธี Modify Classification	37
4.1.1 กราฟความสัมพันธ์ระหว่าง Loss กับ จำนวน Epoch และกราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training กับ Top1-Error Validation	37
4.1.2 Confusion Matrix.....	40
4.1.3 สรุปผลการทดลองการวิเคราะห์ Deep Learning วิธี Modified Classification.....	41
4.1.4 จัดกลุ่ม Confusion Matrix 3x3 เป็น Confusion Matrix 2x2	43
4.1.4.1 Confusion Matrix 2x2 ของการวิเคราะห์แบบ Suspected Positive Low Confidence.....	44
4.1.4.2 Confusion Matrix 2x2 ของการวิเคราะห์แบบ Suspected Positive High Confidence.....	45
4.2 การวิเคราะห์ Deep Learning วิธี Object Detection	47

4.2.1 กราฟความสัมพันธ์ระหว่าง Loss กับ จำนวน Epoch และกราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training กับ Top1-Error Validation	47
4.2.2 Confusion Matrix ของการวิเคราะห์ วิธี Object Detection	48
4.2.3 Class Overview (Positive, Positive Low Confidence, Negative)	48
4.3 เปรียบเทียบการวิเคราะห์ Deep Learning วิธี Modified Classification และ วิธี Object Detection	49
4.3.1 เวลาในการประมวลผลของ Pre-Trained 3 Models	49
4.3.2 การเปรียบเทียบการวิเคราะห์ Deep Learning วิธี Modified Classification และ วิธี Object Detection	50
4.3.3 ผลการวิเคราะห์ Deep Learning และการย้ายจากแพทย์เชี่ยวชาญโรค	50
4.4 การอภิปรายผล	55
บทที่ 5	57
สรุปผลการทดลอง	57
5.1 ปัญหาที่พบ	58
5.2 ข้อเสนอแนะ	58
บรรณานุกรม	59
ประวัติผู้เขียน	67

สารบัญตาราง

	หน้า
ตารางที่ 1 ขั้นตอนการทำงาน.....	5
ตารางที่ 2 ลักษณะภาพย้อมสีที่ที่ไม่ได้คุณภาพ	8
ตารางที่ 3 การเปรียบเทียบคุณสมบัติ Deep Learning Methods 3 แบบ คือ Classification Object Detection และ Segmentation	19
ตารางที่ 4 ตารางสรุปงานวิจัยที่เกี่ยวข้อง.....	27
ตารางที่ 5 แสดงจำนวนชุดข้อมูล (Dataset).....	30
ตารางที่ 6 ช่วงสี HSV จะได้ค่าเฉลี่ยจากช่วงสีดังตารางต่อไปนี้.....	31
ตารางที่ 7 แสดงจำนวนชุดข้อมูล ก่อนและหลังการทำ Image Processing & Label	31
ตารางที่ 8 ค่า Parameter สำหรับวิเคราะห์ข้อมูลด้วย Deep Learning วิธี Modified Classification	33
ตารางที่ 9 รายละเอียดการแบ่งชุดข้อมูลสำหรับวิเคราะห์ด้วย Deep Learning.....	34
ตารางที่ 10 การตั้งค่าสำหรับ Training	34
ตารางที่ 11 การตั้งค่าพารามิเตอร์ต่างๆ.....	35
ตารางที่ 12 Confusion Matrix 3x3 ของ Pre-Trained Model Enhanced.....	40
ตารางที่ 13 Confusion Matrix 3x3 ของ Pre-Trained Model ResNet50.....	40
ตารางที่ 14 Confusion Matrix 3x3 ของ Pre-Trained Model AlexNet	40
ตารางที่ 15 Class Overview ของ Pre-Trained Enhanced.....	41
ตารางที่ 16 Class Overview ของ Pre-Trained ResNet50.....	41
ตารางที่ 17 Class Overview ของ Pre-Trained AlexNet	42
ตารางที่ 18 การเปรียบเทียบ ตัวชี้วัดของ Pre-Trained 3 Models: Enhanced, ResNet50, AlexNet.....	42
ตารางที่ 19 ตัวอย่างภาพจากการ Training Models.....	43

ตารางที่ 20 Confusion Matrix 2x2 ของ Pre-Trained Enhanced.....	44
ตารางที่ 21 Confusion Matrix 2x2 ของ Pre-Trained ResNet50.....	44
ตารางที่ 22 Confusion Matrix 2x2 ของ Pre-Trained AlexNet.....	44
ตารางที่ 23 การเปรียบเทียบ Class Overview และ ตัวชี้วัดของ ของ Pre-Trained 3 Models: Enhanced, ResNet50, AlexNet	45
ตารางที่ 24 Confusion Matrix 2x2 ของ Pre-Trained Enhanced.....	45
ตารางที่ 25 Confusion Matrix 2x2 ของ Pre-Trained ResNet50.....	46
ตารางที่ 26 Confusion Matrix 2x2 ของ Pre-Trained AlexNet.....	46
ตารางที่ 27 การเปรียบเทียบ Class Overview และ ตัวชี้วัดของ ของ Pre-Trained 3 Models: Enhanced, ResNet50, AlexNet	46
ตารางที่ 28 Confusion Matrix.....	48
ตารางที่ 29 Class Overview	49
ตารางที่ 30 ตัวชี้วัดของการ Training Model	49
ตารางที่ 31 การเปรียบเทียบการวิเคราะห์ Deep Learning 2 Models.....	50
ตารางที่ 32 แสดงข้อมูลการตรวจหาเชื้อด้วยวิธีต่างๆ.....	51
ตารางที่ 33 การเปรียบเทียบการตรวจ วิธี Doctor Screening with Suspected Positive High Confidence กับ Light Microscopy	53
ตารางที่ 34 ตารางช่วงสีที่ใกล้เคียงกับเชื้อวัณโรคจากการสุมตัวอย่าง	66

สารบัญภาพ

	หน้า
ภาพที่ 1 การย้อมสีเชื้อด้วยวิธี Acid-Fast Stain	6
ภาพที่ 2 ลักษณะเชื้อวัณโรค 4 แบบ คือ (a) Single Bacilli (b) V-Shape Forms (c) Clumps Of Bacilli และ (d) Bacilli Fragments	8
ภาพที่ 3 แสดงการเปรียบเทียบค่าสี (a) RGB และ (b) HSV	10
ภาพที่ 4 Convolutional Neural Network	16
ภาพที่ 5 Classification	17
ภาพที่ 6 Object Detection	18
ภาพที่ 7 Segmentation (a) Polygons (b) Pixel Masks (c) Smart Labeling	18
ภาพที่ 8 Confusion Matrix	21
ภาพที่ 9 โปรแกรม Halcon	22
ภาพที่ 10 โปรแกรม Deep Learning Tool MVTec	22
ภาพที่ 11 การหาช่วงค่าสี HSV ด้วย Color Thresholder	31
ภาพที่ 12 แผนภาพแสดงการเตรียมชุดข้อมูลภาพ	32
ภาพที่ 13 แผนภาพแสดงการวิเคราะห์ด้วย Deep Learning	36
ภาพที่ 14 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs ของ Pre-Trained Enhanced ...	37
ภาพที่ 15 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs ของ Pre-Trained ResNet50	37
ภาพที่ 16 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs ของ Pre-Trained AlexNet	38
ภาพที่ 17 กราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation ของ Pre-Trained Enhanced	38
ภาพที่ 18 กราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation ของ Pre-Trained ResNet50	39

ภาพที่ 19 กราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation
 ของ Pre-Trained AlexNet 39

ภาพที่ 20 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs 47

ภาพที่ 21 กราฟแสดงความสัมพันธ์ระหว่าง Mean AP Training และ Mean AP Validation..... 47

ภาพที่ 22 กราฟแสดงเวลาของแต่ละ Models ในการ Training ข้อมูล..... 49



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

วัณโรค หรือ Tuberculosis (TB) เป็นสาเหตุการตายอันดับต้นๆของโลก ประมาณ 1 ใน 4 ของประชากรโลก [1, 2] โดยวัณโรคค้นพบครั้งแรกในปี ค.ศ.1882 โดย Robert Koch แพทย์และนักจุลชีววิทยา ชาวเยอรมัน ซึ่งเป็นโรคติดต่อทางเดินหายใจ ที่ร้ายแรงชนิดหนึ่ง เกิดจากเชื้อ Bacillus Mycobacterium Tuberculosis เชื้อวัณโรคจะแพร่กระจายผ่านทางอากาศ จากการที่ผู้ป่วยขับแบคทีเรียนี้ออกไปในอากาศ การพูด การไอ จาม และละอองเสมหะ ซึ่งเชื้อวัณโรคนี้จะอยู่ในอากาศได้นานหลายชั่วโมง ขึ้นอยู่กับสภาพแวดล้อมที่เป็นอยู่ หากอยู่ในพื้นที่ปิด เชื้อก็จะอยู่ได้นาน [1] เมื่อได้รับการสูดดมเข้าไปทำให้เกิดเชื้อได้ โดยโรคนี้อาจส่งผลโดยตรงต่อปอด แต่สามารถติดเชื้อที่ส่วนอื่นๆของร่างกายได้ ไม่ว่าจะเป็น ไต สมอ หรือ ไขสันหลัง ซึ่งสามารถแบ่งลักษณะการติดเชื้อวัณโรคออกเป็น 2 กลุ่ม คือ Latent TB และ TB Disease โดยกลุ่มแรก Latent TB จะไม่มีอาการใดๆ และไม่สามารถแพร่เชื้อให้กับผู้อื่นได้ สัญญาณที่บ่งบอกว่ามีเชื้อวัณโรคแฝง คือ ทำการตรวจทางผิวหนังหรือทางเลือด เท่านั้น ส่วนการติดเชื้อกลุ่มที่สอง TB Disease เมื่อเชื้อวัณโรคทำลายระบบภูมิคุ้มกันของร่างกายได้แล้ว จะส่งผลให้เกิดการลุกลามของเชื้อ แบคทีเรียจะเริ่มเพิ่มจำนวนและทำลายเนื้อเยื่อของร่างกาย ผู้ที่ได้รับเชื้อบางคนจะแสดงอาการป่วยหลังจากได้รับเชื้อแล้วภายใน 2 ปีแรก แต่ในบางคนจะแสดงอาการ ภายหลังจากที่ระบบภูมิคุ้มกันอ่อนแอลง เช่น ผู้ป่วยโรคเบาหวาน หรือผู้ที่ติดเชื้อ HIV ซึ่งการติดเชื้อ HIV เป็นปัจจัยที่เสี่ยงที่สุดที่ของการติดเชื้อวัณโรค เนื่องจากวัณโรคเป็นภาวะแทรกซ้อนของการติดเชื้อ HIV อาจเป็นสัญญาณแรกของการติดเชื้อ ซึ่งมีอัตราส่วนการติดเชื้อวัณโรค และเชื้อ HIV ร่วมกันในกลุ่มคนที่มีอายุระหว่าง 15 - 49 ปี [3] โดยอาการของเชื้อวัณโรคจะมีอาการอ่อนเพลีย มีไข้ (อุณหภูมิโดยเฉลี่ย 38 องศาเซลเซียส) ไอเรื้อรัง มักมีเสมหะ อาจมีอาการเจ็บหน้าอก หรือหายใจลำบากร่วมด้วย เบื่ออาหาร น้ำหนักลดลง และรู้สึกไม่สบายตัว หากไม่ได้รับการรักษาที่เหมาะสม อาจถึงแก่ชีวิตได้ [4] หากสัมผัสกับผู้ป่วยที่ติดเชื้ออย่างใกล้ชิดและเป็นเวลานาน ก็ยังมีความเสี่ยงมากที่จะติดเชื้อ จากสถิติการเสียชีวิตทั่วโลกของผู้ติดเชื้อวัณโรค มีแนวโน้มเพิ่มขึ้นระหว่างปี 2019 ถึง ปี 2021 ซึ่งจำนวนผู้ป่วยในปี 2021 มีผู้ป่วยมากถึง 10.6 ล้านคน เพิ่มขึ้น 4.5% จาก 10.1 ล้านคน ในปี 2020 อัตราการเป็นวัณโรค ผู้ป่วยรายใหม่ต่อประชากร 100,000 คนต่อปีเพิ่มขึ้น 3.6% ระหว่างปี 2020 ถึง 2021 [1] สาเหตุเนื่องมาจากความยากจนที่เพิ่มขึ้น ไม่เพียงเกิดในเฉพาะประเทศที่ยากจน แต่รวมไปถึงกลุ่มประชากรชายขอบ (Marginalized Populations) หรือ

กลุ่มประชากรที่ถูกปฏิบัติอย่างไม่เป็นธรรม ไม่ได้รับสิทธิขั้นพื้นฐาน เนื่องจากความแตกต่างทางด้านเชื้อชาติ ในประเทศแห่งอุตสาหกรรม การเติบโตของประชากร ซึ่งเด็กที่เกิดในช่วงไม่กี่ทศวรรษที่ผ่านมา มีอัตราการเกิดสูงในประเทศที่พบเชื้อวัณโรคมก ซึ่งปัจจุบันจะอยู่ในช่วงอายุที่พบผู้ป่วยวัณโรคมกขึ้น การแพร่ระบาดของโรค HIV ซึ่งมีส่วนทำให้จำนวนผู้ป่วยวัณโรคมกเพิ่มขึ้น และการขาดแคลนทรัพยากรที่จำเป็นสำหรับการตรวจหาเชื้อเพื่อการรักษาที่มีประสิทธิภาพ [5] ประเทศที่มีแนวโน้มพบวัณโรคสูง คือประเทศที่มีระดับการรักษาต่ำ ในปี 2021 จากการประเมินความครอบคลุมในการรักษาต่ำกว่า 50% ได้แก่ สาธารณรัฐแอฟริกากลาง กาบอง อินโดนีเซีย เลโซโท ไลบีเรีย มองโกเลีย เมียนมาร์ ไนจีเรีย ฟิลิปปินส์ และเวียดนาม จะเห็นว่าผู้ป่วยส่วนใหญ่มกอยู่ในประเทศแถบ เอเชียตะวันออกเฉียงใต้ แอฟริกา และทางตะวันตกของแปซิฟิก เนื่องจากไม่ได้รับการรักษาที่ครอบคลุม [6-8] จำนวนผู้ป่วยที่เป็นวัณโรคทั้งหมดในแต่ละปี ประมาณ 90% เป็นผู้ใหญ่ โดยผู้ป่วยมักจะเป็นในกลุ่มของผู้ชายมากกว่าผู้หญิง ซึ่งคิดเป็น 56.5% ของผู้ป่วยทั้งหมดในปี 2021 ผู้หญิง 32.5% และเด็ก 11% และหากไม่ได้รับการรักษาอัตราการเสียชีวิตจะสูงถึง 50% [9] การเข้าถึงการวินิจฉัย การตรวจหาเชื้อจะช่วยลดการแพร่กระจายของเชื้อ และจะช่วยลดอัตราการเสียชีวิตจากเชื้อวัณโรคมกได้มากขึ้น

การตรวจสอบหาเชื้อวัณโรคมกมีความสำคัญเป็นอย่างมาก เนื่องจากช่วยให้วินิจฉัยโรคได้อย่างถูกต้อง เพื่อนำไปทดสอบประสิทธิภาพของยา การดื้อยา และ ช่วยให้มั่นใจว่าระบบการรักษามีประสิทธิภาพ [1] การตรวจสอบหาเชื้อวัณโรคมกมีหลากหลายวิธี เช่น การตรวจเสมหะด้วยวิธี Sputum Smear Microscopy เป็นการหาเชื้อด้วยตาเปล่าผ่านกล้องจุลทรรศน์เพื่อดู Stain Smears ค้นหาเชื้อที่มีลักษณะเป็นแท่ง หรือ เส้นแถบ ซึ่งวิธีนี้ต้องใช้บุคลากรที่มีความชำนาญ อีกทั้งมีความเที่ยงตรงต่ำ ที่อาจจะเกิดจากความเหนื่อยล้า และความแปรปรวนของผู้ประเมิน [10] การเพาะเชื้อและตรวจด้วยวิธี Polymerase Chain Reaction (PCR) โดยผลการเพาะเชื้อจะถูกนำมาตรวจสอบคัดกรอง Smear ซึ่งเป็นมาตรฐานการตรวจหาเชื้อในปัจจุบัน แต่การเพาะเชื้อมีราคาแพงและต้องใช้เทคนิคเฉพาะทางมากกว่าการตรวจแบบ Smear Microscopy และใช้เวลาในการเพาะเชื้อนาน 2-4 สัปดาห์ เพื่อให้ประเมินได้แม่นยำ ทำให้เกิดความล่าช้าในการรักษาได้ ภาพถ่ายเอกซเรย์ทรวงอก หรือ Chest X-Ray (CXR) เพื่อใช้ในการตรวจหาเชื้อวัณโรคมกระยะเริ่มต้นในเด็ก และผู้ใหญ่ที่มีความเสี่ยงสูงต่อการติดเชื้อวัณโรคมก [7] แต่วิธีนี้ต้องอาศัยแรงงานคนที่มีประสบการณ์ และความชำนาญในด้านการดูผลการเอกซเรย์ เช่น แพทย์ รังสีแพทย์ หรือช่างเทคนิค ที่ผ่านการฝึกอบรมและมีประสบการณ์ด้านการอ่านผล [11] การตรวจหาเชื้อในระดับโมเลกุล Rapid Diagnostic Test

(mWRDs เช่น Xpert MTB/RIF) ใช้เป็นเครื่องมือสำหรับคัดกรองผู้ป่วยที่มีความเสี่ยงสูง มักจะใช้ใน กลุ่มผู้ป่วยที่รักษาตัวในโรงพยาบาลที่ติดเชื้อ HIV ในพื้นที่ที่มีภาวะของวัณโรคสูง เนื่องจากการ ตรวจหาเชื้อลักษณะนี้มีการคัดกรองที่จำกัด ค่าตรวจมีราคาสูง และในปัจจุบันมีการนำเทคโนโลยี ทางด้าน Machine Learning เข้ามามีบทบาทในการใช้ตรวจสอบหาเชื้อวัณโรค สามารถเรียนรู้ และสามารถประมวลผลชุดข้อมูลที่ซับซ้อนได้ [12] ทำให้สามารถตรวจหาเชื้อได้อย่างมีประสิทธิภาพ [13] สำหรับ Machine Learning นั้น นักวิจัยหลายคนได้ศึกษาวิธีการ ใช้ Deep Learning มาทำการ วิเคราะห์ถูกออกแบบให้เรียนรู้รูปแบบ และ คุณสมบัติโดยอัตโนมัติจากชุดข้อมูลขนาดใหญ่เมื่อป้อน ข้อมูลที่มีป้ายกำกับจำนวนมากให้กับ Model ทำให้สามารถเรียนรู้ความสัมพันธ์ระหว่าง Input และ Output ด้วยเทคนิคการเพิ่มประสิทธิภาพแบบวนซ้ำ เช่น การไล่ระดับสี แบบจำลองจะปรับ พารามิเตอร์ภายในเพื่อลดข้อผิดพลาดระหว่างการคาดคะเนและผลลัพธ์จริง ประสิทธิภาพของโมเดล จะดีขึ้นเมื่อเรียนรู้จากข้อมูลมากขึ้น ทำให้สามารถสรุปเป็นข้อมูลใหม่ที่มองไม่เห็นได้ สามารถ คาดการณ์และจัดหมวดหมู่ด้วยความแม่นยำสูง เมื่อนำไปใช้กับข้อมูลภาพทางการแพทย์ เช่น เอกซเรย์และซีทีสแกน โมเดลจะสามารถช่วยบุคลากรทางการแพทย์ในการตรวจหาโรค อย่างมี ประสิทธิภาพมากขึ้น

การศึกษานี้เป็นการรวมเทคโนโลยีการประมวลผลภาพ (Image Processing) และการใช้ Deep Learning ซึ่งการใช้ Deep Learning จะใช้วิธีวิเคราะห์ข้อมูลแบบ Modified Classification และ แบบ Object Detection มาเปรียบเทียบกับ เป็นการผสมผสานเทคโนโลยีที่ช่วยให้ระบบ สามารถประมวลผลภาพเพื่อแยกแยะและรู้จักวัตถุในภาพได้อย่างมีประสิทธิภาพ สามารถตรวจหา เชื้อได้รวดเร็ว ช่วยในกระบวนการวินิจฉัยโดยอัตโนมัติให้กับผู้เชี่ยวชาญทางการแพทย์ ลดความ ผิดพลาดที่เกิดจากคน หรือ Human Error สามารถให้ผลลัพธ์ที่เป็นกลางและสอดคล้องกันมากขึ้น แก้ไขปัญหาทางการแพทย์และช่วยเพิ่มประสิทธิภาพในการวินิจฉัยและการดูแลสุขภาพผู้ป่วยในระดับ ที่สูงขึ้นได้อย่างมีคุณภาพและน่าเชื่อถือ

1.2 วัตถุประสงค์

- 1.2.1 พัฒนาโปรแกรมเพื่อตรวจหาเชื้อวัณโรค
- 1.2.2 เพื่อประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียม เพื่อช่วยแพทย์ตรวจหาเชื้อวัณโรค

1.3 ขอบเขตงานวิจัย


- 1.3.1 ศึกษาภาพถ่ายที่ได้จากกล้องจุลทรรศน์
- 1.3.2 พัฒนาวิธีการตรวจหาเชื้อโดยใช้ Deep Learning ในการวิเคราะห์

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1.4.1 โปรแกรมสามารถตรวจหาเชื้อวัณโรคได้อย่างรวดเร็ว
- 1.4.2 โปรแกรมช่วยทำนายและวินิจฉัยทางการแพทย์ได้อย่างรวดเร็ว

1.5 วิธีดำเนินการวิจัย

- 1.5.1 ศึกษางานวิจัยที่เกี่ยวข้อง กับหัวข้องานวิจัย
- 1.5.2 ศึกษาวิธีการวิเคราะห์ภาพ การใช้โปรแกรม
- 1.5.3 ศึกษา Deep Learning สำหรับเป็นแนวทางในการเพิ่มความถูกต้องแม่นยำ




บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 Acid-Fast Stain

Acid-Fast Stain เป็นวิธีการย้อมสีเชื้อเพื่อใช้ในการตรวจหาเชื้อขั้นต้น ซึ่งเชื้อที่จะนำมาเพาะเลี้ยง และย้อมสีด้วยวิธีนี้มักจะเป็นเชื้อในกลุ่ม ไมโครแบคทีเรีย (Mycobacterium) ซึ่งเชื้อวัณโรคหรือ Mycobacterium Tuberculosis นั้นจัดอยู่ในกลุ่มนี้ [14] เชื้อแบคทีเรียทนต่อกรดมักจะมีลักษณะเป็นไซ มีผนังเซลล์แบบ Impermeable Cell Wall ซึ่งเป็นผนังเซลล์ที่ไม่ให้สารต่างๆผ่านได้ ประกอบไปด้วยกรดโมโคลิค กรดไขมัน ไซ และไขมันเชิงซ้อนจำนวนมาก ผนังเซลล์ลักษณะนี้จะทนต่อสารประกอบส่วนใหญ่ ดังนั้นจึงต้องใช้เทคนิคการย้อมสีแบบพิเศษ สีย้อมหลักที่ใช้ในการย้อมแบบ Acid-Fast Stain คือ คาร์โบฟูคซิน ซึ่งสามารถละลายได้ในไขมัน ฟีนอลในคาร์โบฟูคซินจะช่วยให้สีที่ย้อมเข้าไปในผนังเซลล์ที่เป็นไซของแบคทีเรียได้ง่ายขึ้น แบคทีเรียที่ทนต่อกรดจะติดสีไม่ติดหากทำการย้อมแบบปกติ การเพิ่มความร้อนเข้าไปด้วยไอน้ำจะช่วยคลายชั้นไซ และจะช่วยทำให้สีย้อมคาร์โบฟูคซินเข้าสู่ผนังเซลล์เมื่อสีย้อมเข้าสู่ผนังเซลล์จะไม่ออกมา จากนั้นจะใช้ Acid-Alcohol จะกำจัดสีออกจากผนังเซลล์ของแบคทีเรียที่ไม่ทนต่อกรดทันทีและไม่ซึมผ่านผนังเซลล์ของแบคทีเรียที่ไวต่อกรด เนื่องจากคุณสมบัตินี้ ทำให้ง่ายต่อการมองเห็นได้ชัดเจนด้วยกล้องจุลทรรศน์ ดังภาพที่ 1 ซึ่งช่วยในการตรวจสอบหาเชื้อที่เกิดจากแบคทีเรียที่ไวต่อกรด ไม่ว่าจะเป็นโรควัณโรค (Tuberculosis) หรือโรคเรื้อน (Leprosy) [15] ซึ่งจะสะดวกในการติดตามการรักษาว่าหลังเข้ารับการรักษามีผลการตอบสนองต่อการรักษาอย่างไร



ภาพที่ 1 การย้อมสีเชื้อด้วยวิธี Acid-Fast Stain

2.1.1 วิธีการย้อมสีเชื้อ Acid-Fast Stain


วิธีการย้อมสีเชื้อ Acid-Fast Stain ทำได้โดย เตรียมสไลด์ที่มี Smear วางบน Stain Rack หันด้าน Smear ขึ้นด้านบน โดยวางแต่ละสไลด์ห่างกันประมาณ 1 เซนติเมตร ใส่สารละลายคาร์โบลฟูจีน โดยใส่จากขอบด้านบนของสไลด์ หลังจากนั้นให้ความร้อนแต่ละสไลด์ จนกระทั่งเกิดควัน พักไว้ 10 นาที การพักไว้นานขึ้นจะทำให้ Stain ดีขึ้น โดย Stain ต้องไม่แห้ง ล้างแต่ละสไลด์ด้วยน้ำเปล่า ใส่สารละลายดสี (Decolorizing Solution) ลงบนสไลด์ พักไว้ 3 นาที ล้างแต่ละสไลด์ด้วยน้ำเปล่า ใส่เมทิลีนบลูบนสไลด์เป็น ทิ้งไว้ 60 วินาที ล้างแต่ละสไลด์ด้วยน้ำเปล่า ผึ่งลมให้แห้งห่างจากแสงแดด โดยตรง ห้ามซับด้วยกระดาษ ทำความสะอาดด้านหลังของสไลด์ด้วย Moist Paper รอจนกว่าสไลด์จะแห้ง เมื่อเสร็จสิ้นกระบวนการจะได้สไลด์ที่ย้อมสี Smear อย่างถูกต้อง

การอ่านค่า Smear หันด้าน Smear ให้อยู่ด้านบน ทำการหยด Immersion Oil ลงบน Smear โดยที่หัวหยดไม่สัมผัสกับ Smear ป้องกันการปนเปื้อน ใช้กำลังการขยายเลนส์วัตถุ 10x ในการโฟกัส Smear ครั้งแรก ตรวจสอบเชื้อโดยมองจากจุดที่มีเชื้อ หากว่า Smear หนา บางเกินไป หรือมีเฉพาะเยื่อบุเซลล์ (Epithelial Cells) ให้ทำการเลื่อนขึ้นลง เพื่อหาเชื้อ ควรระวังการหมุนเลนส์ใกล้วัตถุ


2.1.2 กล้องที่ใช้สำหรับตรวจดูเชื้อวัณโรค

กล้อง Light Microscopy ในห้องปฏิบัติการเป็นทางเลือกที่ถูกกว่ามากสำหรับกระบวนการที่ซับซ้อนและมีค่าใช้จ่ายสูงในการตรวจหาเชื้อวัณโรค ผู้ที่ทำการตรวจหาเชื้อ ต้องได้รับการฝึกอบรมปฏิบัติตามขั้นตอนการปฏิบัติงานมาตรฐานที่ถูกต้อง และในการศึกษานี้ภาพเชื้อวัณโรคที่ได้จากกล้อง Light Microscopy จะมีขนาดอยู่ที่ประมาณ 48 GB ต่อหนึ่งภาพ ซึ่งเป็นไฟล์ขนาดใหญ่ จึงต้องทำการครอบตัดรูปภาพเพื่อให้ไฟล์มีขนาดเล็กลงก่อนนำไปวิเคราะห์


การตรวจลักษณะที่ปรากฏของแบคทีเรีย Acid-Fast Stain เมื่อมองด้วยเลนส์ที่ใส่น้ำมัน Acid-Fast Stain จะเป็นสีแดง มีลักษณะเป็นแท่งเรียวยาว บางครั้งมีเม็ดเล็กตั้งแต่หนึ่งเม็ดขึ้นไป โดยลักษณะเชื้อวัณโรคจะมีลักษณะแตกต่างกัน 4 แบบ คือ แบบ Single Bacilli แบบ V-shape Forms แบบ Clumps of Bacilli และ แบบ Bacilli fragments ดังภาพที่ 2 การย้อมสีบางครั้งอาจเกิดปัญหาต่างๆทำให้ภาพที่ได้ออกมาผิดไปจากเดิม โดยลักษณะปัญหาที่พบได้บ่อยจะแสดงดังตารางที่ 2




(a) Single Bacilli



(b) V-Shaped Forms



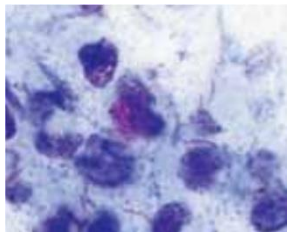

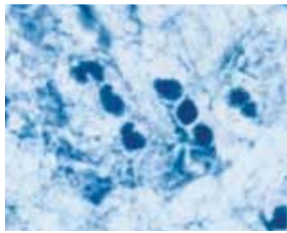
(c) Clumps Of Bacilli

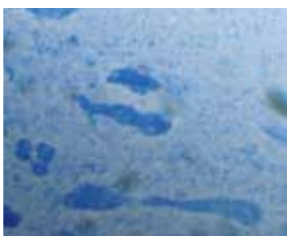
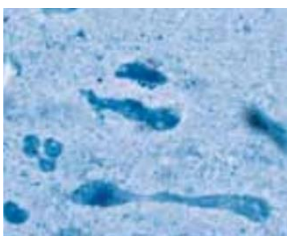
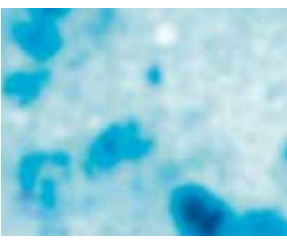
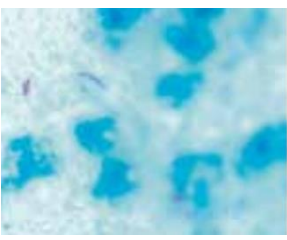
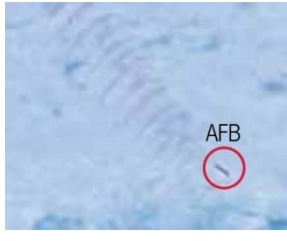


(d) Bacilli Fragments

ภาพที่ 2 ลักษณะเชื้อวัณโรค 4 แบบ คือ (a) Single Bacilli (b) V-Shape Forms (c) Clumps Of Bacilli และ (d) Bacilli Fragments


ตารางที่ 2 ลักษณะภาพย้อมสีที่ที่ไม่ได้คุณภาพ

ลักษณะภาพ	ปัญหา	สาเหตุ
	Smear ติดสีชมพู มากเกินไป	- การดูดซับสีไม่เพียงพอ - ความเข้มข้นของกรดต่ำ หรือ ใช้เวลาในการย้อมสั้นเกินไป - Carbol Fuchsin (CF) แห่งติดบน smear
	Acid-fast bacilli มีสีซีด	- Carbol Fuchsin (CF) ที่มีคุณภาพต่ำ - Carbol Fuchsin (CF) ให้ความร้อนไม่เพียงพอ - Carbol Fuchsin (CF) ใช้เวลาย้อมน้อยกว่า 10 นาที - Smear ร้อนเกินไปในขั้นตอนการเตรียม หรือการย้อมสี - Carbol Fuchsin (CF) Reagent หมดอายุ
	Counterstain ทึบ เกินไป	- ใช้เวลาในการทำ Counterstain นานเกินไป - การล้างไม่สะอาด หลังจากการทำ Counterstaining - Smear หนาเกินไป


ลักษณะภาพ	ปัญหา	สาเหตุ
	Deposit บนสไลด์	<ul style="list-style-type: none"> - Stain ไม่ได้ทำการกรอง - มีฝุ่นสะสมด้านล่าง Smear
	การส่องสว่างไม่สม่ำเสมอ	<ul style="list-style-type: none"> - ขอบเขตของภาพถูกบังบางส่วน - Iris Diaphragm โกล้เกินไป หรือ Condenser ไม่อยู่ในแนวเดียวกัน - เลนส์สกปรก - มีเชื้อราบนเลนส์มาก
	Contrast ภาพมากเกินไป	<ul style="list-style-type: none"> - Iris Diaphragm โกล้เกินไป
	Oil Immersion ไม่ได้สามารถทำให้ภาพชัดได้	<ul style="list-style-type: none"> - น้ำมันบนสไลด์ไม่เพียงพอ, น้ำมันมีคุณภาพต่ำ (การหักเหแสงต่ำ), มีน้ำมันอยู่ในเลนส์, เกิดฟองอากาศในน้ำมัน - แหล่งกำเนิดแสง หรือ Condenser ที่จับเลนส์สกปรก - พื้นผิวเลนส์สกปรก - มีน้ำเกาะบนสไลด์
	ฝุ่นหรือสิ่งสกปรก	<ul style="list-style-type: none"> - ฝุ่นบนที่จับเลนส์ของแหล่งกำเนิดแสง - ฝุ่นบนสุดของเลนส์ Condenser - ฝุ่นเกาะบน Eyepiece
	ภาพรอยที่มีลักษณะคล้ายเชื้ออาจทำให้สับสนกับเชื้อที่ย้อมสีได้	<ul style="list-style-type: none"> - กระจกสไลด์มีรอยขีดข่วน

2.2 ระบบสี Color Model

ระบบสีเป็นระบบที่สามารถวัดการรับรู้การมองเห็นของมนุษย์ เป็นการรวมกันของค่าต่างๆ ในชุดสีหลัก โดยเราสามารถรับรู้ผ่านคุณลักษณะต่างๆ ไม่ว่าจะเป็นด้านสีส้มหรือความสว่าง ซึ่งระบบสีแต่ละระบบก็จะพิจารณาคุณสมบัติของสีแตกต่างกัน เช่น ระบบสี RGB จะมีแม่สี คือ สีแดง สีเขียว และสีน้ำเงิน เป็นการใช้สัดส่วนของสามสีที่แตกต่างกัน เพื่อทำให้เกิดสีที่หลากหลาย วัตถุประสงค์หลักของระบบสี RGB คือ การตรวจจับ และการแสดงภาพในระบบอิเล็กทรอนิกส์ จำพวกโทรทัศน์ หรือคอมพิวเตอร์ ดังภาพที่ 3(a) ส่วนในระบบสี HSV จะประกอบไปด้วย Hue Saturation และ Value โดย Hue คือ สีหลักของภาพ Saturation คือ ความอิ่มตัวของสี และ Value คือ ปริมาณความสว่างของภาพ ซึ่งจะใช้สำหรับ Computer vision และการวิเคราะห์ภาพในกระบวนการ Segmentation ดังภาพที่ 3(b) [17]



(a) RGB



(b) HSV

ภาพที่ 3 แสดงการเปรียบเทียบค่าสี (a) RGB และ (b) HSV

2.3 การประมวลผลภาพ (Image Processing)

การประมวลผลภาพ เป็นวิธีการแปลงภาพในรูปแบบ ดิจิตอล เน้นการจัดการ การวิเคราะห์ และการตีความภาพดิจิทัล โดยนำเทคนิคและอัลกอริทึมต่างๆ มาประยุกต์ใช้กับภาพ เพื่อปรับปรุง คุณภาพภาพ และดึงข้อมูลที่เป็นประโยชน์จากภาพ ให้เหมาะสมกับงานหรือการใช้งานที่เฉพาะมากขึ้น มีบทบาทสำคัญในด้านต่างๆ เช่นการใช้งานภาคธุรกิจด้านการออกแบบกราฟิก วิศวกรรม และ วิทยาการคอมพิวเตอร์ เทคนิคที่ใช้ในการประมวลผลภาพที่สำคัญ มีดังต่อไปนี้

2.3.1 เทคนิค Basic Enhancement and Restoration

การนำภาพเข้าระบบ (Image Acquisition) ในบางครั้งอาจลดคุณภาพของภาพโดยไม่ได้ตั้งใจ เนื่องจากปัญหาทางของอุปกรณ์ อาจมีการเบลอเนื่องจากอยู่นอกโฟกัส การเคลื่อนไหว แสงที่ไม่เหมาะสม และสัญญาณรบกวน จึงทำให้คุณภาพลดลงกว่าภาพต้นฉบับ จุดประสงค์ของการปรับปรุงภาพด้วยเทคนิค Enhancement คือ ความสวยงามของภาพ (Beauty) จากการบันทึกภาพ $c[m, n]$ เพื่อสร้างภาพที่ดูสบายตามากที่สุด $\hat{a}[m, n]$ ส่วนจุดประสงค์ของเทคนิค Restoration คือ การแสดงภาพจริง (Truth) จากการบันทึกภาพ $c[m, n]$ เพื่อหาค่าประมาณที่ดีที่สุดที่เป็นไปได้ $\hat{a}[m, n]$ จากภาพต้นฉบับ $a[m, n]$

การวัดประสิทธิภาพของ เทคนิค Restoration จะใช้ค่า Error วัดระหว่าง ภาพต้นฉบับ $a[m, n]$ กับ ภาพที่ได้จากการประมาณ $\hat{a}[m, n]$: $\varepsilon\{\hat{a}[m, n], a[m, n]\}$ โดยทั่วไปจะใช้ฟังก์ชัน Mean-Square Error ในการวัด เนื่องจากคำนวณได้ง่าย สามารถหาค่าอนุพันธ์ ซึ่งหมายความว่าสามารถหาค่าที่น้อยที่สุดได้ ดังสมการ

$$\varepsilon\{\hat{a}, a\} = \frac{1}{MN} \sum_{M=0}^{M-1} \sum_{N=0}^{N-1} |\hat{a}[m, n] - a[m, n]|^2 \quad (1)$$

2.3.1.1 Unsharp Masking

Unsharp Masking เป็นเทคนิคการเพิ่มขอบของภาพเพื่อปรับปรุงคุณภาพการมองเห็น โดยแยกขอบภาพออกก่อน ทำการขยายขอบภาพ จากนั้นจึงเพิ่มกลับเข้าไปในภาพเดิม โดยที่ k คือ ค่าความขยาย (Amplifying Term) และ $k > 0$ ดังสมการ (3)

$$\hat{a}[m, n] = a[m, n] - (k \cdot \nabla^2 a[m, n]) \quad (2)$$

2.3.1.2 Noise Suppression

Noise Suppression เป็นเทคนิคลดการรบกวน ด้วย Temporal information คือ ลำดับภาพ $\{a_p[m, n] \mid p = 1, 2, \dots, P\}$ ที่มีวัตถุเหมือนกัน แตกต่างกันเฉพาะการรับสัญญาณรบกวน เมื่อมีสัญญาณรบกวน จะหาค่าได้จากสมการ

$$\text{Temporal Averaging } \hat{a}[m, n] = \frac{1}{P} \sum_{p=1}^P a_p[m, n] \quad (3)$$

ผลลัพธ์ที่ได้ ค่าเฉลี่ยของแต่ละพิกเซลจะไม่เปลี่ยนแปลง ค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) จะลดลงจาก σ ไป $\frac{\sigma}{\sqrt{P}}$ หากไม่สามารถหา Temporal Averaging ได้ สามารถใช้ค่า Spatial Averaging เพื่อลดสัญญาณรบกวนได้ แต่จะมีผลต่อความคมชัดของภาพ

2.3.1.3 Distortion Suppression

Distortion Suppression เป็นเทคนิคที่ปรับปรุงภาพที่ถูกสัญญาณรบกวนที่ซับซ้อน เนื่องจากในความเป็นจริงนอกจากภาพเกิดสัญญาณรบกวนแล้ว อาจเกิดจากเลนส์กล้อง รูรับแสง การเคลื่อนไหวของกล้อง หรือ วัตถุ ซึ่งแบบจำลองที่ใช้บ่อย คือ ภาพ $a[m, n]$ ที่ถูก Distort เชิงเส้น Shift-Invariant System $h_o[m, n]$ (เช่น เลนส์) และ สัญญาณรบกวนที่ป้อนเข้ามา $K[M, N]$ ดังสมการ

$$c[m, n] = (a[m, n] \otimes h_o[m, n]) + K[m, n] \quad (4)$$

ซึ่งขั้นตอนการปรับปรุงภาพจะใช้ Linear Filter ควบคู่กับ Mean-Square Error ที่น้อยที่สุด เพื่อสร้าง Wiener Filter

$$H_w(u, v) = \frac{H_o^*(u, v) S_{aa}(u, v)}{|H_o(u, v)|^2 S_{aa}(u, v) + S_{nn}(u, v)} \quad (5)$$

$$= \frac{H_o^*(u, v)}{|H_o(u, v)|^2 + \frac{S_{nn}(u, v)}{S_{aa}(u, v)}} \quad (6)$$

โดยที่ $S_{aa}(u, v)$ คือ Power spectral density ของภาพสุ่ม และ $S_{nn}(u, v)$ คือ Power Of Density ของสัญญาณรบกวน และ $H_o(u, v) = F\{h_o[m, n]\}$ เมื่อ ความถี่ $S_{aa}(u, v) \gg S_{nn}(u, v)$ Signal Spectrum จะมีอิทธิพลมากกว่า Spectrum ที่มีสัญญาณรบกวน และ Wiener Filter กำหนดโดย $\frac{1}{h_o(u, v)}$ ซึ่งเป็น Filter แบบผกผัน ส่วนความถี่ $S_{aa}(u, v) \ll S_{nn}(u, v)$ Spectrum ที่มีสัญญาณรบกวนจะมีอิทธิพลมากกว่า Signal Spectrum และ Wiener Filter กำหนดโดย $h_o(u, v) = 0$ ซึ่งเป็น Filter ที่ตรงกัน และเมื่อความถี่ $h_o(u, v) = 0$ Wiener Filter $h_w(u, v) = 0$ เพื่อป้องกันการ Overflow การใช้ Wiener Filter เป็นวิธีแก้ปัญหาเทคนิคการ Restoration โดยการใช้ Linear Filter และ ค่าที่น้อยที่สุดของ Mean-Square Error (rms) [18]

2.3.2 Segmentation

Segmentation เป็นวิธีการวิเคราะห์ภาพสำหรับแบ่งแยกความแตกต่างของวัตถุที่เราต้องการในภาพนั้น ออกจากวัตถุอื่นในภาพ หรือแบ่งแยกพื้นหลังออกจากกัน เมื่อทำการ Segmentation จะทำให้รู้ว่า พิกเซลไหนเป็นของวัตถุใดในภาพ โดยสามารถแบ่งออกเป็น 4 กลุ่มได้แก่

2.3.2.1 Pixel-Based Segmentation

Pixel-Based Segmentation เป็นเทคนิคการใช้ Whole Palette โดยเริ่มจากการปรับความสว่าง (Illumination) ของฉากให้เหมาะสม หลังจากนั้นระบุ Unevenness ของ ความสว่าง (Illumination) แต่มีข้อเสียคือ ส่งผลให้เกิดการ Bias ของขนาดวัตถุที่ทำการแบ่งส่วน

2.3.2.2 Edge-Based Segmentation

เมื่อวัตถุแสดงการเปลี่ยนแปลงของ Gray Values วัตถุที่เข้มจะเล็กเกินไป ส่วนวัตถุที่สว่างจะใหญ่เกินไป การเปลี่ยนแปลงนี้เป็นผลมาจาก Gray Values ที่ขอบของวัตถุ จะเปลี่ยนพื้นหลังไปยังวัตถุที่ละน้อย ไม่เกิดการ Bias การเอียงเอียงของขนาด เนื่องจากใช้ค่าเฉลี่ยของวัตถุและค่าสีเทาพื้นหลังเป็นเกณฑ์ อย่างไรก็ตามแนวทางนี้จะเป็นไปได้ก็ต่อเมื่อวัตถุทั้งหมดแสดง Gray Values ที่เหมือนกัน หรือใช้เกณฑ์ตามแต่ละวัตถุ สามารถใช้วิธีอื่นเพื่อแบ่งส่วนตามขอบ หลีกเลี่ยงการเกิด Bias ขนาดของวัตถุที่ทำการแบ่งส่วนโดยไม่ต้องใช้เกณฑ์ที่ซับซ้อน Edge-Based Segmentation จะขึ้นอยู่กับตำแหน่งของขอบ ดังสมการ

$$\frac{\partial}{\partial x_w} = 2\pi i k_w, \frac{\partial^2}{\partial x_w^2} = -4\pi^2 k_w^2 \quad (7)$$

โดยหาค่าสูงสุดของ edge strength และหาค่าขอบที่สูงที่สุดของวัตถุ

-Bias by Uneven Illumination

ในการศึกษา Bias ของ Segmentation แบบต่างๆ ของภาพที่มีพื้นหลังไม่สม่ำเสมอ และมีค่าความสว่าง (Brightness) ของวัตถุที่แตกต่างกัน การเบลอบของวัตถุสามารถสร้างแบบจำลองด้วยฟังก์ชัน $h(x)$ จึงสร้าง Models 1-D case ความสว่างของภาพขอบที่จุด Origin เขียนได้ดังนี้

$$g(x) = g_0 \int_{-\infty}^x h(x) dx \quad \text{with} \quad \int_{-\infty}^{\infty} h(x) dx = 1 \quad (8)$$

ความเข้ม (intensity) ของพื้นหลังสามารถจำลองให้อยู่ในรูปการแปรผันของพหุนาม

$$b(x) = b_0 + b_1 x + b_2 x^2 \quad (9)$$

ผลรวมของ ค่าความเข้มในภาพ หาได้จากสมการ

$$g(x) = g_0 \int_{-\infty}^x h(x) dx + b_0 + b_1 x + b_2 x^2 \quad (10)$$

Edge-based segmentation จะไม่แสดง Bias ในตำแหน่งขอบแม้ว่า พื้นหลัง ค่าความเข้มจะเป็น Slope และไม่มี Bias ความเข้มของขอบ $g(0)$ เช่นเดียวกับ Intensity-Based Segmentation และ Edge-based Segmentation จะ Bias เฉพาะความโค้งของความเข้มพื้นหลัง ซึ่งจะเกี่ยวข้องกับความโค้งของจุด Point Spread Function ซึ่งหมายความว่า ค่า Bias จะสูงขึ้นเมื่อขอบเบลอบ อีกทั้ง ค่า Bias จะแปรผกผันกับความเข้มของวัตถุ จะมีผลต่อวัตถุที่ Weak Contrast

- Edge Tracking

เป็นวิธีการ Sequential ซึ่งตรงข้ามกับการ Pixel-Based และ Most Region-Based Segmentation ไม่สามารถดำเนินการแบบขนาน กับทุกพิกเซล ส่วนขั้นตอนต่อไปจะขึ้นอยู่กับผลลัพธ์ที่ได้ โดยรูปภาพถูกสแกนทีละบรรทัดเพื่อหาค่าสูงสุดตามการไล่ระดับสี (Gradient) รอบวัตถุ จนถึงจุดเริ่มต้นอีกครั้ง จากนั้นจะหาค่าสูงสุดถัดไปของการไล่ระดับสี (Gradient) คล้าย Region-Based segmentation ซึ่ง Edgebased Segmentation จะพิจารณาวัตถุที่มีลักษณะเฉพาะที่อยู่ติดกัน

-Region-Based Segmentation

จะเป็นการตัดแยกประเภทของ พิกเซล ซึ่งเป็นพิกเซลของวัตถุที่หาจาก Gray Value เท่านั้น ซึ่งหมายความว่า Isolated points หรือ พื้นที่ขนาดเล็กสามารถตัดแยกพิกเซลของวัตถุได้ โดยไม่คำนึงถึง Connectivity ของวัตถุ

เราจะได้ใช้ภาพต้นฉบับแต่จะใช้ คุณลักษณะของภาพ (Feature Image) เพื่อทำ segmentation ซึ่ง Feature Image จะไม่ได้แทนใน พิกเซลเดียวแต่ Small Neighborhood จะขึ้นอยู่กับ ขนาดของ The Mask ที่ต้องการมาทำการวิเคราะห์ อย่างไรก็ตามที่ขอบของวัตถุ ตำแหน่งที่ต้องการจะรวม พิกเซลจากวัตถุและพื้นหลัง ส่วนคุณลักษณะอื่นไม่สามารถนำมาเปรียบเทียบกันได้ ขั้นตอนที่ต้องคือการจำกัด ขนาดของ The Mask ที่ขอบของวัตถุหรือ พื้นหลัง จะเห็นได้ว่าไม่สามารถทำได้ภายในครั้งเดียว แต่จะทำซ้ำโดยใช้ขั้นตอน Feature Computation และ Segmentation ดังนี้ ขั้นแรก คำนวณคุณสมบัติโดยไม่คำนึงถึง ขอบเขตของวัตถุ (Object Boundaries) จากนั้นจะแบ่งส่วนขั้นต้น (Preliminary Segmentation) และ คำนวณ Feature อีกครั้ง ใช้ผลลัพธ์ของการ Segmentation มาจำกัด The mask ของ Neighborhood operations ที่ขอบของวัตถุไปยังวัตถุ หรือ พิกเซลพื้นหลังนั้น ขึ้นอยู่กับ พิกเซลตรงกลาง เพื่อการปรับปรุงที่ดีขึ้น สามารถทำซ้ำคำนวณ Feature Computation และ Segmentation จนกว่า ขั้นตอนจะรวมกันและเสถียร

2.3.2.3 Model-Based Segmentation

หากต้องการค่าเฉพาะที่เกี่ยวข้องกับรูปทรงเรขาคณิตของวัตถุ (Geometrical Shape) จะพิจารณาจาก เส้นตรง (Straight Lines)

-Parameter Space; Hough Transform

จะตรวจหาเส้น แม้ว่าอาจจะถูกสัญญาณรบกวนหรือ มองเห็นเพียงบางส่วน โดยสมมติว่า ภาพที่ถูก Segment มีเส้นประเกทนี้อยู่ จุดที่อยู่บนเส้นตรง สามารถกำหนดพารามิเตอร์ ของเส้นตรงโดยที่ a_0 และ a_1 คือออฟเซตและความชันของเส้นตรง ดังนี้

$$y_n = a_0 + a_1 x_n \quad (11)$$

แต่ในทางปฏิบัติแล้ว สมการข้างต้นไม่ได้ใช้ เนื่องจากความชันของเส้นตรงอาจไม่มีที่สิ้นสุด และไม่เหมาะสมกับแบบจำลองที่ไม่ต่อเนื่อง การกำหนดพารามิเตอร์ที่ดีกว่าของเส้นตรงจะใช้ 2 พารามิเตอร์ที่แตกต่างกัน ความเป็นไปได้ อย่างหนึ่งคือการใช้ Angle of slope ของเส้น และ ระยะห่างของเส้น จากจุดกึ่งกลาง ของระบบพิกัด จะได้สมการ

$$\tilde{n}x = d \text{ or } x \cos\theta + y \sin\theta = d \quad (12)$$


เมื่อ \tilde{n} เป็นเวกเตอร์ปกติ θ เป็นมุมของเวกเตอร์นี้ไปยัง แกน x ของภาพในระบบพิกัดนี้ [19] ซึ่งการศึกษาครั้งนี้ คัดแยกเชื้อวัณโรคจากการใช้วิธีการ Segmentation เพื่อแยกเชื้อออกจาก วัตถุที่ไม่ต้องการ โดยทำการแบ่งแยกตัวเชื้อ กับ ปอด และพื้นหลังออกจากกัน ด้วยวิธี Erosion แล้ว ทำการแยกสีเชื้อกับเนื้อปอดด้วย ช่วงค่าสี แบบ HSV เพื่อให้ง่ายต่อการครอบตัดรูปภาพ เฉพาะเชื้อ วัณโรคเพียงอย่างเดียว แล้วนำไปวิเคราะห์ด้วย Deep Learning ในขั้นต่อไป

2.4 Convolutional Neural Network (CNN)

โครงข่ายประสาทเทียมแบบ Convolutional เป็นโครงข่ายประสาทเทียมชนิดหนึ่งที่มีหลายเลเยอร์ โดยจะประมวลผลข้อมูลที่มีการจัดเรียงแบบกริด เป็นการจำแนกภาพและการจดจำ วัตถุ โดยใช้ประโยชน์จากหลักการจากพีชคณิตเชิงเส้น โดยเฉพาะการคูณเมทริกซ์ เพื่อระบุรูปแบบ ภายในภาพ โดยใช้หน่วยประมวลผลกราฟิก (GPU) เพื่อฝึกโมเดล (Training Model) แบ่งชั้นการ วิเคราะห์ออกเป็น 3 ชั้น ได้แก่

Convolutional Layer

Convolutional Layer ดังภาพที่ 4 เป็นองค์ประกอบหลักของ CNN ต้องรับค่า Dataset ได้แก่ ข้อมูลเข้า ตัวกรอง และฟังก์ชันลักษณะ เช่น Input เป็นภาพสี ซึ่งประกอบด้วยเมทริกซ์พิกเซลใน แบบ 3 มิติ ซึ่งหมายความว่า Input จะมีสามมิติ ได้แก่ ความสูง ความกว้าง และความลึก ซึ่ง สอดคล้องกับระบบสี RGB อีกทั้งยังมีตัวตรวจจับคุณลักษณะ หรือ ที่เรียกว่าคอร์เนลหรือตัวกรอง (Kernel) ซึ่งจะเคลื่อนผ่านช่องรับสัญญาณของภาพ เพื่อตรวจสอบว่ามีคุณสมบัติที่น้อยอยู่หรือไม่ โดย ต้องใช้องค์ประกอบหลัก คือ Two-Dimensional (2-D) Array Of Weights จากนั้นตัวกรองจะถูก นำไปใช้กับพื้นที่ของรูปภาพ และ Dot Product จะถูกคำนวณระหว่างพิกเซลอินพุตและตัวกรอง Dot Product นี้จะถูกป้อนเข้าสู่ Array Output หลังจากนั้นตัวกรองจะเลื่อนไปที่ละช่อง ทำซ้ำ ขั้นตอนนี้จนกว่า Kernel ไปทั่วทั้งภาพ Output สุดท้ายจากชุดของ Dot Product จากอินพุตและตัว กรองเรียกว่า Feature Map



ภาพที่ 4 Convolutional Neural Network

Pooling layer

การรวม Layer ทำการลดขนาด ลดจำนวนพารามิเตอร์ใน Input เช่นเดียวกับ Convolutional Layer การดำเนินการรวมกลุ่มจะกวาดตัวกรองทั่วทั้ง Input แต่ความแตกต่างคือตัวกรองนี้ไม่มีน้ำหนักมาเกี่ยวข้อง คอร์เนลใช้ฟังก์ชันการรวมเข้ากับค่าภายในฟิลต์รับสัญญาณแทน โดยเติม Array Output

Fully-connected Layer (FC)

Fully-connected Layer (FC) ทำหน้าที่จัดประเภทตามคุณสมบัติที่แยกผ่านเลเยอร์ก่อนหน้า และตัวกรองต่างๆ ในขณะที่ Convolutional Layer และ Pooling Layer มักจะใช้ฟังก์ชัน ReLu Fully-Connected Layer (FC) มักจะใช้ประโยชน์จากฟังก์ชันการเปิดใช้งาน SoftMax เพื่อจำแนก Input อย่างเหมาะสม สร้างความน่าจะเป็นตั้งแต่ 0 ถึง 1

2.4.1 รูปแบบการวิเคราะห์ Deep Learning

Deep Learning มีหลักการทำงานคือ การเตรียมชุดข้อมูล (แบ่งกลุ่มข้อมูล, Label ข้อมูล, การกำหนดขอบเขตภาพ) แล้วทำการ Training ข้อมูล โดยการนำชุดข้อมูลมาฝึกซ้ำๆ ปรับปรุงการคาดคะเนจากการ Validation ชุดข้อมูล แล้วทำการประเมิน (Evaluation) ซึ่งโมเดลจะถูกทดสอบกับ ชุดข้อมูล Test dataset ซึ่งในส่วนของ การ Evaluation จะทำให้ทราบว่าโมเดลมีความแม่นยำหรือไม่ สามารถคาดการณ์กลุ่มของภาพที่ทำการวิเคราะห์ทั้งหมดโดยสามารถแบ่งประเภทการวิเคราะห์เป็น 3 วิธี คือ 1.) Modified Classification 2.) Object Detection และ 3.) Semantic Segmentation ดังตารางที่ 3 ตัวเลือกของการใช้งานขึ้นอยู่กับความต้องการเฉพาะและประเภทของข้อมูลเชิงลึกที่ต้องการดึงออกมาจากชุดข้อมูล [20]

2.4.1.1 Classification

เป็นวิธีการวิเคราะห์อย่างง่าย โดยการนำเข้าไฟล์ข้อมูลภาพ แล้วกำหนดกลุ่มของข้อมูล ดังภาพที่ 5 เป็นวิธีที่วิเคราะห์ภาพที่ว่าภาพนั้นปกติหรือผิดปกติ ใช้เวลาในการตั้งค่าชุดข้อมูลน้อย


สามารถวิเคราะห์เพื่อทำการตัดแยกได้อย่างรวดเร็ว การเตรียมข้อมูลจะเตรียมโดยการแบ่งชุดข้อมูล ออกเป็นชุดๆ เพื่อสำหรับ training และ testing ข้อดีของการวิเคราะห์แบบ Classification คือ เป็นการจำแนกประเภทข้อมูลที่ไม่ซับซ้อน โดยจะต้องแบ่งชุดข้อมูลว่าภาพปกติ หรือ ผิดปกติ สามารถ คาดการณ์ได้อย่างรวดเร็ว ส่วนข้อเสีย คือ การ Classification ไม่สามารถหาตำแหน่งของความ ผิดปกติภายในภาพได้



ภาพที่ 5 Classification

2.4.1.2 Object Detection

เป็นวิธีการ Localized วัตถุ และทำการตีกรอบสี่เหลี่ยมรอบวัตถุนั้น ดังภาพที่ 6 ซึ่งขั้นตอนนี้เรียกว่า การ Label กำหนดวัตถุที่ถูกตีกรอบให้อยู่ในกลุ่มที่ต้องการ สามารถกำหนดว่าจะ Label ภาพแบบ Axis-Parallel หรือ แบบ Oriented Rectangles ซึ่งวัตถุที่มีการทับซ้อนกัน บางส่วน จะถูกแยกออกจากกัน จะช่วยในการคำนวณจำนวนวัตถุ และ หาวัตถุว่าอยู่ตรงส่วนไหนของ ภาพ ข้อดีของการวิเคราะห์แบบ Object Detection คือ สามารถตรวจหาตำแหน่งของความผิดปกติ ภายในภาพได้ โดยการตรวจจับวัตถุที่อยู่ภายใน Bounding Box Coordinates โดยจะได้รับข้อมูลเชิงลึกเกี่ยวกับการกระจายความผิดปกติเชิงพื้นที่ แบบจำลองนี้สามารถใช้ได้กับทั้งกรณีความผิดปกติ เดี่ยวและหลายกรณี




ภาพที่ 6 Object Detection

2.4.1.3 Sematic Segmentation

เป็นวิธีการแบ่งกลุ่มให้แต่ละพิกเซลให้ข้อมูลตำแหน่งที่แม่นยำ ของรูปภาพ ระบุขอบเขตที่แม่นยำโดยการวาดขอบเขตพิกเซล ของวัตถุภายในภาพ เพื่อแยกความแตกต่างระหว่างสองกลุ่ม คือ ขอบ และ พื้นหลัง โดยมีวิธีการ Label อยู่ 3 วิธี คือ แบบ Polygons แบบ Pixel Masks และ แบบ Smart Labeling ลักษณะการ Label ดังภาพที่ 7 ข้อดีของการวิเคราะห์แบบ Segmentation คือ ได้รับข้อมูลที่มีความละเอียดสูง หาความผิดปกติและตำแหน่งได้ ข้อเสียของวิธีนี้ คือ การแบ่งส่วนใช้เวลานาน ใช้หน่วยความจำมาก และต้องใช้ความเชี่ยวชาญ โมเดล มีความซับซ้อน ทั้งทางด้าน Training และ การคาดการณ์แบบ Pixel [21]

จุฬาลงกรณ์มหาวิทยาลัย



(a) Polygons

(b) Pixel Masks

(c) Smart Labeling

ภาพที่ 7 Segmentation (a) Polygons (b) Pixel Masks (c) Smart Labeling

ตารางที่ 3 การเปรียบเทียบคุณสมบัติ Deep Learning Methods 3 แบบ คือ Classification Object Detection และ Segmentation

ตารางเปรียบเทียบ Deep Learning Method			
รายละเอียด (Description)	Classification	Object Detection	Segmentation
ลักษณะการทำงาน (Task)	จำแนกวัตถุจากภาพ	จำแนกวัตถุในภาพ และระบุตำแหน่งของวัตถุจาก Bounding boxes	แบ่งส่วนภาพ เป็นแต่ละพิกเซล แสดงรายละเอียดของขอบเขตและตำแหน่งของวัตถุในภาพ
สถาปัตยกรรม (Architectures)	Convolutional Neural Networks (CNNs)	Faster R-CNN, YOLO, and SSD	Fully Convolutional Networks (FCNs), U-Net, and Deep Lab
จุดเด่น (Advantages)	เป็นการจำแนกประเภทข้อมูลที่ไม่ซับซ้อน สามารถคาดการณ์ได้อย่างรวดเร็ว	จะช่วยให้การหาจำนวนวัตถุ และ สามารถตรวจหาตำแหน่งของวัตถุภายในภาพได้	ได้รับข้อมูลที่มีความละเอียดสูง หาความผิดปกติและตำแหน่งได้
จุดด้อย (Disadvantage)	ไม่สามารถหาตำแหน่งของความผิดปกติภายในภาพได้	การวิเคราะห์ช้าเนื่องจากต้องทำการกำหนด Bounding Boxes ในการจำแนกประเภท และการคาดคะเน	การ Segmentation ใช้เวลานาน ในการกำหนดขอบเขตของวัตถุ ใช้หน่วยความจำมาก และต้องใช้ความเชี่ยวชาญ
ตัวอย่างการใช้งาน (Example)	การจำแนกประเภทจัดระเบียบฐานข้อมูล เช่น แยกภาพดอกไม้ตามสายพันธุ์	การตรวจจับวัตถุสำหรับรถยนต์อัตโนมัติ กล้องวงจรปิด และหุ่นยนต์เพื่อการนำทาง	การวินิจฉัยโรค วางแผนการรักษา และติดตามความก้าวหน้าของโรค กำหนดเส้นรอบ ๆ วัตถุที่ตรวจพบแต่ละชิ้นพร้อมกับจัดประเภทข้อมูล

2.4.2 Pretrained Model

2.4.2.1 Enhanced

เป็น Pretrained Model ของโปรแกรม Deep Learning MVtec ซึ่งเป็น Neural Network ที่ออกแบบให้มีหน่วยความจำ และการประมวลผลที่มีประสิทธิภาพ ที่มี Layer ที่ซับซ้อนเหมาะสมสำหรับงานจำแนกที่ซับซ้อน ขนาดความกว้างและความสูงของรูปภาพที่จะนำมาวิเคราะห์ไม่ควรต่ำกว่า 47 Pixels อีกทั้งไม่มีการจำกัดขนาดของไฟล์รูปภาพ แต่ขนาดไฟล์รูปภาพที่ใหญ่จะเป็นการเพิ่มการใช้หน่วยความจำ และเวลาในการประมวลผลเพิ่มขึ้น

2.4.2.2 ResNet50 หรือ Residual Neural Networks

เป็น Pretrained Model ที่มีความใกล้เคียงกับ Enhanced เหมาะสมสำหรับงานที่ซับซ้อนมากขึ้น มีความเสถียรมากขึ้น เป็นโครงข่ายประสาทเทียมที่มี 50 Layer ประกอบไปด้วย 48 Convolutional Layer, Max Pooling Layer และ Average Pooling Layer ขนาดความกว้างและความสูงของรูปภาพที่จะนำมาวิเคราะห์ไม่ควรต่ำกว่า 32 Pixels

2.4.2.3 AlexNet

มีลักษณะเฉพาะคือมี Convolution Kernels ในชั้นแรกซึ่งมีขนาดใหญ่กว่าใน Network อื่น คือ มีโครงข่ายประสาทเทียมที่มีความลึก 8 Layers ประกอบด้วย 5 Convolutional Layers and 3 Fully-Connected Layers.

2.4.3 ตัวชี้วัดประสิทธิภาพของ Model

1) Accuracy ค่าความแม่นยำ คำนวณได้จากสูตร หรือ ค่าที่โมเดลทายถูกทั้งหมด/ค่าทั้งหมด หากค่าได้จากสูตร

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2) Precision หรือ Positive Predictive Value คือค่าความเที่ยงตรง หรือ ค่าที่โมเดลทายเป็นคลาสที่กำลังพิจารณาถูก/ค่าที่โมเดลทำนายว่าเป็นคลาสที่กำลังพิจารณาทั้งถูกและผิด หากค่าได้จากสูตร

$$Precision = \frac{TP}{TP + FP}$$

3) Sensitivity หรือ Recall คือ ความไว หรือ ค่าที่โมเดลทายเป็นคลาสที่กำลังพิจารณาถูก/ค่าเหตุการณ์จริงเป็นคลาสที่กำลังพิจารณาทั้งถูกและผิด หากค่าได้จากสูตร

$$Recall \text{ or } Sensitivity = \frac{TP}{TP + FN}$$

4) F1-Score คือ ค่าที่ได้จากการเอาค่า Precision และ Recall มาคำนวณรวมกัน (F1-Score สร้างขึ้นมาเพื่อเป็น Single Metric ที่วัดความสามารถของโมเดล หาค่าได้จากสูตร [20])

$$F1 = \frac{2}{P^{-1} + R^{-1}} = 2 * \left[\frac{P * R}{(P + R)} \right] = \frac{2 * TP}{2 * TP + FP + FN}$$

5) Top1-Error คือ อัตราส่วนของภาพที่ทำนายผิด Class

6.) Confusion Matrix คือ เป็นเครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย จากการวิเคราะห์ด้วย Deep Learning ดังภาพที่ 8

		Ground Truth	
		Positive	Negative
Predict	Positive	TP	FP
	Negative	FN	TN

ภาพที่ 8 Confusion Matrix

True Positives (TP) คือ จำนวนของตัวอย่างที่โมเดลทำนายถูกต้องว่าเป็น Positive

True Negatives (TN) คือ จำนวนของตัวอย่างที่โมเดลทำนายถูกต้องว่าเป็น Negative

False Positives (FP) คือ จำนวนของตัวอย่างที่โมเดลทำนายผิดว่าเป็น Positive

False Negatives (FN) คือ จำนวนของตัวอย่างที่โมเดลทำนายผิดว่าเป็น Negative

2.5 Program

2.5.1 Halcon via the MVTec Software

เป็นโปรแกรมสำหรับทำ Machine vision ภาพที่ 9 ที่สามารถใช้ได้ทั้งใน Linux และ Window ใช้ได้กับภาษาทางโปรแกรมได้หลายภาษาไม่ว่าจะเป็น Python, C, C++, หรือ .NET ซึ่งเน้นในเรื่องของการพัฒนาทางด้าน Image processing โดยสามารถนำมาใช้เพื่อแก้ปัญหาทางด้าน


การจัดการตำแหน่ง และการสอบเทียบเครื่องมือ การระบุตัวตน การวัดและการเปรียบเทียบวัตถุ และตำแหน่ง รวมถึงการประมวลผลภาพแบบ 3D Vision และการเรียนรู้เชิงลึก Deep Learning

2.5.2 MVtec Deep Learning Tool

เป็นโปรแกรม ที่ใช้ Deep Learning ในการวิเคราะห์ตรวจหาวัตถุ เพื่อทำการตรวจจับวัตถุ การจัดประเภท การ Segmentation ดังภาพที่ 10

HALCON
a product of MVtec

ภาพที่ 9 โปรแกรม Halcon



ภาพที่ 10 โปรแกรม Deep Learning Tool MVtec

2.6 งานวิจัยที่เกี่ยวข้อง

Ahmed Iqbal และคณะ ได้ทำการพัฒนาเทคโนโลยีคอมพิวเตอร์ Computer-Aided Diagnosis (CAD) ให้เข้ามามีบทบาทในการช่วยวิเคราะห์ตรวจหาเชื้อวัณโรค โดยทำการศึกษา 2 ชุดข้อมูล ข้อมูลชุดแรกใช้ภาพเอกซเรย์ทรวงอก มาทำการ Segmentation ด้วย TB-Unet โดยโครงสร้าง TB-Unet จะประกอบด้วย Dilated Fusion Block (DB) สำหรับกำหนดลักษณะ ปรับข้อมูลรับสัญญาณ และ Attention (AB) สำหรับการเน้นส่วนสำคัญ ลบพื้นหลังที่ไม่ต้องการ โดยผลลัพธ์ค่า Precision ค่า Recall ค่า F1-score และค่า Accuracy มีค่าเท่ากับ 95.74% 95.12% 89.88% และ 97.7% ตามลำดับ ส่วนข้อมูลชุดที่สอง จะใช้การวิเคราะห์ด้วย CNN-based networks โดยที่ใช้ Dataset 3 อย่าง คือ Chest X-ray (CXR), Segmented Images และภาพต้นฉบับ ใช้ Pre-Trained Model คือ DenseNet-169 เพื่อคัดแยกคุณสมบัติและหลีกเลี่ยงการเกิด

ปัญหา Overfitting เนื่องจากชุดข้อมูลมีขนาดเล็ก โดยทดสอบโรคอื่นๆร่วมด้วย 3 โรค ได้แก่ โรคปอดบวม COVID-19 และวัณโรค โดยผลลัพธ์ค่า Precision ค่า Recall ค่า F1-Score และค่า Accuracy มีค่าเท่ากับ 95.67% 95.10% 95.38% และ 95.10% ตามลำดับ [22]

Muhammad Tahir Khan ได้ทำการศึกษาการทำนายผลเชื้อวัณโรคว่าพบเชื้อ หรือไม่พบเชื้อ ด้วย Artificial Neural Networks โดยเก็บรวบรวมข้อมูลผู้ที่เข้าข่ายติดเชื้อวัณโรค จากข้อมูลผู้ป่วยจำนวน 12,636 ราย ระหว่างปี 2559 ถึง ปี 2560 โดยเก็บข้อมูลด้าน เพศ อายุ ประวัติการติดเชื้อ HIV ประวัติการติดเชื้อวัณโรคก่อนหน้า สัญญาณ และอาการของโรค อัตราส่วนของการ Training และ ชุดข้อมูลที่จะทดสอบของผู้ที่เข้าข่ายว่าติดเชื้อ คือ 70 และ 30 ตามลำดับ ซึ่งผลโดยรวมจากการวิเคราะห์ด้วย Artificial Neural Networks ทำนายเชื้อวัณโรค มีความแม่นยำมากกว่า 94% [13]

Lingga Aji Andika นำวิธีการวิเคราะห์แบบ Convolutional Neural Network มาจำแนกประเภทของโรควัณโรค จำแนก PTB โดยใช้ภาพถ่ายรังสีทรวงอก จาก National Library of Medicine ประเทศสหรัฐอเมริกา ร่วมกับ โรงพยาบาล Shenzhen No.3 People's Hospital ประเทศจีน ใช้ภาพทั้งหมด 663 ภาพ แบ่งเป็น 2 กลุ่ม คือ ภาพปกติ และ ภาพ TB การศึกษานี้ ใช้ Adaptive Momentum เพื่อเพิ่มประสิทธิภาพปรับปรุงความแม่นยำของแบบจำลองที่สร้างขึ้น ผลการจำแนกประเภทของแบบจำลองที่สร้างขึ้น สำหรับการ Training มีค่าเท่ากับ 99.19% การ Validation 75 Epochs อยู่ที่ 80.60% และ Accuracy ของชุดทดสอบ มีค่าเท่ากับ 84% [20]

Alfonso Hernández ได้ทำการศึกษาการจำแนกภาพเอกซเรย์อัตโนมัติของผู้ป่วยที่อาจเป็นวัณโรค ด้วย Machine Learning โดยใช้ Pre-Trained Model ของ Convolutional Neural Networks ซึ่งการศึกษานี้มี 3 ขั้นตอนหลัก โดยขั้นแรกจะใช้ Image Processing ปรับภาพใน Training Set ให้เป็น การสะท้อนในแนวนอน (Horizontally Mirroring) ซึ่งจะเป็นการปรับปรุงลักษณะทั่วไปของแบบจำลอง โดยสามารถเข้าถึงข้อมูลที่มีลักษณะใกล้เคียงของภาพทรวงอกทั้งสองข้าง จากนั้นจะใช้เทคนิค Histogram Equalization และ Contrast Limited Adaptive Histogram Equalization (CLAHE) กับทุกภาพ เพื่อช่วยให้เห็นลักษณะของปอดได้ดีขึ้น ซึ่งวิธี Histogram Equalization จะทำให้มองเห็นซีโครงได้น้อยลง และวิธี Contrast Limited Adaptive Histogram Equalization จะช่วยเพิ่ม ความแตกต่าง (Contrast) ระหว่างซีโครงกับพื้นหลัง แล้วทำการปรับขนาดภาพให้มีขนาด 224x224 จากนั้นเพิ่มสัญญาณรบกวน Gaussian แบบสุ่มกับภาพ ซึ่งจะช่วยให้โมเดลสามารถจำแนกภาพที่มีสัญญาณรบกวนได้ดีขึ้น เนื่องจากภาพทางการแพทย์อาจเกิดขึ้นได้จากเครื่องเอกซเรย์ และทำการปรับขนาดพิกเซล 1/255 ให้เป็นมาตรฐาน ไม่ให้ไฟล์ใหญ่เกินไป และทำ

การครอบตัด ที่อยู่ในช่วงการขยาย 99 พิกเซล ขั้นตอนที่สองจะใช้ CNN ในการเลือก ผสมกับเทคนิค Transfer Learning โดยใช้ Architectures ResNet50, InceptionV3 และ VGG19 จาก Keras Library และพารามิเตอร์ที่ต่างกัน สำหรับขั้นตอนสุดท้ายในการทำนาย จาก CNN 3 Models จะใช้สองวิธีในการทำนาย คือ Voting by Majority (VM) ซึ่งภาพแต่ละภาพจะจัดอยู่ในกลุ่มการทำนายแบบ Stand-Alone Model ตั้งแต่ 2 Models ขึ้นไป และ Sum Of Probabilities (SP) จะแสดงค่าความน่าจะเป็นของตัวอย่างแต่ละกลุ่ม ซึ่งการคัดแยกรูปภาพ จะทำได้โดยการนำความน่าจะเป็นของแต่ละกลุ่มจะนำมาเปรียบเทียบกับ Stand-Alone Model ซึ่งแต่ละภาพจะถูกจัดเข้าไปยังกลุ่มที่มีค่าความน่าจะเป็นสูงกว่า โดยกำหนดชุดตัวอย่าง 800 ชุด พร้อมภาพเอกซเรย์ทรวงอก และสร้างชุดข้อมูลที่จะทำการวิเคราะห์ให้มากขึ้น โดยเพิ่มสัญญาณรบกวน Gaussian แบบสุ่ม เนื่องจากในทางการแพทย์อาจเกิดสัญญาณรบกวนจากเครื่องเอกซเรย์ได้ โดยสร้างชุดข้อมูล สองชุด ชุดแรกเป็นภาพเอกซเรย์จากทางด้านหน้าของทรวงอก จำนวน 138 ภาพ แบ่งเป็นภาพปกติ 80 ภาพ และภาพที่มีเชื้อวัณโรค 58 ภาพ ส่วนชุดที่สองเป็นภาพเอกซเรย์ทรวงอกด้านหน้า โดยแบ่งเป็นภาพปกติ จำนวน 326 ภาพ และภาพที่มีเชื้อวัณโรค 336 ภาพ ทำการ Training Model CNN 3 รุ่น (ResNet50, VGG19 และ InceptionV3) โดยความแม่นยำอยู่ที่ 85% [23]

Omar Faruk ได้เสนอแนวทางใหม่ที่มีประสิทธิภาพในการตรวจหาเชื้อวัณโรคโดยใช้ Transfer Learning โดยมีการใช้ชุดข้อมูลวัณโรค ที่ถูกจัดโดย Kaggle สำหรับศึกษา แบบจำลอง Deep Learning Convolution Neural Network (CNN) ถูกสร้างเพื่อใช้สำหรับตรวจหาเชื้อวัณโรค จาก ภาพเอกซเรย์ปอด ใช้ CNNs ที่แตกต่างกัน 4 Pre-Trained model คือ Xception, InceptionV3, InceptionResNetV2, and MobileNetV2 นำไปทำการ Training Validation และ Evaluated เพื่อหา เชื้อวัณโรค และ ไม่พบเชื้อวัณโรค มีการใช้เทคนิค Image Processing เพื่อปรับปรุงความแม่นยำในการวิเคราะห์ อีกทั้งใช้โปรแกรม Python สำหรับวิเคราะห์ข้อมูล และเตรียมชุดข้อมูลโดยใช้ Anaconda Navigation และ Jupyter Notebook อีกทั้งใช้ Google Colab สำหรับจัดการชุดข้อมูลขนาดใหญ่ และ Training Model โดยชุดข้อมูลประกอบด้วย 3,500 ภาพ ที่มีเชื้อวัณโรค และ 3,500 ภาพปกติ โดยเมื่อทำการวิเคราะห์แล้ว โมเดล InceptionResNetV2 ได้รับความแม่นยำสูงสุด F1-score อยู่ที่ 99% ค่า Accuracy ของโมเดลภาพปกติ อยู่ที่ 99% recall 98% และ F1-score 99% ส่วน ความแม่นยำของโมเดลภาพที่มีเชื้อวัณโรค คือ 98% ค่า Recall อยู่ที่ 99% และ F1-score อยู่ที่ 99% ซึ่งวิธีการนี้เป็นประโยชน์สำหรับการตรวจหาเชื้อวัณโรคได้อย่างรวดเร็ว [6]

Khairul Munadi ใช้เทคนิค Deep Learning ในการทำวิจัย เพื่อทำการวินิจฉัยโรคผิวหนังโรค อีทีเอ็มดี ผ่าน Pre-Trained โมเดล ResNet และ EfficientNet เพิ่มคุณภาพของภาพเอกซเรย์ทรวงอกด้วยการทำ Image Processing โดยใช้อัลกอริธึม Image Enhancement ปรับปรุงภาพ 3 แบบ คือ Unsharp Masking High-Frequency Emphasis Filter และ Contrast Limited Adaptive Histogram Equalization รวมทั้งใช้ Gaussian Blur กับภาพต้นฉบับ แล้วทำการลบภาพที่เบลอออกจากภาพต้นฉบับเพื่อให้ได้ขอบภาพที่เบลอ โดยการใช้อัลกอริธึม Unsharp Masking แล้วนำมา ประเมินประสิทธิภาพของแบบจำลองโดยใช้ Classification, Accuracy และ AUC Score ใช้ชุด ข้อมูลจาก Shenzhen Hospital ประกอบด้วย ภาพเอกซเรย์ทรวงอกด้านหน้า 662 ภาพ ซึ่งเป็น ภาพที่มีเชื้อวัณโรค 336 ภาพ และภาพที่ไม่มีเชื้อ อีก 326 ภาพ ซึ่งภาพทั้งหมดจะมี Resolution เท่ากันหมด คือ 3000×3000 Pixels ซึ่ง อัลกอริธึม HEF Image Enhancement ได้คะแนนที่ดีที่สุด ในแง่ของการปรับปรุง Aturalness enhancement ขณะที่อัลกอริธึม CLAHE เป็น Unnatural Enhancement และ Accuracy ต่ำ จากการวิเคราะห์ด้วย Transfer Learning และ Pre-Trained Model EfficientNet-84 ที่ถูกวิเคราะห์มีความเสถียรมากขึ้นเมื่อปรับปรุงภาพด้วยวิธีการ HEF และ UM ซึ่งโมเดลนี้ มีค่า Accuracy เท่ากับ 89.92% และ AUC Score เท่ากับ 94.8% ส่วน ResNet Model มีประสิทธิภาพดีกว่า Model อื่นๆ ในชุดข้อมูลของเซินเจิ้น แต่โมเดล EfficientNet-B4 ที่ทำ การวิเคราะห์ทำงานได้ดีกว่าในการทดลองนี้ [24]

Hsiao-Chuan Huang ทำการประเมินประสิทธิภาพของระบบอีทีเอ็มดี μ -Scan 2.0 สำหรับตรวจหา Acid-Fast Bacilli TB เปรียบเทียบกับวิธีการตรวจหาเชื้อแบบ Manual Smear Microscopy โดยเก็บตัวอย่างจาก 43 โรงพยาบาล และคลินิกทางภาคเหนือของประเทศไทยได้ทุกวัน ใน เดือน มีนาคม ถึงเดือนมิถุนายน ปี 2020 โดยทำการตรวจด้วย Smear Microscopy โดยตัวอย่างจะ ถูกย้อมสีด้วยวิธี AFB ของ Ziehl-Neelsen (ZN) และเพาะเชื้อ Mycobacteria Growth indicator Tube (MGIT) กับอาหารเลี้ยงเชื้อ Lowenstein-Jensen (LJ) ซึ่งจากผลการวิจัย จะเห็นว่า ประสิทธิภาพของระบบอีทีเอ็มดี μ -Scan 2.0 เปรียบเทียบกับ Manual Smear Microscopy ความ แม่นยำโดยรวมมีค่าเท่ากับ 95.7% Prevalence 8.2% และพบว่าระบบอีทีเอ็มดีนั้นมีความไว มากกว่าช่างเทคนิค ในการตรวจหาเชื้อ M. Tuberculosis Complex ส่งผลให้ประสิทธิภาพในการ ตรวจหาเชื้อในห้องปฏิบัติการรวดเร็วขึ้น [25]

Liron Pantanowitz, MD ทำการศึกษาและพัฒนาตรวจสอบความถูกต้องของอัลกอริธึม Deep Learning เพื่อคัดกรอง จากสไลด์ Acid-Fast Stain (AFS) บนเนื้อเยื่อที่มี Mycobacteria

โดยมีชุดข้อมูล ภาพสไลด์ Whole-slide images (WSI) ของเนื้อเยื่อ AFS ทั้งหมด 441 ภาพ สำหรับนำมาวิเคราะห์ด้วย Deep Learning และ อีก นำ 138 สไลด์นำมาเปรียบเทียบกับ Manual Light Microscopy และทำการประเมิน WSI ซึ่งประสิทธิภาพของอัลกอริทึมบนพื้นที่ได้กราฟ คือ 0.960 การใช้ AI เข้ามาช่วยในการระบุ AFBs มากกว่าการใช้เครื่องมือ Manual Microscopy มีค่านัยสำคัญ $P < 0.001$ ค่า Sensitivity ค่า Negative predictive value และค่า Accuracy มีความแม่นยำสูงสุดเมื่อทำการวิเคราะห์ด้วย AI [14]

Jeannette Chang เสนอระบบการวินิจฉัยวัณโรคอัตโนมัติโดยใช้ภาพเรืองแสงจากกล้องจุลทรรศน์มือถือ โดยผู้เขียนใช้ Computer Vision ในการพัฒนาระบบ ออกแบบเพื่อการปรับปรุงประสิทธิภาพ ของการวินิจฉัยเชื้อวัณโรค จากเดิมที่ตรวจหาเชื้อจากเสมหะ และจากวิธีการเพาะเชื้อ และ วิธี Polymerase Chain Reaction (PCR) ใช้ชุดข้อมูลสำหรับทดลอง จากภาพ Cell Scope ทั้งหมด 594 ภาพ โดยภาพที่ผลเป็นบวกหรือพบเชื้อจำนวน 296 ภาพ ส่วนผลที่เป็นลบ หรือไม่พบเชื้อ จำนวน 298 ภาพ ได้ผลรวม Accuracy เท่ากับ 80.2% ซึ่งประสิทธิภาพของระบบนั้น เทียบเท่ากับการอ่านผลของมนุษย์ อีกทั้งผู้เขียนได้ทำการเปรียบเทียบประสิทธิภาพของระบบ กับการวินิจฉัยโรควัณโรคแบบอื่นๆ รวมถึงการเพาะเชื้อและกล้องจุลทรรศน์ ฟลูออเรสเซนซ์ LED พบว่า ประสิทธิภาพของระบบอัตโนมัติที่คล้ายคลึงกับการเพาะเชื้อ ได้รับความแม่นยำโดยรวม 80.2% ในชุดข้อมูลของภาพ Cell Scope 594 ภาพ ผู้เขียนยังพบว่าประสิทธิภาพของระบบอัตโนมัติเทียบได้กับเครื่องอ่านของมนุษย์และวิธีการวินิจฉัยวัณโรคอื่นๆ [10]

ตารางที่ 4 ตารางสรุปงานวิจัยที่เกี่ยวข้อง

No.	ชื่องานวิจัย	ผู้เขียน	Dataset	วิธีการทดลอง	สรุปผล	Ref.
1	Tuberculosis chest X-ray detection using CNN-based hybrid segmentation and classification approach	Ahmed Iqbal	ตัวอย่างจากโรงพยาบาลเดลีเงิน 32 ภาพ ภาพมีเชื้อ TB 336 ภาพ และภาพปกติ 32 ภาพ ภาพจาก National Library Medicine สหรัฐ ภาพมีเชื้อ 58 ภาพ และภาพปกติ 80 ภาพ	Computer-aided diagnosis (CAD)-TB-UNet ,Chest X-ray(CXR) ,Segmentation	ทดสอบกับโรคต่างๆ 3 ชนิด ได้แก่ โควิด-19 โรคปอดบวม และวัณโรค และได้รับความแม่นยำถึง 95%	[22]
2	Artificial Neural Networks for Prediction of Tuberculosis Disease	Muhammad Tahir Khan	ข้อมูลสำหรับการ training จากบันทึกผู้ป่วยวัณโรค จำนวน 12,636 ราย รวมรวมระหว่างปี 2016-2017 แบ่งชุดข้อมูลสำหรับ Training และ Test set 70% และ 30% ตามลำดับ	Artificial neural networks	ทำนายค่าบวกและลบของเชื้อวัณโรค ได้ค่า Accuracy โดยรวมมากกว่า 94% Test และ Validation มีค่า Accuracy มากกว่า 93%	[13]
3	Convolutional neural network modeling for classification of pulmonary tuberculosis disease	Lingga Aji Andika	ภาพทั้งหมด 663 ภาพ แบ่งเป็น 2 กลุ่ม คือ ภาพปกติ และภาพ PTB	Convolutional neural network , Chest X-ray	Accuracy โดยรวม ของการ Training การ Validation และ Test data คือ 99.16% 80.60% และ 84% ตามลำดับ	[20]

No.	ชื่องานวิจัย	ผู้เขียน	Dataset	วิธีการทดลอง	สรุปผล	Ref.
4	An Ensemble Algorithm Based on Deep Learning for Tuberculosis Classification	Alfonso Hernández	ชุดแรกเป็นภาพเอกซเรย์จากทางด้านหน้าของส่วนอก จำนวน 138 ภาพ แบ่งเป็นภาพปกติ 80 ภาพ และภาพที่มีเชื้อวัณโรค 58 ภาพ 4,020x4,892 or 4,892x4,020 พิกเซล ส่วนชุดที่สองเป็นภาพเอกซเรย์ส่วนอกด้านหน้า โดยแบ่งเป็นภาพปกติจำนวน 326 ภาพ และภาพที่มีเชื้อวัณโรค 336 ภาพ 3,000x3,000 พิกเซล	CNN (ResNet50, VGG19 และ InceptionV3) และ Image pre-processing	โมเดลที่ดีที่สุดพบว่าเป็นการรวมระหว่างโมเดล CNN 3 โมเดล (ResNet50, VGG19 และ InceptionV3) โดยมี Accuracy โดยรวม เท่ากับ 85%	[23]
5	A Novel and Robust Approach to Detect Tuberculosis Using Transfer Learning	Omar Faruk	3,500 ภาพ ที่มีเชื้อวัณโรค และ 3,500 ภาพปกติ	Convolution neural network (Xception, InceptionV3, InceptionResNetV2, and MobileNetV2)	ใช้โมเดล InceptionResNetV2 สำหรับพัฒนาวิธีการตรวจหาวัณโรคแบบอัตโนมัติ มีค่า Accuracy ในภาValidation เท่ากับ 99.36%	[6]
6	Image Enhancement for Tuberculosis Detection Using Deep Learning	KHAIRUL MUNADI	ภาพเอกซเรย์ทรวงอกด้านหน้า 662 ภาพ ซึ่งเป็นภาพที่มีเชื้อวัณโรค 336 ภาพ และภาพที่ไม่มีเชื้ออีก 326 ภาพ	โมเดล ResNet และ EfficientNet	accuracy เท่ากับ 89.92% และ AUC score เท่ากับ 94.8%	[24]

No.	ชื่องานวิจัย	ผู้เขียน	Dataset	วิธีการทดลอง	สรุปผล	Ref. กรม
7	Novel TB smear microscopy automation system in detecting acid-fast bacilli for tuberculosis – A multi-center double blind study	Hsiao-Chuan Huang	เก็บตัวอย่างจาก 43 โรงพยาบาล และคลินิคทางภาคเหนือของประเทศไต้หวัน ในเดือน มีนาคม ถึงเดือนมิถุนายน ปี 2020	Smear microscopy, Acid-fast stain	ความแม่นยำโดยรวมมีค่าเท่ากับ 95.7% prevalence 8.2%	[25]
8	Artificial Intelligence-Based Screening for Mycobacteria in Whole-Slide Images of Tissue Samples	Liron Pantanowitz, MD	ภาพสไลด์ whole-slide images (WSI) ของเนื้อเยื่อ AFS ทั้งหมด 441 ภาพ สำหรับนำมาวิเคราะห์ด้วย deep learning และ อีก 138 สไลด์นำมาเปรียบเทียบกับ manual light microscopy และทำการประเมิน WSI	AI, Manual microscopy	ประสิทธิภาพของอัลกอริทึม แสดงพื้นที่ที่ได้นั้นได้ 0.960 ที่ระดับแพพตรูปภาพ การวิเคราะห์ที่ใช้ AI ช่วยระบุ AFB มากกว่าการตรวจด้วยกล้องจุลทรรศน์ด้วยมือหรือ การตรวจ WSI	[14]
9	Automated Tuberculosis Diagnosis Using Fluorescence Images from a Mobile Microscope	Jeannette Chang	ภาพ Cell Scope ทั้งหมด 594 ภาพ โดยภาพที่ผลเป็นบวกหรือพบเชื้อจำนวน 296 ภาพ ส่วนผลที่เป็นลบ หรือไม่พบเชื้อ จำนวน 298 ภาพ	Computer vision, Polymerase chain reaction	Accuracy เท่ากับ 80.2%	[10]

บทที่ 3

วิธีการดำเนินงาน

3.1 การเตรียมชุดข้อมูล

ภาพสแกนการย้อมสีทึนกรด AFB (Acid-Fast Bacilli) ด้วยวิธีการย้อมสี Ziehl-Neelsen Stain (ZN) จากกลุ่มตัวอย่างทั้งหมด 43 เคส แบ่งเป็น พบเชื้อวัณโรค (Positive) จำนวน 7 เคส และไม่พบเชื้อจำนวน 36 เคส เก็บตัวอย่างชุดข้อมูลในปี ค.ศ. 2016 – 2018 จาก ฝ่ายพยาธิวิทยา โรงพยาบาลจุฬาลงกรณ์ สภากาชาดไทย โดยภาพการย้อมสีทึนกรด AFB กำลังขยาย x40 ถูกสแกนโดยใช้เครื่องสแกน Aperio CS2 และจัดเก็บในรูปแบบ SVS File แต่เนื่องจาก SVS File ไม่สามารถเปิดด้วยโปรแกรมอ่านภาพทั่วไป และไฟล์ภาพมีขนาดใหญ่ มีขนาดเฉลี่ยที่ 48 GB ต่อภาพ จึงต้องทำการแปลงไฟล์ภาพให้อยู่ในรูปแบบ TIFF และ ครอบตัดให้เหลือขนาดที่เล็กลงมีขนาดเฉลี่ยที่ 4 GB ต่อภาพ โดยใช้โปรแกรม Panoramic Viewer ในการแปลงไฟล์และครอบตัดภาพ หลังจากนั้นทำการครอบตัดภาพที่ได้อีกครั้ง เพื่อให้เห็นรายละเอียดภายในภาพมากขึ้น และทำให้มีขนาด 1,500x1,500 pixel เท่ากันทุกภาพ สำหรับนำไปวิเคราะห์ Deep Learning ด้วยวิธี Object Detection และสำหรับนำไปทำ Image Processing เพื่อเตรียมข้อมูลการวิเคราะห์ Deep Learning ด้วยวิธี Modified Classification โดยจำนวนชุดข้อมูลทั้งหมดแสดงดังตารางที่ 5

No.	Characteristic	Positive	Negative	Total
1	ZN-Slide (Average 48 GB/Slide)	7 Slides	36 Slides	43 Slides
2	ZN-Slide (Average 4 GB/Image)	109 Images	525 Images	634 Images
3	Image (1500x1500)/Image	71,666 Images	314,079 Images	385,745 Images


3.2 การเตรียมชุดข้อมูลด้วย Image Processing สำหรับการวิเคราะห์ Deep Learning ด้วยวิธี Modified Classification

การเตรียมชุดข้อมูลด้วย Image Processing จะทำการหาเชื้อวัณโรคในภาพการย้อมสีทึนกรด จากกลุ่มตัวอย่างที่พบเชื้อ 7 เคส เพื่อทำการหาช่วงค่าสี HSV ที่มีความใกล้เคียงกับสีของเชื้อมากที่สุด ด้วย Color Thresholder ในโปรแกรม MATLAB โดยสุ่มภาพ จำนวน 12 ภาพ ที่ได้รับการครอบตัด ขนาด 1,500x1,500 พิกเซล มาทำการหาช่วงของค่าสี HSV จาก Color Thresholder ใน MATLAB ดังภาพที่ 11 เมื่อได้ค่า Hue Saturation และ Intensity เฉลี่ยที่ใกล้เคียงสีเชื้อวัณโรคมากที่สุด ดังตารางที่ 6 แล้วนำค่าช่วงสีไปใส่ในโปรแกรม MVTec Halcon ทำการสุ่มภาพ ขนาด

1500x1500 pixels จำนวน 300 ภาพ Positive และ Negative จากตารางที่ 5 นำเข้าโปรแกรม MVTec Halcon โปรแกรมจะทำการหาช่วงสีที่ต้องการ แล้วกำหนดจุดกึ่งกลางของสี และสร้างขอบออกจากจุดกึ่งกลาง รัศมี 25.5 pixels ตีกรอบรอบตัวเชื้อ ให้มีขนาดความกว้าง 51 pixels ความยาว 51 pixels แล้วครอบตัดเฉพาะส่วนที่พบเชื้อ (Patch) ดังภาพที่ 12 โดยจำนวน Patch ที่จะนำไป Classification แสดงดังตารางที่ 7 และทำการแบ่งกลุ่มภาพ ออกเป็น 3 กลุ่ม คือ กลุ่ม Positive กลุ่ม Positive Low Confidence และกลุ่ม Negative เพื่อนำไปวิเคราะห์ด้วย Deep Learning โดยใช้วิธี Modified Classification

ตารางที่ 6 ช่วงสี HSV จะได้ค่าเฉลี่ยจากช่วงสีดังตารางต่อไปนี้


Color	Hue		Saturation		Value	
	Low	High	Low	High	Low	High
Average	145.826	187.935	42.5	194.497	185.402	243.032



ภาพที่ 11 การหาช่วงค่าสี HSV ด้วย Color Thresholder

ตารางที่ 7 แสดงจำนวนชุดข้อมูล ก่อนและหลังการทำ Image Processing & Label

Image Processing Comparison	Type Of Image	Amount
Sample (Random)	Image 1500x1500 Pixels	300 Images
After Processing	Classification Patch	15,000 Patch



ภาพที่ 12 แผนภาพแสดงการเตรียมชุดข้อมูลภาพ

3.3 การวิเคราะห์ด้วย MVtec Deep Learning Tool ด้วยวิธี Modify Classification

การ วิเคราะห์ด้วย Deep Learning ด้วยวิธี Modified Classification จะทำการ Training ด้วย Msi thin GF63 12ve-046 TH 12 th Gen Intel(R) Core(TM) i7-12650H 2.30GHz (cpu:0)

โดยเปรียบเทียบ Pretrained Model ทั้งหมด 3 Models คือ Enhanced ResNet50 และ AlexNet มีวิธีการวิเคราะห์ ดังนี้

1.) จัดกลุ่ม Patch ออกเป็น 3 กลุ่ม โดยแบ่งเป็น กลุ่ม Positive กลุ่ม Positive Low Confidence และกลุ่ม Negative กลุ่มละ 5,000 ภาพ นำทั้งสามกลุ่มเข้าโปรแกรม Deep Learning Tool ทำการปรับแต่งภาพ ใน Mode Image และดูภาพรวมของภาพที่จะนำมา Training ใน mode review

2.) ทำการแบ่งสัดส่วนชุดข้อมูลในการ training เป็น 3 ชุด คือ Training Image 10,500 ภาพ, Validation Image 2,250 ภาพ และ Test Image 2,250 ภาพ ของจำนวนข้อมูลทั้งหมด หรือ อัตราส่วน 70:15:15

3.) เลือก Pretrained Model โดยจะทำการวิเคราะห์ทั้งหมด 3 Models คือ Enhanced, ResNet50 และ AlexNet ซึ่งทั้ง 3 Models จะตั้งค่า Parameter ต่างๆ เหมือนกัน ดังตารางที่ 8 ตารางที่ 8 ค่า Parameter สำหรับวิเคราะห์ข้อมูลด้วย Deep Learning วิธี Modified Classification

Parameter	Value
image width x Height	51 x 51
Num Channels	3
Number of Epochs	100
Number of Iterations	32900
Batch Size	32
Learning Rate	0.001
Momentum	0.9
Percentage step	50
Rotate Step	90
mirror	both
Brightness Variance	20
Brightness Variance	20
Rotate Range	9

3.4 การวิเคราะห์ด้วย Deep Learning ด้วยวิธี Object Detection

การวิเคราะห์ด้วย Deep Learning ด้วยวิธี Object Detection จะทำการ Training ด้วย ด้วย Msi thin GF63 12ve-046 TH 12 th Gen Intel(R) Core(TM) i7-12650H 2.30GHz (cpu:0) โดยใช้ Pretrained Model คือ Enhanced

1.) ภาพ ขนาด 1,500x1,500 พิกเซล จำนวน 300 ภาพ ทำการ Label ภาพขึ้นแต่ละตัว จำนวน 10000 จุด ปรับแต่งภาพ ใน Mode Image และดูภาพรวมของภาพที่จะนำมา Training ใน Mode Review

2.) ทำการแบ่งสัดส่วนชุดข้อมูลในการ Training เป็น 3 ชุด คือ Training 7041 จุด, Validation 1,413 จุด และ Test 1,546 จุด หรืออัตราส่วน 70 : 15 : 15 ดังตารางที่ 9

ตารางที่ 9 รายละเอียดการแบ่งชุดข้อมูลสำหรับวิเคราะห์ด้วย Deep Learning

DL Model	Characteristic	Training	Validation	Test	Total
Object Detection	Image	210 (70%)	45(15%)	45(15%)	300
	Patch	7041	1,413	1,546	10000

3.) เลือก Pretrained Model เป็น Enhanced ตั้งค่าสำหรับ Training ดังตารางที่ 10 และปรับค่า Parameter ต่างๆ ดังตารางที่ 11

ตารางที่ 10 การตั้งค่าสำหรับ Training

รายการ	หน่วย	รายการ	หน่วย
Width	1,536	Number of Epochs	100
Hight	1,536	Number of Iterations	21,000
Number of channels	3	Batch Size	1
Min Level	2	Solver Type	adam
Max Level	6	Learning Rate	0.0001
Anchor Num Subscales	3	Weight Prior	0
Anchor Aspect Ratios	0.5, 1, 2	Bbox Heads Weight	1

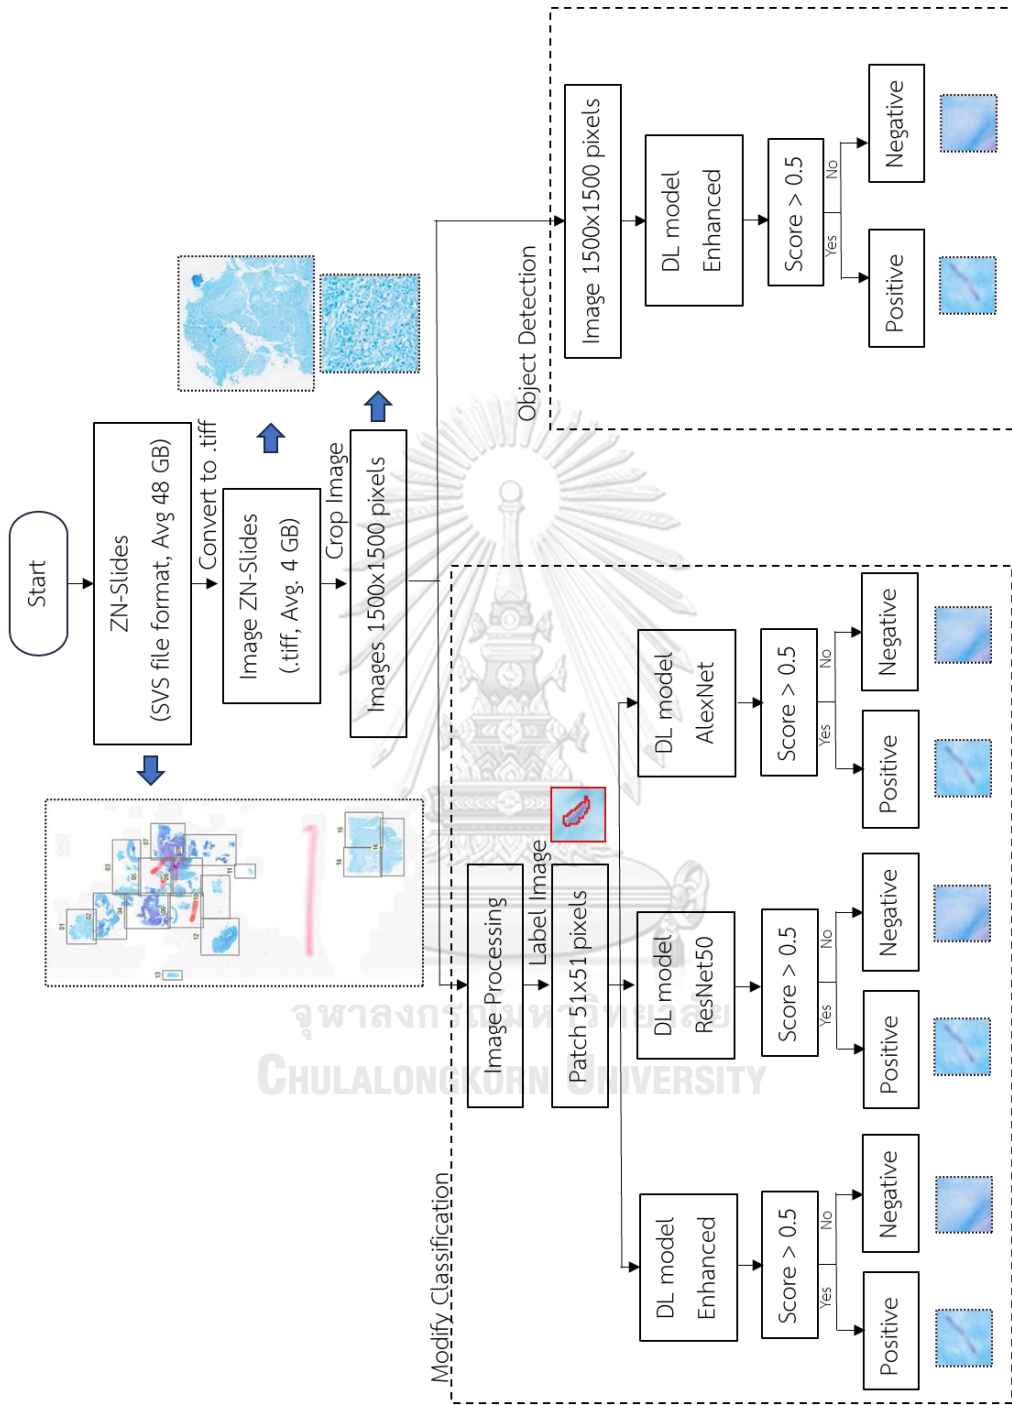
Max Overlap	10%	Class Heads Weight	1
Max Overlap Agnostic	27%	Mask Head Weight	-
Min confidence	0.5	Freeze Backbone Level	2

ตารางที่ 11 การตั้งค่าพารามิเตอร์ต่างๆ

Parameter	Value
Percentage step	50
Rotate Step	90
mirror	both
Brightness Variation	20
Brightness Variation spot	20
Contrast Variation	20
Saturation Variation	20

3.5 การเปรียบเทียบความสามารถในการยืนยันผลโดยใช้ Model ร่วมกับแพทย์เพื่อตรวจหาเชื้อไวรัสโคโรกับการให้แพทย์ตรวจหาเชื้อไวรัสโคโรโดยตรงผ่าน Light Microscopy

วิเคราะห์ Deep Learning วิธี Modified Classification และ วิธี Object Detection แสดงดังภาพที่ 13 เมื่อทำการ Training แล้ว ทำการเลือก Model ที่ดีที่สุดจากการทดลอง ไปทำการตรวจร่วมกับแพทย์ เพื่อเปรียบเทียบผลกับการ ตรวจด้วย Light Microscopy โดยชุดทดลองที่นำมาเปรียบเทียบ ใช้ตัวอย่างชุดข้อมูลจำนวน 43 เคส ที่รายงานว่าเป็น Positive จำนวน 7 เคส และ Negative จำนวน 36 เคส



ภาพที่ 13 แผนภาพแสดงการวิเคราะห์ด้วย Deep Learning


บทที่ 4

ผลการทดลองและการอภิปรายผล


4.1 การวิเคราะห์ Deep Learning วิธี Modify Classification

ผลการทดลองการวิเคราะห์ด้วย Deep Learning แบบ Modified Classification เปรียบเทียบ Pre-Trained Model ทั้ง 3 models คือ Enhanced ResNet50 และ AlexNet จากตัวอย่าง 3 กลุ่ม คือ กลุ่ม Positive กลุ่ม Positive Low Confidence และกลุ่ม Negative

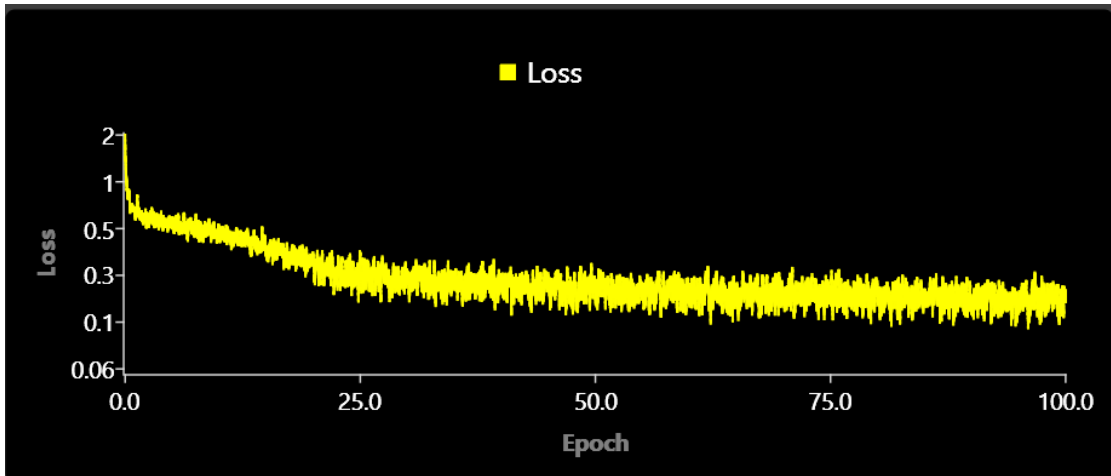
4.1.1 กราฟความสัมพันธ์ระหว่าง Loss กับ จำนวน Epoch และกราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training กับ Top1-Error Validation



ภาพที่ 14 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs ของ Pre-Trained Enhanced




ภาพที่ 15 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs ของ Pre-Trained ResNet50




ภาพที่ 16 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs ของ Pre-Trained AlexNet

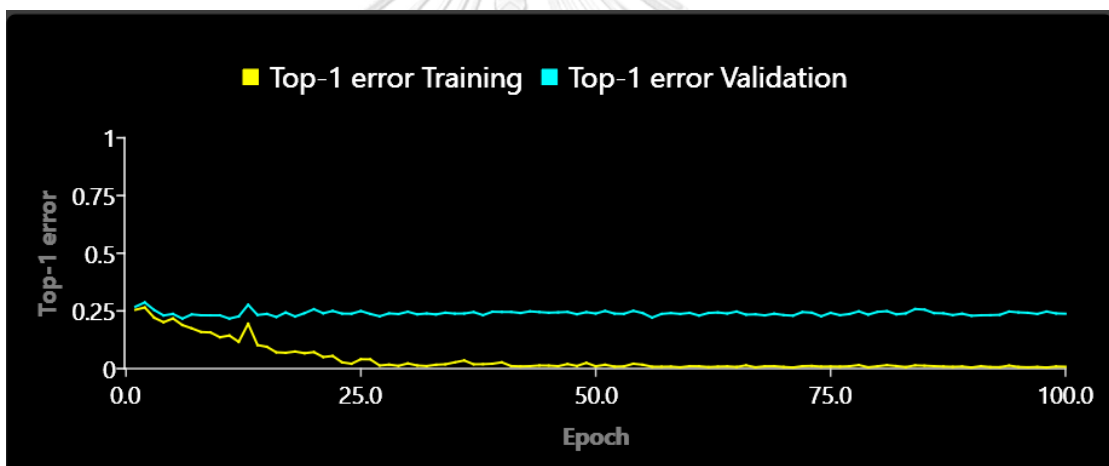
จากกราฟความสัมพันธ์ระหว่าง Loss และ จำนวน Epoch ดังภาพที่ 14, 15 และ 16 พบว่า ค่า Loss Function ของ Models ทั้ง 3 Models มีค่าลดลง โดยเฉพาะ Pre-Trained ResNet50 ลดลงมากที่สุด แสดงให้เห็นว่า Model นี้ มีค่าเบี่ยงเบนระหว่างผลลัพธ์ตามที่ Predict กับ ground truth น้อย โดยมีค่า Loss Function เฉลี่ยเท่ากับ 0.2



ภาพที่ 17 กราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation ของ Pre-Trained Enhanced



ภาพที่ 18 กราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation ของ Pre-Trained ResNet50



ภาพที่ 19 กราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation ของ Pre-Trained AlexNet

จากกราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation ดังภาพที่ 17,18 และ 19 ซึ่ง Models ทั้ง 3 Models เส้นกราฟ Top1-Error Training มีค่าต่ำกว่าเส้นกราฟ Top1-Error Validation ทำให้เกิดการ Overfitting เล็กน้อย แสดงให้เห็นว่า สามารถจำแนกข้อมูลภายในชุดการ Training ได้เป็นอย่างดี แต่เมื่อมีการนำข้อมูลชุดใหม่มาทำนายข้อมูล (Validation Set) ประสิทธิภาพการทำนายจะลดลงเล็กน้อย

4.1.2 Confusion Matrix

การวัดประสิทธิภาพของ Pre-Trained Models โดยใช้ Confusion Matrix 3x3 แสดงรายละเอียดการแบ่งกลุ่ม Positive กลุ่ม Positive Low Confidence และ กลุ่ม Negative เพื่อนำไปคำนวณตัวชี้วัดแสดงดังตารางที่ 12, 13 และ 14

ตารางที่ 12 Confusion Matrix 3x3 ของ Pre-Trained Model Enhanced

Ground Truth

Predict	Enhanced	Positive	Positive Low Confidence	Negative	FP
	Positive	4,086	1,164	27	1,191
Positive Low Confidence	879	3,533	250	1,129	
Negative	35	303	4,723	338	
FN	914	1,467	277	2,658	

ตารางที่ 13 Confusion Matrix 3x3 ของ Pre-Trained Model ResNet50

Ground Truth

Predict	ResNet50	Positive	Positive Low Confidence	Negative	FP
	Positive	4,588	404	27	431
Positive Low Confidence	399	4,459	114	513	
Negative	13	137	4,859	150	
FN	412	541	141	1,094	

ตารางที่ 14 Confusion Matrix 3x3 ของ Pre-Trained Model AlexNet

Ground Truth

Predict	AlexNet	Positive	Positive Low Confidence	Negative	FP
	Positive	4,183	1,027	17	1,044
Positive Low Confidence	728	3,541	148	876	
Negative	89	432	4,835	521	
FN	817	1,459	165	2,441	

4.1.3 สรุปผลการทดลองการวิเคราะห์ Deep Learning วิธี Modified Classification

การวัดประสิทธิภาพของ Pre-Trained Model โดยใช้ Class Overview แสดงรายละเอียดการคำนวณตัวชี้วัดของแต่ละกลุ่ม (กลุ่ม Positive กลุ่ม Positive Low Confidence และ กลุ่ม Negative) ที่ได้จาก Confusion Matrix 3x3 ดังตารางที่ 15, 16 และ 17

ตารางที่ 15 Class Overview ของ Pre-Trained Enhanced

Enhanced	Positive	Positive Low Confidence	Negative	total
TP	4,086	3,533	4,723	12,342
TN	8,809	8,871	9,662	27,342
FP	1,191	1,129	338	2,658
FN	914	1,467	277	2,658
Precision	77.43%	75.78%	93.32%	82.18%
Recall	81.72%	70.66%	94.46%	82.28%
F1-Score	79.52%	73.13%	93.89%	82.18%
Accuracy	82.28%			
Top1-Error	17.72%			

ตารางที่ 16 Class Overview ของ Pre-Trained ResNet50

ResNet50	Positive	Positive Low Confidence	Negative	total
TP	4,588	4,459	4,859	13,906
TN	9,569	9,487	9,850	28,906
FP	431	513	150	1,094
FN	412	541	141	1,094
Precision	91.41%	89.68%	97.01%	92.70%
Recall	91.76%	89.18%	97.18%	92.71%
F1-Score	91.59%	89.43%	97.09%	92.70%
Accuracy	92.71%			
Top1-Error	7.29%			

ตารางที่ 17 Class Overview ของ Pre-Trained AlexNet

AlexNet	Positive	Positive Low Confidence	Negative	total
TP	4,183	3,541	4,835	12,559
TN	8,956	9,124	9,479	27,559
FP	1,044	876	521	2,441
FN	817	1,459	165	2,441
Precision	80.03%	80.17%	90.27%	83.49%
Recall	83.66%	70.82%	96.70%	83.73%
F1-Score	81.80%	75.20%	93.38%	83.46%
Accuracy	83.73%			
Top1-Error	16.27%			

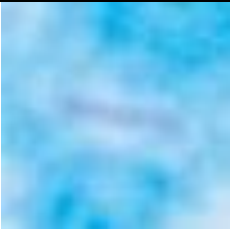


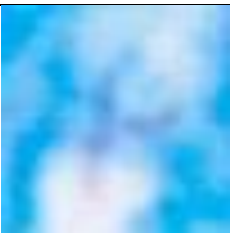
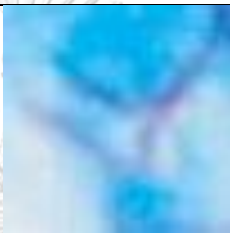




ตารางที่ 18 การเปรียบเทียบ ตัวชี้วัดของ Pre-Trained 3 Models: Enhanced, ResNet50, AlexNet

Pre-Trained Models	Accuracy	Top1-Error	Precision	Recall	F1-Score
Enhanced	82.28%	17.12%	82.18%	82.28%	82.18%
ResNet50	92.71%	7.29%	92.70%	92.71%	92.70%
AlexNet	83.73%	16.27%	83.49%	92.71%	83.73%

จากการทดลอง เมื่อเปรียบเทียบ Training Model ทั้ง 3 Models : Enhanced, ResNet50, AlexNet ดังตารางที่ 18 พบว่า ค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score ของ ResNet50 มีค่าสูงที่สุด มีค่าเท่ากับ 92.71% 92.7% 92.71% และ 92.7% ตามลำดับ ส่วน Model ที่มีค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score น้อยที่สุด คือ Enhanced โดยมีค่าเท่ากับ 82.28% 82.18% 82.28% และ 82.18% ตามลำดับ ส่วน Pre-Trained Model ที่มี

ค่า Top1-Error ที่น้อยที่สุด คือ ResNet50 มีค่าเท่ากับ 7.29% และ Top1-Error ที่มากที่สุด คือ Enhanced มีค่าเท่ากับ 17.1% ตัวอย่างภาพ แสดงดังตารางที่ 19

ตารางที่ 19 ตัวอย่างภาพจากการ Training Models

	Positive	Positive Low Confidence	Negative
Positive			
FP			
	GT : Positive Low Confidence PD : Positive	GT : Positive PD : Positive Low Confidence	GT : Positive PD : Negative
FN			
	GT : Positive PD : Positive Low Confidence	GT : Positive Low Confidence PD : Positive	GT : Negative PD : Positive Low Confidence

4.1.4 จัดกลุ่ม Confusion Matrix 3x3 เป็น Confusion Matrix 2x2

การจัดกลุ่ม Confusion Matrix 3x3 เป็น Confusion Matrix 2x2 โดยการจัดกลุ่มใหม่เพื่อทำการวิเคราะห์ข้อมูล 2 แบบ คือ Suspected Positive Low Confidence และ Suspected Positive High Confidence โดย Suspected Positive Low Confidence เป็นการ Collapse

กลุ่ม Positive Low Confidence และกลุ่ม Positive ให้อยู่ในกลุ่มเดียวกันคือ กลุ่ม Positive เปรียบเทียบกับกลุ่ม Negative และ Suspected Positive High Confidence เปรียบเทียบกับกลุ่ม Positive และกลุ่ม Negative โดย กลุ่ม Negative ได้จากการ Collapse กลุ่ม Positive Low Confidence และ กลุ่ม Negative เข้าด้วยกัน

4.1.4.1 Confusion Matrix 2x2 ของการวิเคราะห์แบบ Suspected Positive Low Confidence

ตารางที่ 20 Confusion Matrix 2x2 ของ Pre-Trained Enhanced

		Ground Truth	
		Positive	Negative
Predict	Enhanced		
	Positive	9,662	277
	Negative	338	4,723

ตารางที่ 21 Confusion Matrix 2x2 ของ Pre-Trained ResNet50

		Ground Truth	
		Positive	Negative
Predict	ResNet50		
	Positive	9,850	141
	Negative	150	4,859

ตารางที่ 22 Confusion Matrix 2x2 ของ Pre-Trained AlexNet

		Ground Truth	
		Positive	Negative
Predict	AlexNet		
	Positive	9,479	165
	Negative	521	4,835

ตารางที่ 23 การเปรียบเทียบ Class Overview และ ตัวชี้วัดของ ของ Pre-Trained 3 Models: Enhanced, ResNet50, AlexNet

Pre-Trained Models	Enhanced	ResNet50	AlexNet
TP	9,662	9,850	9,479
TN	4,723	4,859	4,835
FP	277	141	165
FN	338	150	521
Precision	97.21%	98.59%	98.29%
Recall	96.62%	98.50%	94.79%
F1-Score	96.92%	98.54%	96.51%
Accuracy	95.90%	98.06%	95.43%

จากการทดลอง ตารางที่ 20, 21, 22 และ 23 การวิเคราะห์แบบ Suspected Positive Low Confidence เมื่อเปรียบเทียบ Training Model ทั้ง 3 Models : Enhanced, ResNet50, AlexNet พบว่า ค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score ของ ResNet50 มีค่าสูงที่สุด มีค่าเท่ากับ 98.06% 98.59% 98.50% และ 98.54% ตามลำดับ ส่วน Model ที่มีค่า Accuracy Recall และค่า F1-Score น้อยที่สุด คือ AlexNet มีค่าเท่ากับ 95.43% 94.79% และ 96.51% ตามลำดับ ส่วน Model ที่มีค่า Precision น้อยที่สุด คือ Enhanced มีค่าเท่ากับ 97.21% ตามลำดับ

CHULALONGKORN UNIVERSITY

4.1.4.2 Confusion Matrix 2x2 ของการวิเคราะห์แบบ Suspected Positive High Confidence

ตารางที่ 24 Confusion Matrix 2x2 ของ Pre-Trained Enhanced

		Ground Truth	
		Positive	Negative
Predict	Enhanced		
	Positive	4,086	1,191
	Negative	914	8,809

ตารางที่ 25 Confusion Matrix 2x2 ของ Pre-Trained ResNet50

		Ground Truth	
		Positive	Negative
Predict	ResNet50		
	Positive	4,588	431
Negative		412	9,569

ตารางที่ 26 Confusion Matrix 2x2 ของ Pre-Trained AlexNet

		Ground Truth	
		Positive	Negative
Predict	AlexNet		
	Positive	4,183	1,044
Negative		817	8,956

ตารางที่ 27 การเปรียบเทียบ Class Overview และ ตัวชี้วัดของ ของ Pre-Trained 3 Models: Enhanced, ResNet50, AlexNet


Pre-Trained Models	Enhanced	ResNet50	AlexNet
TP	4,086	4,588	4,183
TN	8,809	9,569	8,956
FP	1,191	431	1,044
FN	914	412	817
Precision	77.43%	91.41%	80.03%
Recall	81.72%	91.76%	83.66%
F1-Score	79.52%	91.59%	81.80%
Accuracy	85.97%	94.38%	87.59%

จากการทดลอง ตารางที่ 24, 25, 26 และ 27 การวิเคราะห์แบบ Suspected Positive High Confidence เมื่อเปรียบเทียบ Training Model ทั้ง 3 Models : Enhanced, ResNet50, AlexNet พบว่า ค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score ของ ResNet50 มีค่าสูงที่สุด มีค่าเท่ากับ 94.38% 91.41% 91.76% และ 91.59% ตามลำดับ ส่วน Model ที่มีค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score น้อยที่สุด คือ Enhanced มีค่าเท่ากับ 85.97% 77.43% 81.72% และ 79.52% ตามลำดับ


4.2 การวิเคราะห์ Deep Learning วิธี Object Detection

ผลการทดลองการวิเคราะห์ด้วย Deep Learning แบบ Object Detection ใช้ Pre-Trained Model คือ Enhanced จากการ Label ภาพ 300 ภาพ จำนวน 10,000 จุด

4.2.1 กราฟความสัมพันธ์ระหว่าง Loss กับ จำนวน Epoch และกราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training กับ Top1-Error Validation



ภาพที่ 20 กราฟแสดงความสัมพันธ์ระหว่าง Loss และ Epochs



ภาพที่ 21 กราฟแสดงความสัมพันธ์ระหว่าง Mean AP Training และ Mean AP Validation

จากกราฟความสัมพันธ์ระหว่าง Loss และ จำนวน Epoch ดังภาพที่ 20 พบว่า ค่า Loss Function ของ Models มีค่าลดลง แสดงให้เห็นว่า Model นี้ มีค่าเบี่ยงเบนระหว่างผลลัพธ์ตามที่ Predict ไว้ กับ ground truth น้อยมาก โดยมีค่า Loss Function เฉลี่ยเท่ากับ 0.06 และกราฟ แสดงความสัมพันธ์ระหว่าง Mean AP Training และ Mean AP Validation ภาพที่ 21 พบว่า กราฟ Mean AP Training มีค่าสูงกว่า กราฟ Mean AP Validation แสดงว่าเกิดการ Overfitting ซึ่งอาจ เกิดจากการที่การ Training ข้อมูลชุดมีความใกล้เคียงกันมาก

4.2.2 Confusion Matrix ของการวิเคราะห์ วิธี Object Detection

การวัดประสิทธิภาพของ Model โดยใช้ Confusion Matrix แสดงรายละเอียด เพื่อนำไป คำนวณตัวชี้วัดต่างๆ ดังตารางที่ 28 โดย

Bg คือ Detectionที่ไม่ซ้อนกับ Ground Truth

Loc คือ Detection ถูกกลุ่ม แต่ ตำแหน่งผิด

Dup คือ Detection สำหรับ Detection Exists

Mul คือ Detection ที่มีผลลัพธ์ผิดหลายประการ (หาตำแหน่งผิด และผิดกลุ่ม)

FP คือ ผลรวมของ Bg, Loc, Dup, Mul

FN คือ จำนวนของ Instances ที่ Network Detect ไม่พบ ว่าอยู่ในกลุ่ม Positive

ตารางที่ 28 Confusion Matrix

Class	Positive	Bg	Loc	Dup	Mul	FP
Positive	3,734	370	405	0	0	775
Unmatched GT	5,868					5,868
FN	6,266	370	405	0	0	6,643

4.2.3 Class Overview (Positive, Positive Low Confidence, Negative)

การวัดประสิทธิภาพของ Model โดยใช้ Class Overview แสดงรายละเอียดการคำนวณ ตัวชี้วัดของแต่ละกลุ่ม (กลุ่ม Positive กลุ่ม Positive Low Confidence และ กลุ่ม Negative) ที่ได้ จาก Confusion Matrix ดังตารางที่ 29 และ 30

ตารางที่ 29 Class Overview

Class	FP / Predicted	Precision%	FN / Label	Recall	Average Precision%
Positive	775 / 4,509	82.81%	6,266 / 10,000	37.34%	36.79%

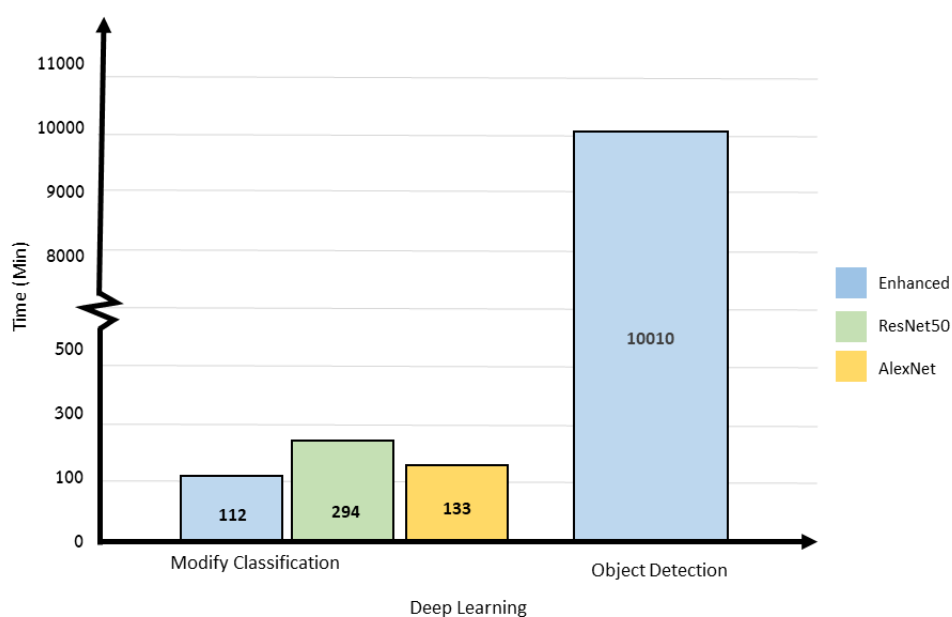
ตารางที่ 30 ตัวชี้วัดของการ Training Model

Precision	Recall	F1-Score	Mean AP
82.81%	37.34%	51.47%	36.79%

จากตารางที่ 30 การวิเคราะห์ Deep learning วิธี Object Detection จะสนใจ ค่า Precision และ ค่า Recall เป็นหลัก โดยค่า Precision ของ Model นี้ มีค่าเท่ากับ 82.81% และ ค่า Recall มีค่าเท่ากับ 37.34% จึงทำให้ ค่า Mean AP ที่เป็นตัววัดประสิทธิภาพของ ทั้ง Model มีค่าน้อย

4.3 เปรียบเทียบการวิเคราะห์ Deep Learning วิธี Modified Classification และ วิธี Object Detection

4.3.1 เวลาในการประมวลผลของ Pre-Trained 3 Models



ภาพที่ 22 กราฟแสดงเวลาของแต่ละ Models ในการ Training ข้อมูล

จากภาพที่ 22 แสดงการเปรียบเทียบ เวลาที่ใช้ในการวิเคราะห์ Deep Learning วิธี Classification และวิธี Object Detection บนอุปกรณ์ แลปท็อป msi thin GF63 12ve-046 TH 12 th Gen Intel(R) Core(TM) i7-12650H 2.30GHz (cpu:0) แสดงให้เห็นว่า Pre-Trained 3 Models ที่วิเคราะห์ Deep Learning วิธี Modified Classification ประมวลผลข้อมูลได้รวดเร็วที่สุด คือ Enhanced ใช้เวลาเพียง 1 ชั่วโมง 52 นาที ส่วน Pre-Trained ที่ประมวลผลข้อมูลได้ช้าที่สุด คือ ResNet50 ใช้เวลานานถึง 4 ชั่วโมง 54 นาที และเมื่อเปรียบเทียบการวิเคราะห์ Deep Learning ใช้เวลาในการประมวลผลข้อมูล 166 ชั่วโมง 50 นาที ซึ่งแสดงให้เห็นว่า วิธี Modified Classification สามารถประมวลผลได้เร็วกว่า

4.3.2 การเปรียบเทียบการวิเคราะห์ Deep Learning วิธี Modified Classification และ วิธี Object Detection

ตารางที่ 31 การเปรียบเทียบการวิเคราะห์ Deep Learning 2 Models

Models	Pre-trained Models	Accuracy (%)	Precision (%)	Recall (%)	F1-Score(%)	Top1-error(%)	Mean AP (%)
Modified Classification	Enhanced	82.28	82.18	82.28	82.18	17.12	
	ResNet50	92.71	92.70	92.71	92.70	7.29	
	AlexNet	83.73	83.49	83.73	83.46	16.27	
Object Detection	Enhanced		82.81	37.34	51.47		36.79

จากตารางที่ 31 เมื่อทำการเปรียบเทียบ การวิเคราะห์ Deep Learning วิธี Modified Classification และ วิธี Object Detection พบว่า Pre-Trained ของการวิเคราะห์ Modified Classification ที่ดีที่สุด คือ ResNet50 ส่วนการวิเคราะห์ด้วย วิธี Object Detection ความสามารถในการตรวจหาเชื้อของ Model มีความสามารถ 36.79%

4.3.3 ผลการวิเคราะห์ Deep Learning และการยืนยันจากแพทย์เชื้อวัณโรค

เมื่อทำการเปรียบเทียบ Models จากการวิเคราะห์ Deep Learning วิธี Modified Classification และ วิธี Object Detection พบว่า วิธี Modified Classification มีความแม่นยำทั้งทางด้าน Accuracy ของ Models ประสิทธิภาพในการทำนายได้มากกว่า Object Detection ความสมดุลของ Model ความสามารถในการทำนายสูง จึงได้นำ Model วิธี Modified Classification มาทดสอบร่วมกับแพทย์เพื่อทำการยืนยันผลจากการวิเคราะห์ Model Modified Classification โดย

แพทย์จะทำการตรวจสอบ 2 วิธี คือ 1.) ตรวจสอบเชื้อวัณโรคร่วมกับการใช้ Model (Doctor Screening with Suspected Positive High Confidence) 2.) ตรวจสอบเชื้อวัณโรคจาก Light Microscopy แสดงดังตารางที่ 32

ตารางที่ 32 แสดงข้อมูลการตรวจหาเชื้อด้วยวิธีต่างๆ

Case	Original Acid-Fast Stain report	Suspected Positive Low Confidence	Suspected Positive High Confidence	Doctor Screening with Suspected Positive High Confidence	Light Microscopy
1	Negative	1,391	74	0	0
2	Negative	108	7	0	0
3	Negative	695	75	0	0
4	Positive	314	61	0	0
5	Negative	80	0	2	0
6	Negative	31	11	0	0
7	Negative	329	18	0	0
8	Negative	160	7	0	0
9	Negative	1,206	46	1	0
10	Negative	2,339	83	0	0
11	Positive	281	57	4	4
12	Positive	475	103	7	4
13	Positive	186	28	0	0
14	Positive	1,691	22	5	4
15	Negative	938	11	0	0
16	Negative	1,111	114	1	0
17	Negative	4,470	139	0	0
18	Positive	42	0	0	0
19	Negative	324	57	0	0
20	Negative	1,498	64	0	0
21	Negative	563	99	0	0

22	Negative	783	144	0	0
23	Negative	185	9	0	0
24	Negative	75	8	0	0
25	Negative	1,378	13	0	0
26	Negative	1,301	124	0	0
27	Negative	347	28	0	0
28	Negative	199	42	1	1
29	Negative	1,245	353	5	0
30	Negative	8,266	26	0	0
31	Negative	135	10	1	1
32	Negative	139	7	0	0
33	Negative	965	109	7	0
34	Negative	571	73	1	0
35	Negative	2,435	293	6	2
36	Negative	1,360	480	4	0
37	Negative	183	39	0	0
38	Positive	285	35	13	0
39	Negative	804	409	0	0
40	Negative	75	21	0	0
41	Negative	144	15	0	0
42	Negative	75	2	0	0
43	Negative	57	8	0	0
Total		39,239	3,324	58	16

จากตารางที่ 32 แสดงจำนวนเชื้อไวรัสโรคที่ได้จากการทดลองวิธีต่างๆ โดยคอลัมน์แรก แสดงจำนวนเคสของผู้ป่วย คอลัมน์ที่สองแสดง Ground Truth ข้อมูลต้นฉบับที่เป็นผลการรายงานว่ามีพบเชื้อไวรัสโรค (Positive) หรือไม่พบเชื้อ (Negative) คอลัมน์ที่สาม แสดงจำนวนเชื้อไวรัสโรคที่วิเคราะห์ด้วย Deep Learning วิธี Modified Classification แบบ Suspected Positive Low Confidence คอลัมน์ที่สี่ แสดงจำนวนเชื้อไวรัสโรคที่วิเคราะห์ด้วย Deep Learning วิธี Modified Classification

แบบ Suspected Positive High Confidence คอลัมน์ที่ห้า แสดงจำนวนเชื้อวัณโรค ที่ตรวจโดย แพทย์ร่วมกับ Model Suspected Positive High Confidence และคอลัมน์สุดท้าย แสดงจำนวน เชื้อวัณโรคที่ตรวจด้วย แพทย์สองคนด้วยกล้อง Light Microscopy

ตารางที่ 33 การเปรียบเทียบการตรวจ วิธี Doctor Screening with Suspected Positive High Confidence กับ Light Microscopy

ชุดข้อมูลที่ทำ การ เปรียบเทียบ	จำนวน ทั้งหมด	การทดลอง	จำนวนเคส ที่ยืนยันผล ถูกต้อง	% ถูก	จำนวนเคสที่ ยืนยันผลผิด	% ผิด
Original Acid-Fast Stain report	43	Doctor Screening with Suspected Positive High Confidence	30	69.77%	13	30.23%
		Light Microscopy	36	83.72%	7	16.28%
Light Microscopy	43	Doctor Screening with Suspected Positive High Confidence	29	67.44%	14	32.56%
Positive (7case)	7	Doctor Screening with Suspected Positive High Confidence	4	57.14%	3	42.86%
		Light Microscopy	3	42.86%	4	57.14%
Positive (Remove 4 case)	4	Doctor Screening with Suspected Positive High Confidence	4	100%	-	-
		Light Microscopy	3	75%	1	25%
Negative	36	Doctor Screening with Suspected Positive High Confidence	26	72.22%	10	27.78%
		Light Microscopy	33	91.67%	3	8.33%

จากตารางที่ 33 วิธี Doctor Screening with Suspected Positive High Confidence ตรวจได้ถูกต้องจำนวน 30 เคส จากเคสทั้งหมด 43 เคส ได้เปอร์เซ็นต์ความถูกต้อง เท่ากับ 69.77% และเคสที่ตรวจผิดจำนวน 13 เคส คิดเป็น 30.23%

วิธีตรวจด้วย Light Microscopy ตรวจได้ถูกต้องจำนวน 36 เคส จากเคสทั้งหมด 43 เคส ได้เปอร์เซ็นต์ความถูกต้อง เท่ากับ 83.72% และเคสที่ตรวจผิดจำนวน 7 เคส คิดเป็น 16.28%

ผลการตรวจทั้งสองวิธี คือ วิธี Doctor Screening with Suspected Positive High Confidence กับ การตรวจด้วย Light Microscopy พบว่า ตรวจได้ถูกต้องจำนวน 29 เคส จากเคสทั้งหมด 43 เคส ได้เปอร์เซ็นต์ความเหมือนกัน เท่ากับ 67.44% และเคสที่ตรวจผิดจำนวน 14 เคส คิดเป็น 32.56%

ผลการตรวจจากเคสที่เป็น Positive ซึ่งมีทั้งหมด 7 เคสจากทั้งหมด 43 เคส พบว่า วิธี Doctor Screening with Suspected Positive High Confidence ตรวจได้ถูกต้องจำนวน 4 เคส ได้เปอร์เซ็นต์ความถูกต้อง เท่ากับ 57.14% เคสที่ตรวจผิดจำนวน 3 เคส คิดเป็น 42.86% และวิธี Light Microscopy ตรวจได้ถูกต้องจำนวน 3 เคส ได้เปอร์เซ็นต์ความถูกต้อง เท่ากับ 42.86% เคสที่ตรวจผิดจำนวน 4 เคส คิดเป็น 57.14% เมื่อดูจากผลการตรวจทั้งสองวิธี ในกลุ่มเคสที่เป็น Positive พบว่า วิธี Doctor Screening with Suspected Positive High Confidence มีความถูกต้องมากกว่า วิธี Light Microscopy

เนื่องจากเคสที่เป็น Positive จำนวน 7 เคส มีการย้อมสีจึงทำการตัดเคสออกจำนวน 3 เคส ได้แก่ เคสที่ 4 13 และ 18 ออก จึงเหลือเคสที่เป็น Positive จำนวนทั้งหมด 4 เคสจากทั้งหมด 40 เคส จะพบว่า วิธี Doctor Screening with Suspected Positive High Confidence ตรวจได้ถูกต้องจำนวน 4 เคส ได้เปอร์เซ็นต์ความถูกต้อง เท่ากับ 100% วิธี Light Microscopy ตรวจได้ถูกต้องจำนวน 3 เคส ได้เปอร์เซ็นต์ความถูกต้อง เท่ากับ 75% เคสที่ตรวจผิดจำนวน 1 เคส คิดเป็น 25% เมื่อดูจากผลการตรวจทั้งสองวิธี ในกลุ่มเคสที่เป็น Positive พบว่า วิธี Doctor Screening with Suspected Positive High Confidence ตรวจได้ถูกต้องทั้งหมด ส่วนวิธี Light Microscopy ตรวจผิดไป 1 เคส

เมื่อพิจารณาจากเคสที่เป็น Negative ซึ่งมีทั้งหมดจำนวน 36 เคส พบว่า วิธี Doctor Screening with Suspected Positive High Confidence มีจำนวนเคสที่ยืนยันถูกต้องจำนวน 26 เคส คิดเป็นเปอร์เซ็นต์ความถูกต้อง เท่ากับ 72.22% เคสที่ตรวจผิดจำนวน 10 เคส คิดเป็น 27.78%

ส่วนวิธี Light Microscopy ตรวจได้ถูกต้องจำนวน 33 เคส ได้เปอร์เซ็นต์ความถูกต้อง เท่ากับ 91.67% และเคสที่ตรวจผิดจำนวน 3 เคส คิดเป็น 8.33% เมื่อดูจากผลการตรวจทั้งสองวิธี ในกลุ่มเคสที่เป็น Negative พบว่า วิธี Doctor Screening with Suspected Positive High Confidence ตรวจได้ถูกต้องน้อยกว่า วิธี Light Microscopy

จากภาพรวม จะเห็นว่าการตรวจด้วย Light Microscopy ได้ผลดีกว่าการตรวจด้วย วิธี Doctor Screening with Suspected Positive High Confidence อยู่ 13.95% แต่เมื่อพิจารณาข้อมูลที่เป็น กลุ่ม Positive ทั้งแบบตัดเคสที่ย้อมสีจางออก และไม่ตัดเคส นั้น พบว่าวิธี Doctor Screening with Suspected Positive High Confidence มีความถูกต้องมากกว่า วิธี Light Microscopy

เคสที่เป็น Negative พบว่า การตรวจด้วย วิธี Doctor Screening with Suspected Positive High Confidence ถูกต้องน้อยกว่าการตรวจด้วย วิธี Light Microscopy ซึ่งในแง่ของการตรวจ Model ในกลุ่มเคส Negative Model ควรจะตรวจพบว่าเป็น Positive มากกว่าทำนายว่าเป็น Negative เพื่อที่จะป้องกันไม่ให้ เคสที่เป็น Positive จริงๆ หลุดการตรวจได้ จากผลการทดลองเคสที่เป็น Negative จึงมีความถูกต้องของ Model น้อยกว่า อยู่ 19.14% และเนื่องจาก Model สามารถตรวจในกลุ่ม Positive ได้ดีจึงสามารถนำ วิธี Light Microscope มาทำการตรวจซ้ำบน Model นี้ได้ โดยที่ไม่ต้องตรวจจนครบทุกเคส

4.4 การอภิปรายผล

ภาพ ZN-slide ที่ได้จากเครื่องสแกน Aperio CS2 Slide Scanner เมื่อทำการสแกนภาพออกมา ภาพที่ได้จะเป็น ไฟล์ SVS file ซึ่งเป็นไฟล์ขนาดใหญ่ไม่สามารถเปิดในโปรแกรมแสดงภาพทั่วไปได้ เพื่อให้สะดวกต่อการทำวิจัย จึงทำการแปลงไฟล์จาก SVS file เป็นไฟล์ .tiff และ ลดขนาดภาพโดยไม่ลดคุณภาพของภาพโดยการตัดภาพออกเป็นส่วนๆ ให้มีขนาดลดลงเหลือ 4 GB หลังจากนั้นทำการตัดภาพ 4GB ให้เหลือขนาด 1500x1500 pixels เพื่อให้ไฟล์มีขนาดเล็กลงสามารถนำเข้าโปรแกรมวิเคราะห์ด้วย Deep Learning ได้ และทำ Image Processing จากการหาช่วงสีได้รวดเร็ว

สีของเชื้อวัณโรคที่ได้จากการย้อมสีทนกรด Acid-Fast Stain ขึ้นอยู่กับการดูดซึม Carbol-fuchsin และความหนาของเนื้อเยื่อที่นำมาย้อม ดังนั้นการทำ Image Processing ควรหาค่าจากเชื้อที่มีช่วงสีใกล้เคียงกัน

การวิเคราะห์ด้วย Deep Learning วิธี Modified Classification ไม่สามารถทำได้โดยตรง เนื่องจากภาพวิธีการ Modified Classification เป็นการระบุถูกหรือผิดเท่านั้น และวิธี Modified Classification ไม่สามารถระบุตำแหน่งเชื้อวัณโรคภายในภาพได้ แต่เชื้อวัณโรคแต่ละภาพมีเชื้อวัณโรคมากกว่า 1 ตัว จึงต้องมีการทำ Image Processing ขึ้นเพื่อให้ภาพใน 1 ภาพ มีเชื้อวัณโรคเพียง 1 ตัว และเมื่อทำการวิเคราะห์เสร็จแล้ว หากต้องการเปลี่ยนแปลงชุดข้อมูลใหม่ ไม่สามารถเพิ่มชุดข้อมูลใหม่ได้ทันทีเหมือนกับการวิเคราะห์ Deep Learning วิธี Object Detection หากต้องการเพิ่มชุดข้อมูลจำเป็นต้องทำ Image Processing ใหม่อีกครั้งหนึ่ง และจัดกลุ่ม

การวิเคราะห์ Deep Learning วิธี Object Detection สามารถเพิ่มชุดข้อมูลได้รวดเร็ว สามารถ Label ได้ข้อมูลได้ทันที แต่ใช้เวลาในการวิเคราะห์ข้อมูลนานกว่า วิธี Modified Classification ถึง 26 เท่า แสดงให้เห็นถึงความล่าช้าในกระบวนการ Training Model นี้ การเลือกใช้วิธีการควรพิจารณาความสมดุลระหว่างความเร็วในการประมวลผลและความแม่นยำของการตรวจจับวัตถุตามความต้องการของงาน

วิธีดั้งเดิมในการตรวจหาเชื้อวัณโรค จากภาพการย้อมสีทึนกรดมีความยุ่งยากและใช้เวลาในการตรวจหาเชื่อนาน การนำ Deep Learning มาช่วยในการตรวจหาเชื้อช่วยลดปัญหาการเกิดข้อผิดพลาดที่เกิดจาก Human Error ได้

เมื่อเปรียบเทียบการตรวจด้วยวิธี Doctor Screening with Suspected Positive High Confidence หากผลที่เป็น Negative แต่ Model ทำนายเป็น Positive สามารถยอมรับได้ เนื่องจาก Model ตรวจเจอส่วนที่มีลักษณะคล้ายเชื่อก่อน เพื่อเป็นการป้องกันการเกิดผลในกรณีที่ผล Positive จริง ตรวจหาไม่เจอ

บทที่ 5

สรุปผลการทดลอง

การวิเคราะห์ Deep Learning สำหรับตรวจหาเชื้อวัณโรค วิธี Modified Classification จะทำการเปรียบเทียบ Pre-Trained 3 Models ได้แก่ Enhanced ResNet50 และ AlexNet โดยแบ่งชุดข้อมูลเป็น 3 กลุ่ม คือ Positive, Positive Low Confidence, และ Negative จะเห็นได้ว่าทุกโมเดลมีค่า Loss Function ลดลงตามการ Training โดย ResNet50 มีการลดลงมากที่สุด การวิเคราะห์กราฟแสดงความสัมพันธ์ระหว่าง Top1-Error Training และ Top1-Error Validation แสดงให้เห็นว่ามีการเกิด Overfitting เล็กน้อย และเมื่อเปรียบเทียบค่า Accuracy, Precision, Recall, และ F1-Score ของ Pre-Trained Model ทั้ง 3 Models ResNet50 มีค่าสูงสุดที่ 92.71%, 92.7%, 92.71%, และ 92.7% ตามลำดับ แสดงให้เห็นว่า Pre-Trained ResNet50 มีประสิทธิภาพที่ดีที่สุดในการจำแนกข้อมูล และเมื่อจัดกลุ่มใหม่เพื่อทำการวิเคราะห์ข้อมูล 2 แบบ คือ Suspected Positive Low Confidence และ Suspected Positive High Confidence เมื่อนำมาคำนวณตัวชี้วัดใหม่ การวิเคราะห์ แบบ Suspected Positive Low Confidence พบว่า ค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score ของ ResNet50 มีค่าสูงสุด มีค่าเท่ากับ 98.06% 98.59% 98.50% และ 98.54% ตามลำดับ ส่วนการวิเคราะห์ แบบ Suspected Positive High Confidence พบว่าค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score ของ ResNet50 มีค่าสูงสุด มีค่าเท่ากับ 94.38% 91.41% 91.76% และ 91.59% ตามลำดับ

การวิเคราะห์ Deep Learning วิธี Object Detection ค่า Precision มีค่าเท่ากับ 82.81%, แสดงถึงความแม่นยำในการตรวจจับเชื้อวัณโรค อย่างไรก็ตาม ค่า Recall ที่ต่ำที่ 37.34% แสดงให้เห็นว่า Model ไม่สามารถตรวจจับวัตถุทั้งหมดที่มีอยู่ในชุดข้อมูล ค่า F1-score ที่อยู่ที่ 51.47% แสดงถึงความสมดุลระหว่าง Precision และ Recall. นอกจากนี้ ค่า Mean AP ที่ต่ำที่ 36.79% ประสิทธิภาพทั่วไปในการตรวจจับวัตถุที่ยังต้องมีการปรับปรุงการ Training เพิ่มเติม เมื่อนำ Model วิธี Modified Classification มาทดสอบร่วมกับแพทย์เพื่อทำการยืนยันผลจากการ โดยแพทย์จะทำการตรวจสอบ 2 วิธี คือ ตรวจหาเชื้อวัณโรคร่วมกับการใช้ Model (Doctor Screening with Suspected Positive High Confidence) ตรวจสอบเชื้อวัณโรคจาก Light Microscopy

จากภาพรวมของผลการทดลอง พบว่าการตรวจด้วย Light Microscopy มีประสิทธิภาพดีกว่าการใช้วิธี Doctor Screening with Suspected Positive High Confidence 13.95%. แต่เมื่อพิจารณาข้อมูลในกลุ่ม Positive ทั้งที่ตัดเคสที่ย้อมสีจางออกและไม่ตัดเคส พบว่าวิธี Doctor Screening with Suspected Positive High Confidence มีความถูกต้อง มากกว่า Light

Microscopy. หากตัดเคสที่ย้อมสีจางออก สามารถตรวจได้ถูกต้อง 100% และ เคสที่เป็น Negative การตรวจด้วยวิธี Doctor Screening with Suspected Positive High Confidence มีความถูกต้องน้อยกว่า Light Microscopy ซึ่งการตรวจสอบโมเดลในกลุ่มของเคสที่เป็น Negative Model ควรที่จะตรวจพบว่ามีเคส Positive มากกว่าการทำนายว่าเป็น Negative เพื่อป้องกัน เคสที่เป็น Positive จริงไม่ได้รับการรักษา จากผลการทดลองเคสที่เป็น Negative วิธี Doctor Screening With Suspected Positive High Confidence จึงมีความถูกต้อง น้อยกว่า อยู่ 19.14% และเนื่องจาก Model สามารถตรวจในกลุ่ม Positive ได้ดีจึงสามารถนำ วิธี Light Microscope มาทำการตรวจซ้ำบน Model นี้ได้ โดยที่ไม่ต้องตรวจจนครบทุกเคส

5.1 ปัญหาที่พบ

จากการทำ Image Processing ช่วงสีของเชื้อในขั้นตอนการหาค่าสีเชื้อวัณโรค มีความสำคัญเป็นอย่างมาก การที่ค่าสีที่ไม่ตรงตามที่เชื้อวัณโรค จะส่งผลต่อการวิเคราะห์ผลลัพธ์ของวิเคราะห์ Deep learning วิธี Modify Classification ได้ และเนื่องจากไฟล์ภาพมีขนาดใหญ่ เมื่อทำการแปลงไฟล์อาจส่งผลถึงคุณภาพของไฟล์ได้

5.2 ข้อเสนอแนะ

การวิเคราะห์ Deep Learning วิธี Modified Classification ต้องทำ Image Processing ก่อน เนื่องจากเป็นส่วนสำคัญเพื่อปรับปรุงภาพเพื่อให้โมเดล Deep Learning สามารถตรวจจับและจัดแยกข้อมูลได้ โดยเฉพาะในขั้นตอนการหาช่วงสี Hue Saturation และ Value เพื่อให้ตรวจพบเชื้อได้มากขึ้นควรทำช่วงสีให้มีความใกล้เคียงกับสีของเชื้อวัณโรคที่ได้จากการย้อมสี Acid-Fast Stain มากที่สุด กรณีที่ช่วงสีของ HSV ไม่มีความใกล้เคียงกับสีเชื้อวัณโรค จะทำให้ยากต่อการตัดรูป เพื่อแบ่งกลุ่มสำหรับวิเคราะห์ด้วย Deep Learning วิธี Modified Classification ได้

บรรณานุกรม

1. Bagcchi, S., *WHO's global tuberculosis report 2022*. The Lancet Microbe, 2023. 4(1): p. e20.
2. Ghebreyesus, T. and T. Kasaeva, *Global tuberculosis report 2019*. World Health Organization, 2019.
3. Ait-Khaled, N., D.A. Enarson, and S.T. Initiative, *Tuberculosis: a manual for medical students*. 2003, World Health Organization.
4. Centers for Disease Control and Prevention. *Tuberculosis: An Overview* 2014.
5. Ait-Khaled, N. and D.A. Enarson, *Tuberculosis: a manual for medical students [electronic resource]*. 2005, World Health Organization.
6. Faruk, O., et al., *A novel and robust approach to detect tuberculosis using transfer learning*. Journal of healthcare engineering, 2021. 2021.
7. Organization, W.H., *WHO consolidated guidelines on tuberculosis. Module 2: screening-systematic screening for tuberculosis disease*. 2021: World Health Organization.
8. Pavlou, A.K., et al., *Detection of Mycobacterium tuberculosis (TB) in vitro and in situ using an electronic nose in combination with a neural network system*. Biosensors and Bioelectronics, 2004. 20(3): p. 538-544.
9. Blas, E. and A.S. Kurup, *Equity, social determinants and public health programmes*. 2010: World Health Organization.
10. Chang, J., et al. *Automated tuberculosis diagnosis using fluorescence images from a mobile microscope*. in *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2012: 15th International Conference, Nice, France, October 1-5, 2012, Proceedings, Part III* 15. 2012. Springer.
11. Wong, A., et al., *TB-Net: A tailored, self-attention deep convolutional neural network design for detection of tuberculosis cases from chest x-ray images*. Frontiers in Artificial Intelligence, 2022. 5: p. 827299.
12. Tavolara, T.E., et al., *Automatic discovery of clinically interpretable imaging biomarkers for Mycobacterium tuberculosis supersusceptibility using deep*

- learning*. EBioMedicine, 2020. **62**.
13. Khan, M.T., et al., *Artificial neural networks for prediction of tuberculosis disease*. *Frontiers in microbiology*, 2019. **10**: p. 395.
 14. Pantanowitz, L., et al., *Artificial intelligence–based screening for Mycobacteria in whole-slide images of tissue samples*. *American Journal of Clinical Pathology*, 2021. **156**(1): p. 117-128.
 15. Hussey, M.A. and A. Zayaitz, *Acid-fast stain protocols*. American Society for Microbiology, 2008.
 16. Lumb, R., et al., *Laboratory diagnosis of tuberculosis by sputum microscopy: The Handbook*. 2013: SA Pathology.
 17. Hema, D. and D.S. Kannan, *Interactive color image segmentation using HSV color space*. *Sci. Technol. J*, 2019. **7**(1): p. 37-41.
 18. Young, I.T., J.J. Gerbrands, and L.J. Van Vliet, *Fundamentals of image processing*. Vol. 841. 1998: Delft University of Technology Delft.
 19. Jähne, B., *Digital image processing*. 2005: Springer Science & Business Media.
 20. Andika, L.A., H. Pratiwi, and S.S. Handajani. *Convolutional neural network modeling for classification of pulmonary tuberculosis disease*. in *Journal of Physics: Conference Series*. 2020. IOP Publishing.
 21. Halcon, *HALCON Solution Guide II_D 2022*.
 22. Iqbal, A., M. Usman, and Z. Ahmed, *Tuberculosis chest X-ray detection using CNN-based hybrid segmentation and classification approach*. *Biomedical Signal Processing and Control*, 2023. **84**: p. 104667.
 23. Hernández, A., Á. Panizo, and D. Camacho. *An ensemble algorithm based on deep learning for tuberculosis classification*. in *Intelligent Data Engineering and Automated Learning–IDEAL 2019: 20th International Conference, Manchester, UK, November 14–16, 2019, Proceedings, Part I 20*. 2019. Springer.
 24. Munadi, K., et al., *Image enhancement for tuberculosis detection using deep learning*. *IEEE Access*, 2020. **8**: p. 217897-217907.
 25. Huang, H.-C., et al., *Novel TB smear microscopy automation system in detecting acid-fast bacilli for tuberculosis–A multi-center double blind study*.

Tuberculosis, 2022. **135**: p. 102212.





ภาคผนวก

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ภาคผนวก ก.

เอกสารรับรองจริยธรรมการวิจัยในมนุษย์

สถาบันพยาธิวิทยา กรมการแพทย์
เลขที่ IOP-FO-RT-02คณะกรรมการจัดการความรู้และบริหารวิจัย
สถาบันพยาธิวิทยา กรมการแพทย์ กระทรวงสาธารณสุข

โครงการวิจัยชื่อเรื่อง

(ภาษาไทย): ความร่วมมือต่างสถาบันเพื่อพัฒนาระบบปัญญาประดิษฐ์ในงานทางพยาธิวิทยาดิจิทัล

(ภาษาอังกฤษ): Multi-Institutional Artificial Intelligence (AI) Development in Digital Pathology

เลขที่โครงการวิจัย : IOP-KM-R65-001

ผู้ดำเนินการวิจัยหลัก : ศ.นพ.ชนพ ช่วงโชติ

หน่วยงานรับผิดชอบ : 1. คณะแพทยศาสตร์ และคณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
2. กลุ่มงานพยาธิวิทยากายวิภาค สถาบันพยาธิวิทยา กรมการแพทย์ กระทรวงสาธารณสุขคณะกรรมการจัดการความรู้และบริหารวิจัย สถาบันพยาธิวิทยา อนุมัติในแจ้งจริยธรรมการวิจัย
ให้ดำเนินการศึกษาวิจัยเรื่องข้างต้นได้ลงนาม *W.K.*

(แพทย์หญิงสมฤทัย ช่วงโชติ)

ประธาน

คณะกรรมการจัดการความรู้และบริหารวิจัย

ลงนาม *Sirintorn*

(นางเสริมทรัพย์ วรรณกะวิกิรานต์)

กรรมการและเลขานุการ


คณะกรรมการจัดการความรู้และบริหารวิจัย

รับรองวันที่ 5 ตุลาคม 2564

สอวป


ภาคผนวก ข.

ภาพการหาช่วงสี HSV




SN63-02179,A

_f9_Image_004_0017




SN63-02179,A

_f9_Image_0017_009




SN63-02179,A

_f9_Image_0020_005




SN63-08092,A1

_f24_Image_004_0010




SN63-08092,A1

_f5_Image_002_008




SN63-08092,A1

_f10_Image_0024_0023




SN63-16240,A3

_f19_Image_006_0024




SN63-16240,A3

_f18_Image_0011_0012




SN63-16240,A3


_f18_Image_0019_001




SN63-29842,A
_f5_Image_0012_0020




SN63-29842,A
_f11_Image_005_004



SN63-29842,A
_f11_Image_0010_0011



SN64-12569,A
_f23_Image_005_0023



SN64-12569,A
_f23_Image_007_0017



SN64-12569,A
_f23_Image_0010_0011

ตารางที่ 34 ตารางช่วงสีที่ใกล้เคียงกับเชื้อไวรัสจากการสุ่มตัวอย่าง

No.	Case	Image No.	H		S		V	
			Low	High	Low	High	Low	High
1	SN63-02179,A	f9_Image_004_0017	149.18	177.48	78.03	148.92	197.12	246.08
	SN63-02179,A	f9_Image_0017_009	145.86	182.58	51.77	255.00	177.99	243.02
	SN63-02179,A	f9_Image_0020_005	146.63	196.35	35.96	252.45	181.05	247.10
2	SN63-08092,A1	f14_Image_004_0010	151.73	190.49	35.45	127.50	202.98	245.06
	SN63-08092,A1	f5_Image_002_008	143.06	166.01	41.82	142.55	215.99	246.08
	SN63-08092,A1	f10_Image_0024_0023	146.37	187.43	27.29	127.50	201.96	242.00
3	SN63-16240,A3	f19_Image_006_0024	147.65	183.86	59.93	185.39	182.07	239.96
	SN63-16240,A3	f18_Image_0011_0012	143.57	186.15	39.78	253.73	185.90	236.90
	SN63-16240,A3	f18_Image_0019_001	147.39	187.94	38.25	214.71	179.01	244.04
4	SN63-29842,A	f5_Image_0012_0020	138.98	164.22	86.19	255.00	177.99	243.02
	SN63-29842,A	f11_Image_005_004	144.33	182.84	28.31	183.35	180.03	247.10
	SN63-29842,A	f11_Image_0010_0011	147.14	167.79	49.73	151.22	196.10	246.08
5	SN64-12569,A	f23_Image_005_0023	147.65	216.50	14.03	164.22	163.97	248.12
	SN64-12569,A	f23_Image_007_0017	145.10	218.28	24.23	200.94	161.93	240.98
	SN64-12569,A	f23_Image_0010_0011	142.80	211.14	26.78	255.00	176.97	230.01
Average			145.83	187.94	42.50	194.50	185.40	243.03

ประวัติผู้เขียน

ชื่อ-สกุล	Terisara Micaraseth
วัน เดือน ปี เกิด	09 Sep 1997
สถานที่เกิด	Bangkok
วุฒิการศึกษา	วศ.บ. ภาควิชาวิศวกรรมอาหาร คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์
ที่อยู่ปัจจุบัน	222 ร่มเกล้า44 แขวงคลองสามประเวศ เขตลาดกระบัง กรุงเทพฯ 10520
ผลงานตีพิมพ์	"Coffee Bean Inspection Machine with Deep Learning Classification" from 2022 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME)



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY