

Received: June 14, 2023; Revised: October 23, 2023; Accepted: November 29, 2023

การพัฒนาระบบปัญญาประดิษฐ์เพื่อตรวจหาเชื้อ ไมโคแบคทีเรีย ทูเบอร์คูโลซิส
(*M. tuberculosis*) จากเสมหะด้วยวิธีการตรวจ Acid-Fast Bacillus (AFB)
The development of artificial intelligence system to detect
Mycobacterium tuberculosis (*M. tuberculosis*) from sputum
with Acid-Fast Bacillus (AFB) method

ปณณธร ขุนโหร^{1*}, ปรีภา พวงทอง¹, วิเชียร ดอนราม¹ และแชนธรรพ์ แสงภู²
Punnathorn Khunhon^{1*}, Peraga Puangtong¹, Vichien Donram¹ and Thanthun Sangphoo²

¹โรงเรียนวิทยาศาสตร์จุฬาภรณราชวิทยาลัยชลบุรี จังหวัดชลบุรี

¹Princess Chulabhorn Science High School Chonburi, Chonburi Province

²โรงพยาบาลเฉลิมพระเกียรติ สมเด็จพระเทพรัตนราชสุดาฯ สยามบรมราชกุมารี ราชวิทยาลัย จังหวัดระยอง

²Rayong Hospital in HRH Royal Highness Princess Maha Chakri Sirindhorn, Rayong Province

*Corresponding Author E-mail Address : khpunnathorn@gmail.com

บทคัดย่อ

วัณโรคปอดเป็นโรคติดต่อทางเดินหายใจชนิดหนึ่ง เกิดจากการติดเชื้อไมโคแบคทีเรีย ทูเบอร์คูโลซิส (*Mycobacterium tuberculosis*) ซึ่งในประเทศไทยนิยมตรวจวัณโรคด้วยวิธีการตรวจเสมหะ Acid-Fast Bacillus (AFB) เนื่องจากค่าใช้จ่ายที่ต่ำ ทว่าในการตรวจหาเชื้อวัณโรคสำหรับแพทย์นั้นมียะเวลาค่อนข้างนาน การวิจัยในครั้งนี้จึงมีวัตถุประสงค์เพื่อพัฒนาปัญญาประดิษฐ์ในการตรวจหาเชื้อวัณโรคเพื่อสนับสนุนแพทย์ โดยในขั้นตอนการพัฒนา ผู้วิจัยได้เริ่มจากการรวบรวมภาพเสมหะจาก Kaggle และ ZNSM-iDB รวมทั้งสิ้น 1,952 ภาพ นำภาพเหล่านั้นไปทำความสะอาดและปรับแต่งภาพ โดยการกลับภาพ หมุนภาพ ปรับความสว่าง ความคมชัด และค่าสีของภาพเพื่อเพิ่มชุดจำนวนข้อมูลภาพ และฉลากเชื้อวัณโรคภายในทุกภาพเพื่อนำไปเทรนโมเดลทั้งหมด 8 โมเดล ประกอบด้วย YOLOv5n, YOLOv5s, YOLO5m, YOLO5l, YOLO5n6, YOLO5s6, YOLO5m6 และ YOLO5l6 จากนั้นจึงนำแต่ละโมเดลที่เทรนไปประเมินและเปรียบเทียบประสิทธิภาพเพื่อหาโมเดลที่ดีที่สุดสำหรับการตรวจหาเชื้อวัณโรค ซึ่งจากผลการพัฒนาพบว่า ในการตรวจภาพเบื้องต้นซึ่งคัดกรองภาพเสมหะว่ามีเชื้อวัณโรคหรือไม่ โมเดล YOLOv5s มีประสิทธิภาพมากที่สุดซึ่งให้ค่าความไว ความจำเพาะ F1-score และระยะเวลาเฉลี่ยในการตรวจจับเชื้อต่อ 1 ภาพ คือ 0.9802, 0.9647, 0.9727 และ 11.1 มิลลิวินาที ตามลำดับ และในขั้นตอนการตรวจจับวัตถุซึ่งระบุตำแหน่งของเชื้อวัณโรคทั้งหมดภายในภาพ โมเดล YOLOv5n6 มีความแม่นยำที่สุดซึ่งมีค่า Precision, Recall และ mAP@0.5 อยู่ที่ 0.673, 0.761 และ 0.727 ตามลำดับ โดยสรุปแล้วระบบปัญญาประดิษฐ์นี้สามารถตรวจหาเชื้อวัณโรคได้อย่างอัตโนมัติด้วยความแม่นยำที่สูง และใช้เวลาที่รวดเร็วในการตรวจ

คำสำคัญ: ปัญญาประดิษฐ์ ไมโคแบคทีเรีย ทูเบอร์คูโลซิส Acid-Fast Bacillus โมเดลโครงข่ายประสาทเทียม

Abstract

Pulmonary tuberculosis is an infectious disease that still has outbreaks in Thailand (Department of Disease Control, 2021), caused by a bacterium called *Mycobacterium tuberculosis*, often known as MTB. In Thailand, the AFB sputum smear test is commonly used to diagnose tuberculosis. It is reliable and affordable, however the physician inspection process is time-consuming. So, we created an AI to automatically inspect the sputum smear to support the physician's inspection procedure in which we started by collecting sputum images from Kaggle and ZNSM-iDB, and processed them through data cleaning and augmentation process. Then, we developed the program for supporting all of the AI, coupled with the Yolov5 module to train, evaluate, and finally compare the performances of the different CNN models used in Yolov5's image processing process. As a result, the system is able to learn from the image dataset, which in preliminary examination, which classifies between positive and negative sputum sample, the most effective model, Yolov5s, was able to detect the MTBs with the sensitivity, specificity, F1-score, and mean detection time per image of 0.9802, 0.9647, 0.9727 and 11.1 milliseconds, respectively, and in the object detection task in which locates every TB in the sample, the most efficient model, Yolov5n6, was able to detect objects and classify the types of MTB with the precision, recall, mAP of 0.673, 0.761, 0.727 respectively. Once the model is exported, the CNN image processing model is trained and ready to be used in further experiments or further development into various innovations. To conclude, the model is able to inspect the MTBs automatically with a high accuracy and fast detection time. However, model image predictions in some images are still wrong, possibly because of the different staining characteristics in each picture, causing the system to misinterpret.

Keywords: Artificial intelligence, *Mycobacterium tuberculosis*, Acid-Fast Bacillus, Convolutional neural network

บทนำ

วัณโรคปอด เป็นโรคติดต่อซึ่งแพร่เชื้อผ่านทางอากาศ เกิดจากการติดเชื้อภายในปอดจากแบคทีเรียที่ชื่อไมโคแบคทีเรียทูปอร์คูโลซิส (*M. tuberculosis*) ส่งผลให้ผู้ติดเชื้อมีอาการไอเรื้อรัง ไอเป็นเลือด เจ็บหน้าอก รู้สึกเจ็บเวลาหายใจหรือไออ่อนเพลีย และอาการอื่น ๆ อันเป็นอันตรายต่อชีวิต โดยอ้างอิงจากสถิติในปี พ.ศ. 2560 มีผู้คนมากกว่า 1.6 ล้านคนเสียชีวิตจากวัณโรค ซึ่งเป็นสาเหตุการเสียชีวิตอันดับที่ 2 รองลงมาจากโรค COVID-19 (World Health Organization, 2021) ดังนั้นการคัดกรองผู้ป่วยวัณโรคที่มีความรวดเร็ว แม่นยำ และมีประสิทธิภาพจึงมีความสำคัญในการควบคุมการแพร่กระจายของวัณโรคต่อสังคมทั่วโลก

ในประเทศไทยการตรวจเชื้อวัณโรคโดยเบื้องต้นสามารถกระทำได้อยู่ 2 วิธี (กรมควบคุมโรค, 2561) ได้แก่ การทดสอบทูเบอร์คูลินผ่านผิวหนัง (Tuberculin skin test) ซึ่งไม่เป็นที่นิยม และการตรวจเสมหะ (AFB sputum smear test) ซึ่งเป็นการนำเสมหะตัวอย่างจากผู้เข้ารับการรักษาเชื้อไปย้อมสีที่มีความจำเพาะต่อเชื้อวัณโรคและนำไปส่องกล้องจุลทรรศน์ อย่างไรก็ตามการตรวจหาเชื้อนี้มีโอกาสที่จะไม่พบเชื้อในบริเวณหนึ่งของสไลด์ด้วยปริมาณของเชื้อในผู้ป่วยที่ต่ำ ผู้ตรวจจึงต้องค้นหาทุกบริเวณของสไลด์เพื่อยืนยันการติดเชื้อวัณโรคและส่งผลให้การตรวจหาเชื้อใช้เวลานาน นอกจากนี้ในการตรวจหาเชื้อด้วยวิธีดังกล่าวจำเป็นต้องใช้ผู้เชี่ยวชาญ จึงส่งผลให้เกิดปัญหาการขาดแคลนบุคลากรในการตรวจหาเชื้อ และปัญหาการตรวจหาเชื้อที่คลาดเคลื่อน ส่งผลต่อการรักษาวัณโรคได้ล่าช้าและมีความเสี่ยงต่อผู้ป่วยมากขึ้น

ด้วยเหตุนี้เองในปัจจุบันเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) จึงได้เข้ามามีบทบาทสำคัญในขั้นตอนการป้องกันและควบคุมการแพร่กระจายเชื้อวัณโรคมากขึ้นเพื่อเพิ่มประสิทธิภาพในการคัดกรองผู้ป่วยซึ่งในการนำ AI ไปประยุกต์ใช้เพื่อตรวจหาเชื้อวัณโรคนั้นสามารถกระทำได้อย่างหลากหลายวิธี ยกตัวอย่างเช่น จากการพัฒนาปัญญาประดิษฐ์

ของ Priya และ Rajinikanth ที่ได้ใช้อัลกอริทึม K-means ในการตรวจหาเชื้อวัณโรคจากค่าสี RGB ของภาพเสมหะตัวอย่าง ซึ่งให้ค่าความไวและความจำเพาะในการระบุวัณโรคอยู่ที่ 97.58% และ 55.28% ตามลำดับ จึงทำให้สรุปได้ว่าความแม่นยำของ AI นี้แปรผันตรงกับค่าสีของภาพ (Priya and Rajinikanth, 2021) จากการพัฒนาปัญญาประดิษฐ์ของ Serrão และคณะ ที่ใช้ Convolutional Neural Network (CNN) และหลักการเชื่อมโยงสัมพันธ์กันของภาพในการพัฒนาโมเดล AI ซึ่งให้ความแม่นยำในการตรวจหาวัณโรคโดยใช้ F1 score ถึง 99.65% ทว่าไม่ได้มีการระบุเพิ่มเติมในส่วนของความแม่นยำในการระบุตำแหน่งของเชื้อวัณโรคในภาพ (Serrão et al., 2020) และจากการพัฒนาปัญญาประดิษฐ์ของ Panicker และคณะ ที่ได้ใช้ CNN ในการตรวจจับเชื้อวัณโรคโดยมีการจำแนกลักษณะสิ่งที่พบในเสมหะเป็นเชื้อวัณโรคเดี่ยว เชื้อวัณโรคที่สัมผัสกัน และสิ่งอื่น ๆ ที่ไม่ใช่เชื้อวัณโรค ซึ่ง AI ที่ถูกพัฒนาให้ค่าความแม่นยำในการตรวจหาวัณโรคโดยใช้ F1 score ถึง 86.76% (Panicker et al., 2018)


ผู้วิจัยจึงได้มีแนวคิดในการพัฒนาเครื่องมือทางการแพทย์เพื่อมาทำหน้าที่แทนผู้ตรวจในการตรวจหาเชื้อวัณโรคด้วยวิธีการตรวจเสมหะชนิด AFB smear test โดยการพัฒนาระบบปัญญาประดิษฐ์เพื่อตรวจหาเชื้อวัณโรคจากภาพถ่ายได้กล้องจุลทรรศน์ในการตรวจเสมหะ เพื่อให้การตรวจวัณโรคเป็นไปด้วยความรวดเร็วและแม่นยำมากขึ้น ส่งผลให้ผู้ป่วยได้รับการรักษาได้เร็วยิ่งขึ้น และช่วยเพิ่มประสิทธิภาพในการควบคุมการแพร่กระจายของวัณโรค

วัสดุ อุปกรณ์ และวิธีการ


ในการวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการพัฒนาระบบปัญญาประดิษฐ์ออกเป็น 2 ขั้นตอน ดังนี้

1. ขั้นตอนก่อนการพัฒนาระบบ (Preprocess)

1.1 รวบรวมรูปภาพเสมหะจากกล้องจุลทรรศน์ในการตรวจหาเชื้อ *M. tuberculosis* จากการตรวจเสมหะด้วยวิธี AFB โดยรูปภาพที่รวบรวมมานั้นเป็นภาพถ่ายของเสมหะที่มีเชื้อ *M. tuberculosis* (ภาพที่เป็นผลบวก) ดังรูปที่ 1(ก) และภาพที่ไม่มีเชื้ออยู่ในภาพ (ภาพที่เป็นผลลบ) ดังรูปที่ 1(ข) ผสมกันอยู่ซึ่งถูกเผยแพร่ลงบนเว็บไซต์ Kaggle จำนวน 1,257 ภาพ (Uddin, n.d.) และ ZNSM-iDB จำนวน 695 ภาพ (Shah et al., n.d.) รวมทั้งสิ้น 1,952 ภาพ ซึ่งมีขนาดภาพ 1,280x1,280 พิกเซล โดยภาพทั้งหมดนั้นจะถูกนำมาทำความสะอาด (Data cleansing) เพื่อล้างข้อมูลที่ไม่พึงประสงค์ออกไปซึ่งในที่นี้คือภาพที่เป็นสีดำทั้งภาพซึ่งเกิดขึ้นจากความผิดพลาดในขณะการดาวน์โหลด และภาพซ้ำในชุดข้อมูลรูปภาพ โดยหลังจากการทำ Data cleaning จะเหลือรูปภาพทั้งหมด 1,923 ภาพ



(ก) ภาพเสมหะที่เป็นผลบวก




(ข) ภาพเสมหะที่เป็นผลลบ

รูปที่ 1 ตัวอย่างภาพเสมหะตัวอย่าง


1.2 ปรับแต่งรูปภาพ (Augmentation) ทั้งหมดเพื่อเพิ่มจำนวนของชุดข้อมูลด้วย Albumentation (Iglovikov, 2023) ซึ่งเป็นไลบรารีของ Python (2022) ดังรูปที่ 2 โดยเทคนิคที่ใช้ในการปรับแต่งภาพนั้นประกอบไปด้วยดังนี้

- 1.2.1 Vertical flip and horizontal flip
- 1.2.2 Random brightness and contrast
- 1.2.3 Gaussian blur and noise
- 1.2.4 Downscale
- 1.2.5 Hue saturation value
- 1.2.6 JPEG compression
- 1.2.7 Rotate



รูปที่ 2 ตัวอย่างภาพที่ได้จากการปรับแต่งภาพด้วย Albumentation

1.3 แบ่งชุดข้อมูลภาพออกเป็น 2 ชุดข้อมูลย่อย ดังรูปที่ 3 คือชุดการฝึก (Train set) ทั้งหมด 9,000 ภาพ และชุดการทดสอบ (Test set) ทั้งหมด 3,741 ภาพ โดยมีภาพผลบวก 1,871 ภาพ และภาพผลลบ 1,870 ภาพ




รูปที่ 3 แผนภาพการสร้างชุดข้อมูล (Dataset) ทั้ง 2 ชุดข้อมูล


1.4 นำภาพเสมหะในชุดการฝึก ไปทำฉลากให้ข้อมูล (Data labeling) สำหรับการฝึกปัญญาประดิษฐ์เพื่อตรวจจับวัตถุ (Object detection AI) โดยใช้เว็บไซต์ Roboflow (2022) ในการทำการฉลากเชื้อวัณโรคทำได้โดยการใช้เครื่องมือในเว็บไซต์ Roboflow ตีกรอบเชื้อวัณโรคทุกตัวในภาพทั้งหมดเพื่อทำฉลากสำหรับการฝึกปัญญาประดิษฐ์ ซึ่งในขั้นตอนนี้ได้มีแพทย์ผู้เชี่ยวชาญพิเศษคอยกำกับดูแลการฉลากเชื้อวัณโรค ดังรูปที่ 5 เพื่อให้การทดลองมีความถูกต้องและน่าเชื่อถือ โดยในการวิจัยครั้งนี้ผู้วิจัยได้จำแนกประเภทของ *M. tuberculosis* ออกเป็น 2 ประเภท ได้แก่

1.4.1 True MTB คือ *M. tuberculosis* ที่อยู่ตัวเดียว หรือกลุ่มเล็ก (2 ถึง 3 ตัว) ดังรูปที่ 4(ก)

1.4.2 Globi MTB คือ *M. tuberculosis* ที่อยู่กันเป็นกระจุก ไม่สามารถนับจำนวนได้ชัดเจน ดังรูปที่ 4(ข)



(ก) ตัวอย่างภาพที่พบ True MTB



(ข) ตัวอย่างภาพที่พบ Globi MTB

รูปที่ 4 ภาพการจำแนกระหว่าง True MTB และ Globi MTB



รูปที่ 5 การกำกับดูแลของแพทย์ผู้เชี่ยวชาญ


2. ขั้นตอนการพัฒนาาระบบ (System development)

2.1 พัฒนาโปรแกรมขึ้นด้วยโครงสร้างโปรแกรมภาษา Python โดยใช้ Google Colaboratory เป็นเครื่องมือในการพัฒนาโปรแกรม และได้ใช้ชุดคำสั่งของ YOLOv5 (Jocher, 2020) ซึ่งเป็นโมเดลที่มีพื้นฐานในการคิดวิเคราะห์เพื่อตรวจจับวัตถุจาก CNN ซึ่งเป็น AI ที่มีหลักการคล้ายคลึงกับการมองเห็นของมนุษย์ที่มองพื้นที่เป็นที่ย่อย ๆ และประมวลผลภาพที่ได้จากการนำกลุ่มของพื้นที่ย่อย ๆ มาผสานกันและใช้ลักษณะที่สังเกตได้มาเชื่อมโยงเพื่อสรุปผลว่าวัตถุที่มองเห็นคืออะไร มาพัฒนาปัญญาประดิษฐ์ในการตรวจจับ *M. tuberculosis* โดยผู้วิจัยได้นำเข้าโมเดลของ YOLOv5 ทั้งหมด 8 โมเดล เพื่อทดลองและเปรียบเทียบหาโมเดลที่มีประสิทธิภาพมากที่สุด ดังนี้

- 2.1.1 YOLOv5n
- 2.1.2 YOLOv5s
- 2.1.3 YOLOv5m
- 2.1.4 YOLOv5l
- 2.1.5 YOLOv5n6
- 2.1.6 YOLOv5s6
- 2.1.7 YOLOv5m6
- 2.1.8 YOLOv5l6

2.2 ทำการฝึกโมเดลที่นำเข้าด้วยคำสั่งจาก YOLOv5 โดยโมเดลขนาดเล็ก ซึ่งประกอบไปด้วยโมเดล YOLOv5n, YOLOv5s, YOLOv5m และ YOLOv5l จะถูกฝึกด้วยภาพที่มีขนาด 640x640 พิกเซล ส่วนโมเดลขนาดใหญ่ขึ้นคือ YOLOv5n6, YOLOv5s6, YOLOv5m6 และ YOLOv5l6 จะถูกฝึกด้วยภาพที่มีขนาด 1,280x1,280 พิกเซล ซึ่งในแต่ละโมเดลซึ่งถูกแบ่งออกเป็นโมเดล n, s, m และ l นั้น จะมีขนาดและจำนวนชั้นของโครงข่ายประสาทเทียมที่ใช้ในการประมวลผลที่ต่างกัน โดยในการฝึกโมเดลทั้งหมดนั้นจะถูกฝึกไว้ที่ 100 epochs ซึ่ง epoch คือจำนวนรอบที่โมเดลนั้นได้เรียนรู้จากชุดข้อมูลเดิมนั่นเอง

2.3 ประเมินประสิทธิภาพของโมเดลซึ่งประเมินได้จากการวิเคราะห์กราฟ Validation loss หรือกราฟความผิดพลาดที่ระบบคิดได้หลังจากการฝึกของแต่ละโมเดลจากการเรียนซ้ำ ๆ หลาย epoch ทำให้ได้ข้อมูลที่มีความต่อเนื่องกัน ซึ่งในการวิเคราะห์กราฟดังกล่าวนี้หากกราฟที่ได้มีความแปรปรวนจนไม่สามารถหารูปแบบของเส้นโค้งได้จะถือว่าโมเดลที่ถูกฝึกนั้นไม่ดี ดังรูปที่ 6 และจำเป็นต้องกลับไปขั้นตอนก่อนหน้าเพื่อจัดการกับชุดข้อมูลรูปภาพให้ดีขึ้น และสามารถปรับค่า Hyperparameters ต่าง ๆ ให้เหมาะสมกับโมเดลเพื่อการฝึกในครั้งถัดไปได้




รูปที่ 6 ตัวอย่าง Validation loss จากการเรียนรู้ที่ไม่ดี

2.4 นำโมเดลที่ทำการฝึกเรียบร้อยแล้วมาเปรียบเทียบประสิทธิภาพในด้านการตรวจภาพเบื้องต้นจากการนำภาพในชุดข้อมูลทดสอบ มาทดลองกับแต่ละโมเดลเพื่อทดสอบความถูกต้องในการทำนายผลลัพธ์เมื่อเทียบกับผลการตรวจของแพทย์ และเปรียบเทียบประสิทธิภาพในด้านการตรวจจับวัตถุของโมเดลด้วยค่า F1-Score และ mAP@0.5 ที่ได้จากการประมวลผลภาพของชุดข้อมูลทดสอบ ก่อนนำไป export เป็นโมเดลที่พร้อมใช้งานจริง ๆ ออกสู่การทดลองหรือการพัฒนาเป็นนวัตกรรมในอนาคต

ผลการวิจัย

ในการนำเสนอผลการวิจัย รวมถึงการวิเคราะห์ข้อมูลของการวิจัยในครั้งนี้ ผู้วิจัยได้นำเสนอตามลำดับ ดังนี้


1. ประสิทธิภาพในการเรียนรู้ของโมเดล



รูปที่ 7 กราฟแสดงค่าระหว่าง Validation box loss และ epoch


หลังจากการฝึกโมเดลแต่ละ epochs ระบบจะทำการทดสอบประสิทธิภาพและหาค่าความคลาดเคลื่อนในการระบุตำแหน่งของวัตถุ (Box loss) และเมื่อครบ 100 epochs แล้วจึงสามารถนำค่าตำแหน่งของวัตถุ มาสร้างกราฟเพื่อวิเคราะห์ความสามารถในการเรียนรู้ของระบบจากชุดรูปภาพได้ ซึ่งจากรูปที่ 7 พบว่า ระบบนั้นสามารถเรียนรู้จากชุดรูปภาพได้ โดยที่

โมเดลใหญ่ซึ่งมีลักษณะเป็นกราฟเส้นประจะสามารถเรียนรู้ได้ดีกว่าโมเดลเล็กซึ่งเป็นกราฟเส้นทึบ โดยจากกราฟนั้นโมเดลใหญ่ให้ค่าตำแหน่งของวัตถุที่น้อยกว่าโมเดลเล็ก



รูปที่ 8 กราฟแสดงค่าระหว่าง Validation object loss และ epoch

เช่นเดียวกับกราฟดังรูปที่ 8 พบว่า ค่าความคลาดเคลื่อน (Validation object loss) ซึ่งได้จากการวัดค่าการพบหรือไม่พบวัตถุในบริเวณนั้น ๆ ของโมเดลใหญ่มีค่าความคลาดเคลื่อนน้อยกว่าโมเดลเล็กจึงทำให้โมเดลใหญ่มีแนวโน้มที่จะให้ค่าความคลาดเคลื่อนในการตรวจจับวัตถุน้อยกว่าโมเดลเล็ก จึงสามารถสรุปได้ว่าโมเดลใหญ่นั้นมีประสิทธิภาพในการเรียนรู้ที่ดีกว่าโมเดลเล็ก นอกจากนี้ผู้วิจัยก็ได้พบว่า ระบบนั้นมีแนวโน้มที่จะเกิดภาวะ Overfitting ของโมเดล นั่นคือภาวะที่โมเดลมีการเรียนรู้จากชุดข้อมูลชุดการฝึกที่ดี ทว่าไม่สามารถนำไปใช้กับข้อมูลใหม่นั้นคือชุดข้อมูลทดสอบ ได้ส่งผลให้ประสิทธิภาพและความแม่นยำเมื่อนำไปใช้จริงมีค่าที่ต่ำ โดยหากมีการฝึกโมเดลด้วยจำนวน epoch ที่มากกว่า 100 epoch จะสังเกตภาวะ Overfitting ของโมเดลได้จากค่าความคลาดเคลื่อนของกราฟโมเดลทุกตัวที่มีแนวโน้มเพิ่มขึ้นหลังผ่าน epoch ที่ 60



รูปที่ 9 กราฟแสดงค่าระหว่าง mAP และ epoch


จากรูปที่ 9 นั้นพบ ว่าโมเดลใหญ่มีค่า mAP (Mean Average Precision) มากกว่าโมเดลเล็ก ซึ่งค่า mAP ก็คืออัตราส่วนของพื้นที่ของวัตถุที่ระบบสามารถตรวจจับได้เทียบกับขนาดจริง หากยังมีค่า mAP มากนั้นก็หมายความว่าโมเดลนั้นสามารถตรวจจับวัตถุได้แม่นยำมาก จึงสรุปได้ว่าโมเดลใหญ่มีแนวโน้มที่จะตรวจจับวัตถุได้มีประสิทธิภาพมากกว่าโมเดลเล็ก

2. ประสิทธิภาพในการตรวจภาพเบื้องต้นและการตรวจจำวัตถุ

ตารางที่ 1 ตารางค่าทางสถิติสำหรับการวัดประสิทธิภาพในการตรวจภาพเบื้องต้น

Model	Measures for classification			
	Sensitivity	Specificity	F1-Score	Average Detection Time (Milliseconds)
Yolov5n	0.9743	0.969	0.9717	10.6
Yolov5s	0.9802	0.9647	0.9727	11.1
Yolov5m	0.9818	0.9572	0.9699	13.6
Yolov5l	0.9845	0.9364	0.9614	17.0
Yolov5n6	0.9898	0.9353	0.9636	13.7
Yolov5s6	0.9947	0.9064	0.9526	13.9
Yolov5m6	0.9952	0.9037	0.9517	18.7
Yolov5l6	0.9952	0.8775	0.9399	23.8

จากตารางที่ 1 พบว่า โมเดล Yolov5s สามารถให้ค่า F1-Score ได้สูงที่สุดนั่นคือ 0.9727 เนื่องจากในการวัดประสิทธิภาพในการตรวจภาพเบื้องต้นนั้น ค่า F1-Score จะถูกใช้เพื่อเปรียบเทียบความแม่นยำของโมเดล โดยยิ่ง F1-Score มีค่ามากหมายความว่าโมเดลมีประสิทธิภาพในการตรวจภาพเบื้องต้นมาก และ Average detection time คือการวัดประสิทธิภาพเชิงเวลา นั่นคือเวลาเฉลี่ยที่ระบบใช้ในการตรวจหาเชื้อต่อ 1 ภาพ ในหน่วยมิลลิวินาที



รูปที่ 10 Confusion matrix ของโมเดล Yolov5n6


ตารางที่ 2 ตารางค่าทางสถิติสำหรับผลการตรวจจำวัตถุ

Model	Measures for object detection		
	Precision	Recall	mAP
Yolov5n	0.605	0.582	0.584
Yolov5s	0.624	0.595	0.569
Yolov5m	0.666	0.652	0.645
Yolov5l	0.615	0.551	0.537
Yolov5n6	0.673	0.761	0.727
Yolov5s6	0.738	0.732	0.710
Yolov5m6	0.708	0.735	0.699
Yolov5l6	0.714	0.748	0.718

จากตารางที่ 2 พบว่า โมเดล YOLOv5n6 สามารถให้ค่า mAP ได้สูงที่สุดนั่นคือ 0.727 นั่นคือโมเดล YOLOv5n6 มีความสามารถในการตรวจจับวัตถุ 72.7% ซึ่งเป็นความแม่นยำที่อยู่ในเกณฑ์มาตรฐาน โดยในการวัดประสิทธิภาพในการตรวจจับวัตถุ จะใช้ค่า mAP ในการเปรียบเทียบประสิทธิภาพการตรวจจับวัตถุแต่ละโมเดล นั่นคือยิ่งโมเดลมีค่า mAP มาก ประสิทธิภาพในการตรวจจับวัตถุก็จะมากนั่นเอง


3. ตัวอย่างภาพจากการตรวจหาเชื้อด้วยระบบ

ผู้วิจัยต้องการให้ผู้อ่านได้เห็นภาพของรูปภาพที่ต้องใช้ในการตรวจหาเชื้อมากขึ้น จึงนำตัวอย่างของภาพแต่ละประเภทมานำเสนอ ดังรูปที่ 11




รูปที่ 11 ภาพการตรวจจับเชื้อภาพที่มีการย้อมสีเสมหะดี

ภาพการตรวจหาเชื้อที่ได้นั้นคือภาพที่พื้นหลัง หรือสิ่งอื่นที่ไม่ใช่เชื้อวัณโรค (Artifacts) เป็นสีน้ำเงิน และเชื้อตัวเชื้อวัณโรคเป็นสีชมพูหรือแดง ซึ่งภาพที่มีการย้อมสีเสมหะที่ดีนั้นมีแนวโน้มที่จะถูกตรวจหาเชื้อได้อย่างแม่นยำ เนื่องจากสีของเชื้อกับพื้นหลังแตกต่างกันอย่างสิ้นเชิง



รูปที่ 12 ภาพการตรวจจับเชื้อภาพที่มีการใส่เลนส์เสริมสีเขียวด้วย mAP@.5 ที่ 72.7%

นอกจากนี้ ในบางภาพที่มีพื้นหลังลักษณะเป็นสีเขียวหรือฟ้า นั้นเกิดจากการใส่เลนส์เสริมสีเขียวเพื่อถนอมสายตาของผู้ตรวจหาเชื้อ ดังรูปที่ 12 ซึ่งภาพดังกล่าวนี้มีอยู่ในชุดข้อมูลซึ่งจากค่า mAP@.5 ที่ได้จึงทำให้โมเดลสามารถตรวจหาเชื้อในภาพได้สูงถึง 18 จุด จาก 20 จุด



รูปที่ 13 ภาพการตรวจจับเชื้อที่เป็น False positive (ตรวจจับผิดพลาด) ด้วย mAP@.5 ที่ 72.7%

ในบางภาพเสมหะตัวอย่างที่มีการประมวลผลที่ผิดพลาด พบว่า ระบบนั้นมีการตรวจจับสิ่งอื่นที่ไม่ใช่เชื้อไวรัส หรือ Artifacts ที่อยู่ในภาพเสมหะและระบุว่าเป็นเชื้อไวรัสเนื่องจาก Artifact ดังกล่าวมักมีลักษณะบางประการที่คล้ายคลึงกับเชื้อไวรัส เช่น สี รูปร่าง ขนาด ส่งผลให้เกิดภาพ False positive ขึ้นและจึงทำให้ระบบมีการตรวจจับเชื้อที่ผิดพลาด ดังรูปที่ 13

การอภิปรายผล

จากการพัฒนาปัญญาประดิษฐ์ในทุกขั้นตอน สามารถวิเคราะห์ข้อมูลได้ดังนี้


1.การวิเคราะห์ชุดของข้อมูล

1.1 การปรับปรุงชุดของข้อมูล

ในการพัฒนาความแม่นยำในการตรวจหาเชื้อนั้น ในช่วงแรกพบว่า มีความแม่นยำต่ำเนื่องจากใช้จำนวนชุดข้อมูลในการฝึกโมเดลน้อยเกินไป แต่หลังจากผู้วิจัยได้ทำการปรับปรุงจำนวนชุดของข้อมูลโดยการเพิ่มจำนวนรูปภาพ และคัดกรองรูปภาพที่มีการ Label ไว้ไม่ได้ออกจากชุดของข้อมูล พบว่า โมเดลมีความแม่นยำในการตรวจหาเชื้อเพิ่มมากขึ้น

1.2 ความยากในการแยกแยะเชื้อในภาพ

ในบางภาพนั้นมีความยากการแยกแยะเชื้อออกจากภาพพื้นหลัง เช่น เชื้อไวรัสในภาพมีสีที่กลมกลืนกับภาพพื้นหลังซึ่งอาจเกิดจากการย้อมเสมหะตัวอย่างที่ไม่ดี หรืออาจมี Artifacts อื่น ๆ ภายในภาพที่มีลักษณะใกล้เคียงกับเชื้อไวรัส นอกจากนี้ ในบางภาพนั้นมีย้อมสีเสมหะที่ต่างกัน จึงทำให้โมเดลนั้นเกิดความคลาดเคลื่อนในการตรวจพบเชื้อ



รูปที่ 14 ภาพเสมหะที่มีเชื้อไวรักลมกลืนกับพื้นหลัง

2. การวิเคราะห์ประสิทธิภาพการตรวจหาเชื้อของโมเดล

2.1 ความแม่นยำในการตรวจหาเชื้อ

จากการตารางที่ 1 พบว่า เมื่อมีการคำนวณด้วย Confusion Matrix ในรูปที่ 10 พบว่า โมเดลที่มีค่า F1-Score มากที่สุด มีค่าความแม่นยำสูงถึง 97.27% ซึ่งมีความแม่นยำมากกว่า 95% นั่นคือโมเดลสามารถตรวจหาเชื้อได้อย่างแม่นยำ และจากเวลาที่โมเดลใช้ในการตรวจหาเชื้อต่อภาพเฉลี่ย พบว่า โมเดลสามารถตรวจหาเชื้อในภาพได้อย่างรวดเร็ว ซึ่งทั้งนี้ ระบบยังจำเป็นต้องพัฒนาเพื่อให้มีความแม่นยำเฉลี่ยนั้นมีความมากกว่า 99% เพื่อให้ระบบในการตรวจจับเชื้อวัณโรคนี้เป็นที่ยอมรับได้ในทางการแพทย์และสามารถนำไปใช้กับผู้ป่วยจริงได้ ซึ่งอาจทำได้โดยการเพิ่มผลจากการจำแนกชนิดของวัตถุต่าง ๆ ที่พบในเสมหะที่ถูกย้อมที่นอกเหนือจากเชื้อวัณโรค

บทสรุป

จากการสร้างระบบปัญญาประดิษฐ์ในการตรวจหาเชื้อวัณโรคเพื่ออำนวยความสะดวกของแพทย์ในการตรวจหาเชื้อวัณโรค ด้วยวิธีการตรวจเสมหะแบบ Acid-Fast Bacillus (AFB) ซึ่งได้มีการพัฒนาขึ้นโดยเริ่มจากการเตรียมชุดข้อมูลภาพเสมหะตัวอย่างและฉลากเชื้อวัณโรคภายในภาพทั้งหมด จากนั้นนำชุดข้อมูลภาพที่ถูกเตรียมไปเทรนปัญญาประดิษฐ์เป็นจำนวน 100 epoch ในแต่ละโมเดล และนำมาเปรียบเทียบประสิทธิภาพในการตรวจหาเชื้อวัณโรคหลังเทรน ซึ่งพบว่า ปัญญาประดิษฐ์สามารถตรวจหาเชื้อ *M. tuberculosis* จากภาพได้กล้องจุลทรรศน์ของเสมหะได้สอดคล้องกับแนวคิดของผู้วิจัย ทั้งในการตรวจภาพเบื้องต้นและตรวจจับวัตถุโดยในการตรวจภาพเบื้องต้น โมเดลที่มีประสิทธิภาพมากที่สุดคือ YOLOv5s ซึ่งสามารถตรวจภาพเบื้องต้นด้วยค่าความไว ความจำเพาะ F1-Score และระยะเวลาเฉลี่ยที่ระบบใช้ในการตรวจจับเชื้อต่อ 1 ภาพ คือ 0.9802, 0.9647, 0.9727 และ 11.1 มิลลิวินาที ตามลำดับ และในการตรวจจับวัตถุ โมเดลที่มีประสิทธิภาพมากที่สุด คือ YOLOv5n6 ซึ่งสามารถตรวจจับวัตถุและสามารถแยกแยะประเภทของเชื้อได้ด้วยค่า Precision, Recall และ mAP คือ 0.673, 0.761 และ 0.727 ตามลำดับ

ทั้งนี้ความแม่นยำเฉลี่ยในการตรวจหาเชื้อวัณโรคที่สูงที่สุดที่ระบบสามารถทำได้นั้นคือ 72.7% ซึ่งมีความแม่นยำในการตรวจภาพเบื้องต้นคือ 96.36% สามารถนำไปพัฒนาให้มีความแม่นยำมากขึ้นเพื่อให้ระบบเป็นที่ยอมรับในทางการแพทย์ตามคำแนะนำของนายแพทย์แอนดรูว์ แสงภู โดยการเพิ่มจำนวนของภาพเสมหะตัวอย่าง ปรับแต่ง Hyperparameter ต่าง ๆ ในการเรียนรู้ของโมเดล และรวมถึงการทดลองใช้โมเดลอื่น ๆ นอกเหนือจากโมเดลของ YOLOv5 ในอนาคต ดังนั้นผู้วิจัยจึงมีแนวคิดที่จะพัฒนาระบบเพื่อเพิ่มความแม่นยำในการตรวจหาเชื้อวัณโรคให้มีความมากกว่า 99% รวมถึงการพัฒนาโปรแกรมเพื่อให้ระบบสามารถติดตั้งกับอุปกรณ์ที่ติดกับกล้องจุลทรรศน์และสามารถนำไปใช้กับผู้ป่วยได้จริงในอนาคต

กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จลงได้ด้วยกรุณาของนายวิเชียร ดอนแรม ครูที่ปรึกษางานวิจัย ที่ได้ให้คำแนะนำในการจัดทำวิจัย การจัดหาเอกสารและตารางต่าง ๆ ที่เป็นประโยชน์สำหรับการศึกษาค้นคว้า และจำเป็นต่อการใช้ทำการวิจัยครั้งนี้ ตลอดจนช่วยตรวจเช็คสภาพความเรียบร้อยของงานวิจัย และขอขอบคุณนายแพทย์แอนดรูว์ แสงภู ครูที่ปรึกษาพิเศษของงานวิจัย ในครั้งนี้ที่ช่วยตรวจเช็คสภาพความเรียบร้อยของงานวิจัย ตลอดจนให้คำแนะนำในการแก้ไขปัญหาต่าง ๆ ขอขอบคุณผู้ปกครอง และอีกหลาย ๆ ท่าน ที่มีได้กล่าวถึงในที่นี้ ซึ่งคอยเป็นกำลังใจและให้คำแนะนำในการจัดทำงานวิจัยครั้งนี้ด้วยดีเสมอมาด้วยทางคณะผู้วิจัยขอขอบพระคุณท่านเป็นอย่างสูงไว้ ณ โอกาสนี้

สุดท้ายนี้ถ้ามีข้อบกพร่องประการใด คณะผู้จัดทำยินดียอมรับไว้ด้วยความยินดียิ่ง ทั้งนี้ เพื่อจะได้นำไปพัฒนาผลงานในอนาคตให้มีความสมบูรณ์มากยิ่งขึ้น

เอกสารอ้างอิง

- กรมควบคุมโรค. (2561). การคัดกรองเพื่อค้นหาวัณโรคและวัณโรคดื้อยา (Systematic screening for active TB and drug-resistant TB). พิมพ์ครั้งที่ 2. สำนักพิมพ์อักษรกราฟิกแอนดี้ไซน์: กรุงเทพฯ.
- Iglovikov V. (2023). Albuementations. Accessed 20 Aug 2022. <https://albuementations.ai/>
- Jocher G. (2020). YOLOv5. Accessed 20 Aug 2022. <https://github.com/ultralytics/yolov5>
- Panicker R.O., Kalmady K.S., Rajan J. and Sabu M.K. (2018). Automatic detection of tuberculosis bacilli from microscopic sputum smear images using deep learning methods. Biocybernetics and Biomedical Engineering. 38(3): 691–699.
- Priya E. and Rajinikanth V. (2021). Signal and image processing techniques for the development of intelligent healthcare systems. 1st Edition. Springer: Singapore.
- Python. (2022). Download the latest version for Windows. Accessed 20 Aug 2022. <https://www.python.org/downloads/>
- Roboflow. (2022). Overview - Roboflow. Accessed 20 Aug 2022. <https://docs.roboflow.com/>
- Uddin S. (n.d.). Tuberculosis Image Dataset. Accessed 8 Sep 2022. <https://www.kaggle.com/datasets/saife245/tuberculosis-image-datasets>
- Serrão M.K.M., Costa M.G.F., Fujimoto B.L., Ogusku M.M. and Filho C.F.F.C. (2020). Automatic Bacillus detection in light field microscopy images using convolutional neural networks and mosaic imaging Approach. In the 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). The Institute of Electrical and Electronics Engineers: Montreal, QC, Canada. 1903-1906.
- Shah M.I., Mishra S., Yadav V.K., Chauhan A., Sarkar M., Sharma S.K. and Rout C. (n.d.). Tuberculosis Image. Accessed 28 Dec 2022. <http://14.139.240.55/znsn/>
- World Health Organization. (2021). Global tuberculosis report 2021. Accessed 20 Aug 2022 <https://www.who.int/publications/i/item/9789240037021>