

การจำแนกโรคปอดบวมจากภาพเอ็กซเรย์ทรวงอกโดยใช้โครงข่ายประสาทเทียม แบบคอนโวลูชันและเทคนิคการถ่ายโอนความรู้

Pneumonia Detection from Chest X-ray Images using Convolutional Neural Networks and Transfer Learning Techniques

พงษ์ศธร เชิดสม¹

Pongsathorn Chedsom¹

¹ งานวิชาการและวิจัย คณะสถาปัตยกรรมศาสตร์ มหาวิทยาลัยขอนแก่น ขอนแก่น 40002 ประเทศไทย

¹ Academic Affairs and Research, Faculty of Architecture Khon Kaen University, Khon Kaen, 40002 Thailand

* Corresponding Author: Pongsathorn Chedsom, pongche@kku.ac.th

Received:

14 January 2024

Revised:

21 April 2024

Accepted:

22 May 2024

คำสำคัญ:

โรคปอดบวม, ภาพเอ็กซเรย์ทรวงอก,
โครงข่ายประสาทเทียมแบบ
คอนโวลูชัน, การถ่ายโอนความรู้,
การเสริมข้อมูล

Keywords:

Pneumonia, Chest X-ray,
Convolutional Neural
Networks, Transfer Learning,
Data Augmentation

บทคัดย่อ: จากข้อมูลของกองระบาดวิทยา พบว่าในช่วงวันที่ 1 มกราคม ถึง 31 ตุลาคม พ.ศ. 2566 มีผู้ป่วยโรคปอดบวมหรือปอดอักเสบจำนวน 239,197 ราย และในช่วง 5 ปีที่ผ่านมา (พ.ศ. 2561–2565) มีจำนวนผู้ป่วยเฉลี่ยเดือนละ 20,000 ราย โดยมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง การวินิจฉัยและรักษาตั้งแต่ระยะเริ่มต้นสามารถช่วยลดอัตราการเสียชีวิตได้อย่างมีนัยสำคัญ งานวิจัยนี้จึงเสนอแบบจำลองการจำแนกโรคปอดบวมจากภาพเอ็กซเรย์ทรวงอกโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน ได้แก่ VGG16 และ VGG19 ร่วมกับเทคนิคการถ่ายโอนความรู้โดยใช้ชุดข้อมูล Chest X-Ray Images (Pneumonia) จำนวน 5,232 ภาพ ซึ่งประกอบด้วยภาพผู้ป่วย 4,273 ภาพ และภาพไม่เป็นโรค 1,583 ภาพ พร้อมทั้งประยุกต์เทคนิคการเสริมข้อมูล และแบ่งข้อมูลออกเป็นชุดเรียนรู้ร้อยละ 70 ชุดตรวจสอบร้อยละ 20 และชุดทดสอบร้อยละ 10 การทดลองแบ่งเป็นสองกลุ่ม ได้แก่ กลุ่มที่ 1 ใช้สถาปัตยกรรม VGG16 และ VGG19 โดยไม่ปรับแต่ง และกลุ่มที่ 2 ปรับแต่งชั้น Fully Connected ของโมเดลร่วมกับการถ่ายโอนความรู้ ผลการทดลองกลุ่มที่ 1 พบว่า VGG16 ให้ความแม่นยำร้อยละ 95.42 และค่าความสูญเสีย 0.18 ส่วน VGG19 ให้ความแม่นยำร้อยละ 94.89 และค่าความสูญเสีย 0.21 สำหรับกลุ่มที่ 2 พบว่า VGG16 พร้อมปรับแต่งชั้น Fully Connected จำนวน 9 ชั้น (ประกอบด้วย 2048-1024-512-256-128-64-32-16-8 โหนด) ให้ผลดีที่สุด โดยมีความแม่นยำร้อยละ 97.83 และค่าความสูญเสีย 0.11 เมื่อเปรียบเทียบกับ VGG16 และ VGG19 ที่ไม่ปรับแต่ง พบว่าความแม่นยำเพิ่มขึ้นร้อยละ 2.41 และ 2.94 ตามลำดับ ขณะที่ค่าความสูญเสียลดลง 0.07 และ 0.10 ตามลำดับ

Abstract: According to data from the Bureau of Epidemiology, between January 1 and October 31, 2023, a total of 239,197 cases of pneumonia or lung inflammation were reported. Over the past five years (2018–2022), the average number of cases was approximately 20,000 per month, with a continuously increasing trend. Early detection and treatment of pneumonia can significantly reduce mortality rates. This study proposes a classification model for pneumonia based on chest X-ray images using Convolutional Neural Networks (CNNs), specifically the VGG16 and VGG19 architectures, in conjunction with the transfer learning technique. The Chest X-Ray Images (Pneumonia) dataset, consisting of 5,232 images (4,273 pneumonia cases and 1,583 normal cases), was used. Data augmentation techniques were applied, and the dataset was divided into 70% training, 20% validation, and 10% testing sets. The experiments were divided into two groups: Group 1 employed the VGG16 and VGG19 architectures, while Group 2 utilized these architectures with transfer learning and customized Fully Connected (FC) layers. In Group 1, the VGG16 achieved an accuracy of 95.42% with a loss value of 0.18, while VGG19 achieved an accuracy of 94.89% with a loss of 0.21. In Group 2, the best performance was achieved using the VGG16 architecture with customized fully connected (FC) layers, consisting of nine layers with 2048, 1024, 512, 256, 128, 64, 32, 16, and 8 nodes, respectively. This configuration achieved the highest accuracy of 97.83% and the lowest loss of 0.11. Compared to the VGG16, the model achieved a 2.41% improvement in accuracy and a 0.07 reduction in loss. When compared to the unmodified VGG19, accuracy improved by 2.94% and loss decreased by 0.10.

1. บทนำ (Introduction)


โรคปอดบวมหรือปอดอักเสบ (Pneumonia) เกิดจากการติดเชื้อที่ถุงลมปอด (Alveoli) เป็นภาวะที่ที่เกิดจากเชื้อไวรัสและแบคทีเรีย เช่น เชื้อไวรัสโคโรนา 2019 (COVID-19) ในท่อนลมหายใจและลักษณะการอักเสบของปอดทำให้เกิดการสะสมของน้ำหลายอย่างในหลอดลมหายใจ อาจทำให้เกิดภาวะระบบหายใจล้มเหลวและเสียชีวิตได้พบได้ทั่วไปในทุกช่วงอายุ (Department of Disease Control, 2022) และสถานการณ์ในประเทศไทยในปี 2566 ข้อมูลจากกองระบาดวิทยาพบว่า ระหว่างวันที่ 1 มกราคม - 31 ตุลาคม 2566 มีผู้ป่วยจำนวน 239,197 ราย คิดเป็นอัตราการป่วย 361.48 รายต่อประชากร 100,000 ราย และในช่วง 5 ปีที่ผ่านมา (2561 - 2565) มีผู้ป่วยเฉลี่ยเดือนละ 20,000 ราย มีผู้เสียชีวิต 224 คนและ

มีแนวโน้มสูงขึ้นตลอดเวลา (Department of Disease Control, 2023) การตรวจร่างกายเพื่อวินิจฉัยโรคปอดบวมของแพทย์ด้วยการถ่ายภาพด้วยรังสีเอ็กซเรย์ (Chest X-Ray) มีประสิทธิภาพมากยิ่งขึ้นและในปัจจุบันการพัฒนาของเทคโนโลยีมีความก้าวหน้าที่สามารถอ่านและคัดแยกโรคเบื้องต้นจากภาพถ่ายเอ็กซเรย์โดยใช้วิธีการของคอมพิวเตอร์วิทัศน์ (Computer Vision) ซึ่งเป็นแขนงหนึ่งของปัญญาประดิษฐ์ (AI) ที่มีความซับซ้อนและมีความรวดเร็วในการประมวลผลซึ่งในเทคนิคการทำงานของการเรียนรู้เชิงลึก (Deep Learning) มีเทคนิคหรือแบบจำลองอื่นๆ ที่สามารถนำมาใช้ในการวิเคราะห์และคัดแยกข้อมูลจากรูปภาพและที่นิยมมากที่สุดในปัจจุบันคือโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs) เป็นโครงข่ายได้รับความนิยม

และมีความสามารถในการสกัดคุณลักษณะเด่นของรูปภาพได้อย่างมีประสิทธิภาพและอีกทั้งการถ่ายโอนความรู้ (Transfer Learning) เป็นเทคนิคหนึ่งที่ได้รับคามนิยมเพื่อลดเวลาในการเรียนรู้ของเครื่องและเหมาะสมสำหรับข้อมูลที่มีขนาดไม่ใหญ่มาก โดยใช้ค่าน้ำหนัก (Weight) ที่ได้รับการเรียนรู้ไว้ล่วงหน้าแล้วมาใช้งาน ซึ่งมีความเหมาะสมกับการนำมาใช้งานในชุดข้อมูลที่มีขนาดไม่ใหญ่มากเช่น ข้อมูลทางการแพทย์ที่มีปริมาณไม่เยอะมาก (Iman, Arabnia, & Rasheed, 2023) โดยแบบจำลองที่ได้รับการยอมรับนำมาใช้ในการถ่ายโอนความรู้ เช่น Xception, VGG16, VGG19, ResNet, ResNetV2 เป็นต้น โครงสร้างของแบบจำลอง VGG16, VGG19 มีลักษณะที่เหมือนกันและมีความแตกต่างในชั้นของแบบจำลองที่ใช้สำหรับการสกัดคุณลักษณะเด่นของข้อมูล VGG16 จะมีเพียง 16 ชั้น และ VGG19 จะมีเพียง 19 ชั้น ดังแสดงในภาพที่ 3 โครงสร้างของแบบจำลอง ConvNet หรือ VGG16 และ VGG19 ในข้อ D และ E

บทความนี้จึงนำเสนอแบบจำลองในการตรวจหาโรคปอดบวมหรือโรคปอดอักเสบจากภาพเอ็กซเรย์ทรวงอกจาก Mendeley data (Kermany, Zhang, & Goldbaum, 2018) เป็นชุดข้อมูลที่ได้รับคามนิยมในบทความต่างๆ และชุดข้อมูลนี้ได้

เผยแพร่บนเว็บไซต์ kaggle.com ที่มีผู้ดาวน์โหลดนำไปใช้งานโดยเฉลี่ยเดือนละ 200 ครั้ง โดยในชุดข้อมูลประกอบไปด้วยภาพเอ็กซเรย์ทรวงอกที่ระบุการเป็นโรคปอดบวม (Pneumonia) ทั้งหมด 5,232 ภาพ แบ่งออกเป็น ไม่เป็นโรค (Normal) จำนวน 1,583 ภาพ และที่บ่งบอกว่าไม่ปกติหรือเป็นโรคปอดบวมจำนวน 4,273 ภาพและใช้เทคนิคการเสริมข้อมูล (Data Augmentation) เฉพาะข้อมูลที่ไม่เป็นโรคเพื่อทำให้ปริมาณข้อมูลที่เท่ากันทั้งสองส่วน โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันได้แก่สถาปัตยกรรม VGG16, VGG19 เพื่อนำมาใช้ร่วมกับเทคนิคการถ่ายโอนความรู้ ได้แบ่งการทดลองออกเป็น 2 กลุ่ม กลุ่มที่ 1 การทดลองโดยใช้สถาปัตยกรรม VGG16, VGG19 โดยที่ไม่มีการปรับแต่งใดๆ และกลุ่มการทดลองที่ 2 ที่นำสถาปัตยกรรม VGG16, VGG19 ซึ่งได้รับความนิยมและประสิทธิภาพในระดับต้นๆ มาใช้โดยการถ่ายโอนความรู้และปรับแต่งในชั้น Fully connected (FC) โดยนำรูปแบบพัฒนาการเพิ่ม/ลดจำนวน Node ในการทดลอง 6 รูปแบบ ดังแสดงในภาพประกอบ 1 ได้แก่ 1) การเพิ่มขึ้นของจำนวน Node สม่่าเสมอ 2) การเพิ่มขึ้นของจำนวน Node สม่่าเสมอและลดลงอย่างสม่่าเสมอเท่ากับการเพิ่มขึ้น 3) การลดจำนวนของ



ภาพประกอบ 1 รูปแบบการพัฒนาแบบจำลองของบทความ

Node สม้าเสมอ 4) จำนวนของ Node เท่าเดิม 5) จำนวนของ Node สลับกัน (สองค่า) 6) จำนวนของ Node เพิ่มและลดไม่เท่ากันจาก (Cherdsom & Kanarkard, 2023) ดังแสดงในภาพประกอบ 8

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง (Materials and Methods)


2.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs)

เป็นโครงข่ายได้รับความนิยมและมีความสามารถในการสกัดคุณลักษณะเด่นของรูปภาพได้อย่างมีประสิทธิภาพ โครงสร้างประกอบไปด้วย 3 ชั้น ชั้นที่ 1 ชั้นคอนโวลูชัน (Convolutional Layer) เป็นชั้นที่ใช้สำหรับการสกัดคุณลักษณะเด่นของข้อมูล (Feature Extraction) ชั้นที่ 2 ชั้นพูลลิง (Pooling Layer) เป็นชั้นสำหรับการลดขนาดของข้อมูลโดยใช้เทคนิคต่างๆ ได้แก่ การเลือกค่ามากที่สุด (Max pooling) การเลือกน้อยที่สุด (Min Pooling) การเลือกผลรวม (Sum Pooling) และการเลือกค่าเฉลี่ย (Average

Pooling) ชั้นที่ 3 ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully Connected Layer) เป็นชั้นสำหรับการรวมข้อมูลเป็นลักษณะ 1 มิติแล้วนำข้อมูลทุกๆ โหนดเชื่อมเข้าด้วยกันทั้งหมดดังแสดงในภาพที่ 2 โครงสร้างประสาทเทียมแบบคอนโวลูชัน (Sengupta *et al.*, 2020)

2.2 VGG-Net Architecture

สถาปัตยกรรม VGG-Net หรือ VGG (Visual Geometry Group) ถูกพัฒนามาจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยกลุ่มนักวิจัย Visual Geometry Group จากมหาวิทยาลัย Oxford ซึ่งปัจจุบันได้รับความนิยมได้แก่ VGG16 และ VGG19 หมายเลข 16 และ 19 คือจำนวนชั้นของการสกัดคุณลักษณะของข้อมูลก่อนเข้าสู่ชั้นการจำแนกข้อมูลดังแสดงในภาพประกอบที่ 3 มีจำนวนพารามิเตอร์ 138 ล้านพารามิเตอร์และ 144 ล้านพารามิเตอร์ตามลำดับ อีกทั้งยังได้ใช้ชุดข้อมูล ImageNet มาใช้ในการเรียนรู้ล่วงหน้าของสถาปัตยกรรมเพื่อให้มีประสิทธิภาพมากยิ่งขึ้น (Karen & Andrew, 2015)



ภาพประกอบที่ 2 โครงสร้างประสาทเทียมแบบคอนโวลูชัน (Sengupta *et al.*, 2020)

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

ภาพประกอบที่ 3 โครงสร้างของแบบจำลอง ConvNet (VGG) (Karen & Andrew, 2015)

2.3 การถ่ายโอนความรู้ (Transfer Learning)

เทคนิคการถ่ายโอนความรู้โดยใช้แบบจำลองที่ได้รับการเรียนรู้ล่วงหน้าไว้ก่อนแล้ว (Pre-trained Model) จากชุดข้อมูลอื่นๆ ที่ได้รับความนิยมเช่น ImageNet ที่มีข้อมูลตัวอย่างจำนวนข้อมูล 1.2 ล้านภาพและมีจำนวน 1000 หมวดหมู่ นอกจากจะลดเวลาในการเรียนรู้ของแบบจำลองแล้ว ยังทำให้แบบจำลองมีประสิทธิภาพมากขึ้น (Singh *et al.*, 2023b) โดยเป็นการนำค่าน้ำหนักมาใช้ในการเรียนรู้ของแต่ละชั้นกับชุดข้อมูลใหม่

2.4 การแบ่งข้อมูลด้วยวิธี K-Fold Cross Validation

เทคนิคการแบ่งข้อมูลเพื่อใช้สำหรับการทดสอบแบบจำลองเพื่อป้องกันการเกิด Bias ของแบบจำลองที่พัฒนาขึ้นโดยแบ่งข้อมูลที่มีจำนวนเท่ากันออกเป็นจำนวนกลุ่ม (K) ที่ต้องการเช่น 5, 10 (K=5, K=10)

โดยการสุ่มข้อมูล แบ่งออกเป็นชุดข้อมูลเรียนรู้และชุดข้อมูลทดสอบและในแต่ละกลุ่มข้อมูลจะข้อมูลในชุดข้อมูลเรียนรู้และชุดข้อมูลทดสอบที่มีความแตกต่างกันดังแสดงภาพประกอบที่ 6 กระบวนการจัดเตรียมชุดข้อมูล ในหัวข้อการแบ่งข้อมูลสำหรับการทดสอบ (K=5)

2.5 การเสริมข้อมูล (Data Augmentation)

เทคนิคการเสริมข้อมูลหรือการเพิ่มจำนวนข้อมูล กรณีที่มีจำนวนข้อมูลน้อยไม่เพียงพอต่อการนำมาใช้ในการเรียนรู้ของแบบจำลอง ข้อมูลที่ได้มีความหลากหลายมากขึ้นเพื่อป้องกันปัญหา Overfit ระหว่างการเรียนรู้ของแบบจำลองและเพื่อเพิ่มความแม่นยำ ประสิทธิภาพให้แบบจำลองที่พัฒนาขึ้น การเลือกใช้วิธีการเสริมข้อมูลเช่น การหมุนภาพตามองศาที่ต้องการ การเพิ่มการรบกวนของภาพ (Noise) ในลักษณะต่างๆ การลดหรือเพิ่มแสง การตัดครอบภาพ (Crop) เป็นต้น ทั้งนี้การเพิ่มข้อมูลโดยเทคนิคนี้

ต้องเลือกใช้วิธีการที่มีความเหมาะสม วิธีการที่นำมาใช้ต้องมีโอกาสที่จะเกิดขึ้นจริงของข้อมูลนั้นๆ

2.6 งานวิจัยที่เกี่ยวข้อง

ในการค้นหาโรคปอดบวมของ Chouhan *et al.* (2020) ได้นำแบบจำลองต่างๆ มาใช้งานร่วมกับเทคนิคการทำ Ensemble model ที่นำแบบจำลองมากกว่าหนึ่งแบบจำลองมาช่วยในการพยากรณ์ ได้แก่ AlexNet, DenseNet121, InceptionV3, ResNet18 และ GoogLeNet และใช้ชุดข้อมูลที่ปริมาณข้อมูลทั้งสองคลาสมีจำนวนที่ไม่เท่ากันคือ 4,273 ภาพที่บ่งบอกว่าเป็นโรคและไม่เป็นโรค 1,583 ภาพ แบบจำลองที่นำเสนอได้รับความแม่นยำร้อยละ 96.40

การวินิจฉัยโรคปอดบวมของ Zhang *et al.* (2021) ได้นำเสนอแบบจำลองจากการปรับแต่งของแบบจำลองจากสถาปัตยกรรม VGG16 มีความแม่นยำร้อยละ 96.06 เมื่อเปรียบเทียบกับแบบจำลองจากสถาปัตยกรรม VGG16 ที่ไม่ได้รับการปรับแต่งมีความแม่นยำร้อยละ 94.35 แบบจำลองจากสถาปัตยกรรม Xception มีความแม่นยำร้อยละ 96.06 แบบจำลองจากสถาปัตยกรรม MobileNet มีความแม่นยำร้อยละ 95.473 แบบจำลองจากสถาปัตยกรรม ResNet121 มีความแม่นยำร้อยละ 87.35

การนำเสนอแบบจำลองของ Racic *et al.* (2021) ที่พัฒนามาจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้ชุดข้อมูลที่ปริมาณข้อมูลทั้งสองคลาสไม่เท่ากันได้แก่ 4,273 ภาพที่เป็นโรคและไม่เป็นโรค 1,583 ภาพ มีความแม่นยำของแบบจำลองร้อยละ 88.90

การวิเคราะห์โรคของ Singh *et al.* (2023b) ได้นำเสนอแบบจำลองจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน และแบบจำลองที่ถ่ายโอนความรู้ ได้แก่ VGG16, VGG19, ResNet50, InceptionV3, Xception, InceptionResNetV2, NasNetLarge ได้ผลความแม่นยำร้อยละ 92.14, 89.90, 84.24, 89.42,

86.64, 86.17, 88.14 ตามลำดับ ส่วนแบบจำลองที่นำเสนอคือ CNN มีความแม่นยำร้อยละ 95.47 และใช้ชุดข้อมูลที่ปริมาณข้อมูลทั้งสองคลาสได้แก่ 4,273 ภาพที่เป็นโรคและไม่เป็นโรค 1,583 ภาพ

บทความของ Mabrouk *et al.* (2022) ได้นำเสนอการแบบจำลองการจำแนกประเภทโรคปอดบวมโดยใช้เทคนิค Ensemble Learning เพื่อลดความซ้ำซ้อนของข้อมูลโดยใช้แบบจำลอง MobileNetV2, DenseNet169, Vision Transformer (ViT) ใช้ชุดข้อมูลที่ปริมาณข้อมูลทั้งสองคลาสมีจำนวนที่ไม่เท่ากันคือ 4,273 ภาพที่เป็นโรคและไม่เป็นโรค 1,583 ภาพ ผลการจำแนกพบว่าแบบจำลอง MobileNetV2, DenseNet169 และ Vision Transformer (ViT) ที่ไม่ใช้เทคนิค Ensemble Learning พบว่ามีความแม่นยำร้อยละ 91.35, 90.87, 92.47 และเมื่อนำ 3 แบบจำลองมาใช้ร่วมกับเทคนิค Ensemble Learning พบว่ามีความแม่นยำร้อยละ 93.91

การตรวจหาโรคปอดบวมของ Varshni *et al.* (2019) ได้ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันในรูปแบบของการทำ pre-trained โดยใช้แบบจำลอง Xception, VGG16, VGG-19, ResNet-50, DenseNet-121 และ DenseNet-169 ในการสกัดข้อมูลและนำไปพยากรณ์โดยใช้ Random Forest, K-nearest Neighbors, Naive Bayes และ Support Vector Machine (SVM) ซึ่งผลพบว่าการใช้งาน ResNet-50 ร่วมกับ SVM (rbf Kernel) ให้ผล AUC เท่ากับ 0.7749 ซึ่งเมื่อเทียบกับแบบจำลอง VGG16 และ VGG19 มีความแตกต่างของค่า AUC ประมาณ 0.0899

ในการศึกษาของ (Shankar *et al.*, 2023) ได้เปรียบเทียบแบบจำลองของ machine learning models ได้แก่ Logistic Regression, KNN, Decision Tree, Random Forest, Naive Bayes, and Support Vector Machines และ deep

learning models ได้แก่ CNN, VGG16, ResNet และปริมาณของข้อมูลที่เป็นโรคและไม่เป็นโรคมียังมีจำนวนประมาณ 1,200 ภาพต่อคลาสซึ่งเป็นการลดจำนวนข้อมูลให้ทั้งสองคลาสมีปริมาณที่เท่ากัน พบว่าระหว่าง machine learning models และ deep learning models ไม่มีความแตกต่างกันมากเมื่อนำมาใช้งานจริงแต่เมื่อเปรียบเทียบความแม่นยำพบว่าโครงข่ายประสาทเทียมแบบคอนโวลูชันพื้นฐานให้ผลร้อยละ 89.74 VGG16 ให้ผลร้อยละ 75.80 และ ResNet ให้ผลร้อยละ 88.14 ซึ่งให้ผลที่มากกว่า Machine Learning Models

และการศึกษาของ (Singh *et al.*, 2023a) ได้นำเสนอแบบจำลอง QCSA network (Quaternion Channel-Spatial Attention Network) ปริมาณข้อมูลทั้งสองคลาสมีจำนวนที่ไม่เท่ากันคือ 4,273 ภาพที่เป็นโรคและไม่เป็นโรค 1,583 ภาพ ให้ความแม่นยำร้อยละ 94.53 และนำมาเปรียบเทียบกับแบบจำลองอื่นๆ เช่น VGG16 และ VGG19 ได้ความแม่นยำร้อยละ 92.14 และ 90.22 ตามลำดับ

ในการระบุโรคปอดบวมของ (Chiwariro & Wosowei, 2023) ได้นำแบบจำลองจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks : CNN) มาใช้ได้แก่ VGG19, VGG16, ResNet50 และ InceptionNet v3 โดยใช้ YoLo v5 ในการค้นหาตำแหน่งของการเกิดโรคเท่านั้น พบว่า VGG16 มีความแม่นยำร้อยละ 88.00 และ VGG19 มีความแม่นยำร้อยละ 80.00 ส่วน ResNet50 และ InceptionNet v3 มีความแม่นยำร้อยละ 73.00 และ 79.00 ตามลำดับ

ในการระบุโรคของ (Papadimitriou, Kanaivos, & Maragoudakis, 2023) นำเสนอแบบจำลองจากโครงข่ายประสาทเทียมแบบคอนโวลูชันที่พัฒนาขึ้นเองที่มีโครงสร้าง 3 รูปแบบและพารามิเตอร์ในการทดลองที่แตกต่างกัน ได้แก่จำนวนรอบของการเรียนรู้ (Epoch) 5, 10, 20, 30, 40, 50 จำนวนของข้อมูล

ที่ใช้ในการเรียนรู้ต่อรอบ (Batch size) 128, 256, 512, 1024 โดยใช้ชุดข้อมูลที่มีปริมาณข้อมูลทั้งสองคลาสมีจำนวนที่ไม่เท่ากันคือ 4,273 ภาพที่เป็นโรคและไม่เป็นโรค 1,583 ภาพ พบว่าแบบจำลองที่ได้ผลดีที่สุดมีความแม่นยำร้อยละ 95.59 โครงสร้างรูปแบบที่ 2 Epoch คือ 50 และ Batch size เท่ากับ 128

3. ชุดข้อมูลและวิธีการ (Materials and Methods)

3.1 เครื่องมือ

งานวิจัยนี้ใช้ไลบรารี Keras เวอร์ชัน 2 และ Tensorflow ในการพัฒนาแบบจำลองด้วยภาษา Python ซึ่งคอมพิวเตอร์สเปค CPU Intel Core i5-10400F หน่วยความจำหลัก 32 GB หน่วยประมวลผลกราฟฟิก Nvidia RTX 3060 (12GB) ระบบปฏิบัติการ Ubuntu เวอร์ชัน 20.04 LTS


3.2 ชุดข้อมูลและการเตรียมข้อมูล

การจัดเตรียมชุดข้อมูลเพื่อการพัฒนาแบบจำลองได้นำมาจาก Mendeley data (Kermany, Zhang, & Goldbaum, 2018) เป็นชุดข้อมูลที่ได้รับค่านิยมในบทความต่างๆ และชุดข้อมูลนี้ได้เผยแพร่บนเว็บไซต์ kaggle.com ที่มีผู้ดาวน์โหลดนำไปใช้งานโดยเฉลี่ยเดือนละ 200 ครั้ง โดยในชุดข้อมูลประกอบไปด้วยภาพเอ็กซเรย์ทรวงอกที่ระบุการเป็นโรคปอดบวม (Pneumonia) ทั้งหมด 5,232 ภาพ ตัวอย่างข้อมูลแสดงในภาพประกอบที่ 4 ด้านบน 4 ภาพคือตัวอย่างของภาพจากภาพเอ็กซเรย์ที่ไม่แสดงโรคปอดบวม และ 4 ภาพด้านล่างคือภาพที่แสดงโรคปอดบวม โดยแบ่งออกเป็นภาพเอ็กซเรย์ทรวงอกที่บ่งบอกว่าปกติ (Normal) จำนวน 1,583 ภาพ และที่บ่งบอกว่าไม่ปกติหรือเป็นโรคปอดบวม (Pneumonia) จำนวน 4,273 ภาพ ซึ่งทั้งสองกลุ่มมีจำนวนข้อมูลไม่เท่ากัน (Imbalanced


Data) จึงได้นำเทคนิคการเสริมข้อมูลเฉพาะกลุ่มข้อมูล บ่งบอกว่าปกติจำนวน 1,583 ภาพ ให้มีจำนวนเท่ากับ ทั้งสองประเภท ซึ่งก่อนจะใช้เทคนิคการเสริมข้อมูล ได้แบ่งข้อมูลสำหรับชุดทดสอบการเรียนรู้ 10% เป็นจำนวน 428 ภาพ จากจำนวนภาพที่จะเกิด หลังจากการเสริมข้อมูลจำนวน 4,273 ภาพ เพื่อ ป้องกัน Bias จากชุดข้อมูล โดยได้เลือกใช้วิธีการ หมุนภาพ 15 องศา (Rotation) การกลับภาพแนวนอน (Horizontal Flip) การกลับภาพแบบแนวตั้ง (Vertical Flip) การซูมภาพ 20% (Zoom) การ บิดภาพไม่เกิน 30 องศา (Shear) โดยการใช้วิธีทั้ง 5 รูปแบบนี้ได้คำนึงถึงลักษณะที่จะเกิดขึ้น

ของแผ่นภาพเอ็กซเรย์ทรวงอกที่ใช้งานจริง โดยแสดง ตัวอย่างในภาพประกอบที่ 5 มีจำนวนภาพทั้งหมด 8,546 ภาพ ทำการแบ่งจำนวนข้อมูลสำหรับการ สร้างการเรียนรู้ของแบบจำลองเป็น Training Set ร้อยละ 70 จำนวน 2,991 ภาพ Validation Set ร้อยละ 20 จำนวน 854 ภาพ Test Set ร้อยละ 10 จำนวน 428 ภาพ ของแต่ละกลุ่มข้อมูลและมีการทำ k-Fold Cross-Validation (K=5) โดยใช้การจัด กลุ่มข้อมูลจากการสุ่มให้เป็นชุดข้อมูลใหม่ทั้ง 5 กลุ่ม เพื่อให้ข้อมูลมีการกระจายตัวอย่างสม่ำเสมอและ นำมาทดสอบประสิทธิภาพของแบบจำลองที่ได้พัฒนา ขึ้น แสดงในภาพประกอบที่ 6

ตัวอย่างภาพที่บ่งบอกว่าปกติ ไม่แสดงโรค (Normal)




ตัวอย่างภาพที่บ่งบอกว่าไม่ปกติ แสดงโรค (Pneumonia)




ภาพประกอบ 4 ตัวอย่างภาพเอ็กซเรย์ทรวงอกจากชุดข้อมูลที่แสดงโรคปอดบวม (ด้านล่าง) และไม่แสดงโรค ปอดบวม (ด้านบน) (Kermany, Zhang, & Goldbaum, 2018)

ตัวอย่างภาพการเสริมข้อมูล (Data Augmentation)



ภาพประกอบ 5 ตัวอย่างภาพเอ็กซเรย์ทรวงอกจากการเสริมข้อมูล



ภาพประกอบ 6 กระบวนการการจัดเตรียมชุดข้อมูล

ตาราง 1 การแบ่งข้อมูลสำหรับการเรียนรู้ของแบบจำลอง

ชุดข้อมูล	กลุ่มข้อมูล	ร้อยละ	จำนวนข้อมูล	รวมทั้งหมด
Training set	ปกติ (Normal)	70	2,991	5,982
	โรคปอดบวม (Pneumonia)		2,991	
Validation set	ปกติ (Normal)	20	854	1,704
	โรคปอดบวม (Pneumonia)		854	
Test set	ปกติ (Normal)	10	428	856
	โรคปอดบวม (Pneumonia)		428	

3.3 การวัดประสิทธิภาพ

การวัดประสิทธิภาพของแบบจำลอง ได้นำการวัดค่าความแม่นยำ (Accuracy) มาใช้

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

โดยที่ TP คือ ค่าที่พยากรณ์ถูกต้องเชิงบวก TN คือ ค่าที่พยากรณ์ถูกต้องเชิงลบ FP คือ ค่าที่พยากรณ์ผิดพลาดเชิงบวก FN คือ ค่าที่พยากรณ์ผิดพลาดเชิง และการวัดความสูญเสีย (Loss Function) คือ ฟังก์ชันที่ใช้วัดระยะห่างระหว่างค่าที่คาดการณ์

ไว้กับค่าที่แท้จริงในแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) ค่าการสูญเสียจะทำหน้าที่เป็นตัวบ่งชี้ประสิทธิภาพของแบบจำลอง โดยค่าการสูญเสียต่ำจะหมายความว่าแบบจำลองทำงานได้แม่นยำมากขึ้น

3.4 กระบวนการฝึกสอนแบบจำลอง

กระบวนการสร้างแบบจำลองโดยแบ่งออกเป็นขั้นตอนดังนี้ ที่แสดงในภาพประกอบ 7

1. เมื่อเตรียมข้อมูลและแบ่งข้อมูลเพื่อให้มีความพร้อมสำหรับการสร้างแบบจำลอง

2. เรียกใช้งานฟังก์ชัน ImageDataGenerator เพื่อแปลงข้อมูลของรูปภาพให้เป็นแบบ One-hot Encoding ให้พิกเซล (Pixel) ของรูปภาพมีค่าอยู่ระหว่าง 0 และ 1

3. เรียกใช้งานฟังก์ชัน flow_from_directory เพื่อจัดเตรียมข้อมูลขั้นตอนสุดท้ายก่อนเข้าสู่กระบวนการสร้างแบบจำลองโดยที่กำหนดขนาดของภาพที่ต้องการ (target_size) เป็น $224 * 224$ ขนาดของจำนวนข้อมูลที่ใช้ในการเรียนรู้แต่ละรอบ (batch_size) และกำหนดรูปแบบของชุดข้อมูล (class_mode) เป็นแบบ binary

4. เข้าสู่ขั้นตอนการเรียนรู้ของแบบจำลอง โดยกำหนดให้ loss function เป็นแบบ binary_crossentropy และ optimizer คือ Adam จำนวนรอบการเรียนรู้ (epoch) 15 รอบ


5. ในกระบวนการเรียนรู้ในแต่ละรอบ (Epoch) จะมีการปรับแต่งค่าต่างๆ ที่ในการเรียนรู้ เช่น weights, loss และกลับเข้าสู่รอบการเรียนรู้ถัดไป ซึ่งจะได้ผลการเรียนรู้ค่าความแม่นยำและความสูญเสียในแต่ละรอบของการเรียนรู้

6. เมื่อครบรอบการเรียนรู้ใน 1 ครั้ง 15 รอบ จะนำมาทดสอบกับชุดข้อมูล k-Fold Cross-Validation (K=5) ที่ได้เตรียมไว้ ซึ่งจะได้ผลการเรียนรู้



ค่าความแม่นยำและความสูญเสีย

3.5 รูปแบบและวิธีการทดลอง

การออกแบบการทดลองได้แบ่งการทดลองเป็น 2 กลุ่ม กลุ่มที่ 1 ทดลองโดยใช้สถาปัตยกรรมพื้นฐานที่ได้รับความนิยมและทันสมัย 2 สถาปัตยกรรม ได้แก่ VGG16 และ VGG19 ที่ไม่ได้มีการปรับแต่ง กลุ่มที่ 2 ทดลองโดยนำสถาปัตยกรรมพื้นฐานได้แก่ VGG16 และ VGG19 มาใช้โดยเทคนิคการถ่ายโอนข้อมูล และปรับแต่งชั้น Fully Connected ซึ่งนำรูปแบบการพัฒนาการเพิ่ม/ลดจำนวน Node ในการทดลอง 6 รูปแบบ ได้แก่ 1) การเพิ่มขึ้นของจำนวน Node สม่าเสมอ 2) การเพิ่มขึ้นของจำนวน Node สม่าเสมอและลดลงอย่างสม่าเสมอเท่ากับการเพิ่มขึ้น 3) การลดจำนวนของ Node สม่าเสมอ 4) จำนวนของ Node เท่าเดิม 5) จำนวนของ Node สลับกัน (สองค่า) 6) จำนวนของ Node เพิ่มและลดไม่เท่ากันจาก (Cherdsom & Kanarkard, 2023) ดังแสดงในภาพประกอบ 9 และกำหนดพารามิเตอร์ในการทดลองได้ของทั้ง 2 กลุ่มการทดลองได้แก่ Optimizer คือ Adam Learning Rate คือ 0.001 (ค่าตั้งต้นของ Optimizer Adam) Batch Size คือ 64 และ Epoch คือ 15 รอบ ดังแสดงในภาพประกอบ 8



ภาพประกอบ 7 ขั้นตอนการเรียนรู้ของแบบจำลอง



ภาพประกอบ 9 รูปแบบการพัฒนาการเพิ่ม/ลดจำนวน Node (Cherdsom & Kanarkard, 2023)

4. ผลการวิจัย (Experimental Result)


4.1 ผลการทดลองกลุ่มที่ 1 การทดลองโดยใช้สถาปัตยกรรมพื้นฐาน (VGG16, VGG19)

ในการทดลองกลุ่มที่ 1 ทำการทดลองโดยใช้สถาปัตยกรรมพื้นฐานที่ไม่ได้มีการปรับแต่งชั้นต่างๆของแบบจำลอง ซึ่งเพิ่มชั้น Fully Connected เป็น

ชั้น Output ในการพยากรณ์โรคเท่านั้น ดังแสดงในตาราง 2 ข้อมูลในตารางแสดงผลจากการทดสอบค่าความแม่นยำ ค่าความสูญเสีย และค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) รวมทั้งค่าเฉลี่ยของความแม่นยำและความสูญเสียจากชุดข้อมูลทดสอบ (Test Set) และภาพประกอบ 10 แสดงค่าความแม่นยำ และค่าความสูญเสียจากชุดข้อมูลทดสอบทั้ง 2 แบบจำลอง

ตาราง 2 ผลการทดลองกลุ่มที่ 1 การทดลองโดยใช้สถาปัตยกรรมพื้นฐาน

#	แบบจำลอง (Model)	Test set		Validation set (K=5)			
		ค่าความแม่นยำ (Accuracy)	ค่าความสูญเสีย (Loss)	ค่าเบี่ยงเบนมาตรฐาน (SD Accuracy)	ค่าเบี่ยงเบนมาตรฐาน (SD Loss)	ค่าเฉลี่ย (Average Accuracy)	ค่าเฉลี่ย (Average Loss)
P1	VGG16	95.42	0.18	0.007	0.017	95.06	0.08
P2	VGG19	94.89	0.21	0.013	0.025	94.71	0.09



ภาพประกอบ 10 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองในตาราง 2

โดยในคอลัมน์ # ระบุ P1-P2 ซึ่งนำมาแสดงในกราฟค่าความแม่นยำและค่าความสูญเสียในภาพประกอบ 10

4.2 ผลการทดลองกลุ่มที่ 2 การปรับแต่งชั้น Fully connected

การทดลองกลุ่มที่ 2 ได้นำสถาปัตยกรรม VGG16 และ VGG19 มาใช้ในการพัฒนาเพิ่มเติมในชั้นของ Fully Connected โดยใช้รูปแบบ 6 รูปแบบโดยใช้การถ่ายโอนข้อมูลและใช้รูปแบบการปรับแต่งจำนวนโหนด (Node) ดังแสดงในตาราง 3 - 8 ซึ่งข้อมูลในตารางแสดงผลจากการทดสอบค่าความแม่นยำ ค่าความสูญเสีย และค่าเบี่ยงเบนมาตรฐาน รวมทั้งค่าเฉลี่ยของความแม่นยำ และความสูญเสีย จากชุดข้อมูลทดสอบ

รูปแบบที่ 1 การเพิ่มขึ้นของจำนวน Node สม่่าเสมอ ผลการทดลองได้แสดงในตาราง 3 จำนวน

3 รายการในแต่ละแบบจำลองโดยใช้สถาปัตยกรรม VGG16 และ VGG19 (3 ลำดับที่มีค่าความแม่นยำมากที่สุด) และภาพประกอบ 11 แสดงค่าความแม่นยำและค่าความสูญเสียจากชุดข้อมูลทดสอบทั้ง 6 แบบจำลอง

รูปแบบที่ 2 การเพิ่มขึ้นของจำนวน Node สม่่าเสมอและลดลงอย่างสม่่าเสมอเท่ากับการเพิ่มขึ้น ผลการทดลองได้แสดงในตาราง 4 จำนวน 3 รายการในแต่ละแบบจำลอง (3 ลำดับที่มีค่าความแม่นยำมากที่สุด) และภาพประกอบ 12 แสดงค่าความแม่นยำ และค่าความสูญเสียจากชุดข้อมูลทดสอบทั้ง 6 แบบจำลอง

รูปแบบที่ 3 การลดจำนวนของ Node สม่่าเสมอ ผลการทดลองได้แสดงในตาราง 5 จำนวน 3 รายการในแต่ละแบบจำลอง (3 ลำดับที่มีค่าความแม่นยำมากที่สุด) และภาพประกอบ 13 แสดง

ค่าความแม่นยำ และค่าความสูญเสียจากชุดข้อมูลทดสอบทั้ง 6 แบบจำลอง

รูปแบบที่ 4 จำนวนของ Node เท่าเดิม ผลการทดลองได้แสดงในตาราง 6 จำนวน 3 รายการในแต่ละแบบจำลอง (3 ลำดับที่มีค่าความแม่นยำมากที่สุด) และภาพประกอบ 14 แสดงค่าความแม่นยำ และค่าความสูญเสียจากชุดข้อมูลทดสอบทั้ง 6 แบบจำลอง

รูปแบบที่ 5 จำนวนของ Node สลับกัน (สองค่า) ผลการทดลองได้แสดงในตาราง 7 จำนวน


3 รายการในแต่ละแบบจำลอง (3 ลำดับที่มีค่าความแม่นยำมากที่สุด) และภาพประกอบ 15 แสดงค่าความแม่นยำ และค่าความสูญเสียจากชุดข้อมูลทดสอบทั้ง 6 แบบจำลอง

รูปแบบที่ 6 จำนวนของ Node เพิ่มและลดไม่เท่ากันจาก ผลการทดลองได้แสดงในตาราง 8 จำนวน 3 รายการในแต่ละแบบจำลอง (3 ลำดับที่มีค่าความแม่นยำมากที่สุด) และภาพประกอบ 16 แสดงค่าความแม่นยำ และค่าความสูญเสีย จากชุดข้อมูลทดสอบทั้ง 6 แบบจำลอง

ตาราง 3 ผลการทดลองกลุ่มที่ 2 การปรับแต่งชั้น Fully Connected รูปแบบที่ 1

#	แบบจำลอง (Model)	จำนวน โหนดของชั้น Fully connected (Fc)	Test set		Validation set (K=5)			
			ค่าความแม่นยำ (Accuracy)	ค่าความสูญเสีย (Loss)	ค่าเบี่ยงเบนมาตรฐาน (SD Accuracy)	ค่าเบี่ยงเบนมาตรฐาน (SD Loss)	ค่าเฉลี่ย (Average Accuracy)	ค่าเฉลี่ย (Average Loss)
P1	VGG16	64	97.54	0.11	0.005	0.027	97.00	0.07
P2	VGG16	64-128-256-512-1024-2048	97.18	0.07	0.007	0.029	97.10	0.09
P3	VGG16	64-128-256-512-1024	96.07	0.23	0.007	0.024	96.89	0.09
P4	VGG19	64-128-256-512	97.30	0.09	0.009	0.022	97.07	0.08
P5	VGG19	64	96.72	0.16	0.010	0.036	96.61	0.10
P6	VGG19	64-128-256-512-1024-2048	96.60	0.13	0.009	0.062	96.14	0.14

* โดยในคอลัมน์ # ระบุ P1-P6 ซึ่งนำมาแสดงในกราฟค่าความแม่นยำและค่าความสูญเสียในภาพประกอบ 11




ภาพประกอบ 11 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองในตาราง 3

ตาราง 4 ผลการทดลองกลุ่มที่ 2 การปรับแต่งชั้น Fully Connected รูปแบบที่ 2

#	แบบจำลอง (Model)	จำนวน โหนดของ ชั้น Fully connected (FC)	Test set			Validation set (K=5)		
			ค่าความ แม่นยำ (Accuracy)	ค่า ความ สูญเสีย (Loss)	ค่าเบี่ยงเบน มาตรฐาน (SD Accuracy)	ค่าเบี่ยงเบน มาตรฐาน (SD Loss)	ค่าเฉลี่ย (Average Accuracy)	ค่าเฉลี่ย (Average Loss)
P1	VGG16	64-128-256- 512-1024- 2048-1024- 512-256-128- 64	97.54	0.11	0.011	0.022	97.10	0.09
P2	VGG16	64-128-256- 128-64	97.18	0.07	0.015	0.053	96.50	0.11
P3	VGG16	64-128-256- 512-256-128- 64	96.07	0.23	0.005	0.018	97.01	0.08
P4	VGG19	64-128-256- 512-1024- 2048-1024- 512-256-128- 64	97.30	0.09	0.006	0.019	97.00	0.08
P5	VGG19	64-128-256- 512-256-128- 64	96.72	0.16	0.010	0.029	96.03	0.10
P6	VGG19	64-128-64	96.60	0.13	0.022	0.058	95.28	0.13

* โดยในคอลัมน์ # ระบุ P1-P6 ซึ่งนำมาแสดงในกราฟค่าความแม่นยำและค่าความสูญเสียในภาพประกอบ 12




ภาพประกอบ 12 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองในตาราง 4

ตาราง 5 ผลการทดลองกลุ่มที่ 2 การปรับแต่งชั้น Fully Connected รูปแบบที่ 3

#	แบบจำลอง (Model)	จำนวนโหนดของชั้น Fully connected (Fc)	Test set		Validation set (K=5)			
			ค่าความแม่นยำ (Accuracy)	ค่าความสูญเสีย (Loss)	ค่าเบี่ยงเบนมาตรฐาน (SD Accuracy)	ค่าเบี่ยงเบนมาตรฐาน (SD Loss)	ค่าเฉลี่ย (Average Accuracy)	ค่าเฉลี่ย (Average Loss)
P1	VGG16	2048-1024-512-256-128-64-32-16-8	97.83	0.11	0.004	0.014	97.61	0.09
P2	VGG16	2048-1024	97.54	0.12	0.013	0.068	96.64	0.11
P3	VGG16	2048-1024-512-256-128-64	97.48	0.11	0.013	0.063	96.59	0.10
P4	VGG19	2048-1024-512	97.38	0.10	0.011	0.019	96.64	0.09
P5	VGG19	2048-1024-512-256	97.30	0.09	0.021	0.114	95.93	0.13
P6	VGG19	2048-1024-512-256-128-64-32-16	97.24	0.08	0.010	0.028	96.66	0.10

* โดยในคอลัมน์ # ระบุ P1-P6 ซึ่งนำมาแสดงในกราฟค่าความแม่นยำและค่าความสูญเสียในภาพประกอบ 13




ภาพประกอบ 13 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองในตาราง 5

ตาราง 6 ผลการทดลองกลุ่มที่ 2 การปรับแต่งชั้น Fully Connected รูปแบบที่ 4

#	แบบจำลอง (Model)	จำนวนโหนดของชั้น Fully connected (Fc)	Test set			Validation set (K=5)		
			ค่าความแม่นยำ (Accuracy)	ค่าความสูญเสีย (Loss)	ค่าเบี่ยงเบนมาตรฐาน (SD Accuracy)	ค่าเบี่ยงเบนมาตรฐาน (SD Loss)	ค่าเฉลี่ย (Average Accuracy)	ค่าเฉลี่ย (Average Loss)
P1	VGG16	20248-20248-20248	97.59	0.13	0.013	0.030	96.61	0.10
P2	VGG16	128-128-128	97.59	0.13	0.010	0.026	97.10	0.09
P3	VGG16	512-512-512	97.24	0.12	0.018	0.919	96.64	0.49
P4	VGG19	128-128-128	97.24	0.09	0.027	0.094	95.56	0.14
P5	VGG19	64-64-64	97.07	0.10	0.014	0.028	96.75	0.09
P6	VGG19	20248-20248-20248	96.60	0.15	0.008	0.013	96.05	0.10

* โดยในคอลัมน์ # ระบุ P1-P6 ซึ่งนำมาแสดงในกราฟค่าความแม่นยำและค่าความสูญเสียในภาพประกอบที่ 14




ภาพประกอบ 14 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองในตาราง 6

ตาราง 7 ผลการทดลองกลุ่มที่ 2 การปรับแต่งชั้น Fully Connected รูปแบบที่ 5

#	แบบจำลอง (Model)	จำนวนโหนดของชั้น Fully connected (Fc)	Test set		Validation set (K=5)			
			ค่าความแม่นยำ (Accuracy)	ค่าความสูญเสีย (Loss)	ค่าเบี่ยงเบนมาตรฐาน (SD Accuracy)	ค่าเบี่ยงเบนมาตรฐาน (SD Loss)	ค่าเฉลี่ย (Average Accuracy)	ค่าเฉลี่ย (Average Loss)
P1	VGG16	128-64-128-64	97.59	0.12	0.012	0.025	96.78	0.09
P2	VGG16	512-256-512-256	97.48	0.16	0.013	0.042	96.38	0.11
P3	VGG16	256-128-256-128	97.42	0.10	0.010	0.027	95.23	0.15
P4	VGG19	128-64-128-64	97.24	0.12	0.011	0.026	96.36	0.10
P5	VGG19	32-16-32-16-32-16	97.24	0.10	0.009	0.026	96.61	0.09
P6	VGG19	256-128-256-128	96.72	0.13	0.027	0.088	94.46	0.16

* โดยในคอลัมน์ # ระบุ P1-P6 ซึ่งนำมาแสดงในกราฟค่าความแม่นยำและค่าความสูญเสียในภาพประกอบ 15




ภาพประกอบ 15 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองในตาราง 7

ตาราง 8 ผลการทดลองกลุ่มที่ 2 การปรับแต่งชั้น Fully Connected รูปแบบที่ 6

#	แบบจำลอง (Model)	จำนวนโหนดของชั้น Fully connected (Fc)	Test set		Validation set (K=5)			
			ค่าความแม่นยำ (Accuracy)	ค่าความสูญเสีย (Loss)	ค่าเบี่ยงเบนมาตรฐาน (SD Accuracy)	ค่าเบี่ยงเบนมาตรฐาน (SD Loss)	ค่าเฉลี่ย (Average Accuracy)	ค่าเฉลี่ย (Average Loss)
P1	VGG16	32-2048-32-16-8	97.65	0.13	0.004	0.012	97.01	0.09
P2	VGG16	2048-32-2048-32-16	97.36	0.10	0.007	0.016	96.87	0.10
P3	VGG16	128-128-128-128-64-128-64	97.36	0.13	0.007	0.013	97.15	0.09
P4	VGG19	64-128-256-512-2048-20248-20248	97.24	0.11	0.019	0.042	96.38	0.10
P5	VGG19	128-128-128-128-64-128-64	97.07	0.11	0.023	0.072	96.00	0.12
P6	VGG19	2048-1024-512-256-128-64-32-16-8-4-4-4	96.59	0.11	0.016	0.037	96.19	0.11

* โดยในคอลัมน์ # ระบุ P1-P6 ซึ่งนำมาแสดงในกราฟค่าความแม่นยำและค่าความสูญเสียในภาพประกอบ 16



ภาพประกอบ 16 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองในตาราง 8

ตาราง 9 เปรียบเทียบผลการทดลองกับบทความอื่น

อ้างอิง (Reference)	แบบจำลอง (Model)	ค่าความแม่นยำ (Accuracy)
(Chouhan <i>et al.</i> , 2020)	Ensemble model [AlexNet, DenseNet121, InceptionV3, GoogLeNet, and ResNet18]	96.40
(Zhang <i>et al.</i> , 2021)	Xception	96.06
	MobileNet	95.47
	VGG16	94.35
	ResNet50	92.80
	ResNet121	87.35
Racic <i>et al.</i> (2021)	CNN	88.90
(Singh <i>et al.</i> , 2023b)	CNN	95.47
	VGG16	92.14
	VGG19	89.90
	ResNet50	84.24
	InceptionV3	89.42
	Xception	86.64
	InceptionResNetV2	86.17
	NasNetLarge	88.14
(Mabrouk <i>et al.</i> , 2022)	E n s e m b l e m o d e l [MobileNetV2,DenseNet169,Vision Transformer (ViT)]	93.91
	MobileNetV2	91.35
	DenseNet169	90.87
	Vision Transformer (ViT)	92.47
(Shankar <i>et al.</i> , 2023)	CNN	89.74
	VGG16	75.80
	ResNet	88.14
(Singh <i>et al.</i> , 2023a)	QCSA	94.53
	VGG16	92.14
	VGG19	90.22
(Chiwariro & Wosowei, 2023)	VGG16	88.00
	VGG19	80.00
	ResNet50	73.00
	InceptionNet	79.00
(Papadimitriou <i>et al.</i> , 2023)	CNN	95.59
ผู้เขียน	VGG16	95.42
	VGG19	94.89
	VGG16 + FC (นำเสนอ)	97.83

สรุปผลการทดลอง

จากการพัฒนาแบบจำลองในการตรวจหาโรคปอดบวมจากภาพเอ็กซเรย์ทรวงอกโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันได้แก่สถาปัตยกรรม VGG16, VGG19 เพื่อนำมาใช้ร่วมกับเทคนิคการถ่ายโอนความรู้ (Transfer Learning) แบ่งการทดลองออกเป็น 2 กลุ่ม กลุ่มที่ 1 การทดลองโดยใช้สถาปัตยกรรม VGG16 และ VGG19 โดยที่ไม่มีการปรับแต่งใดๆ และกลุ่มที่ 2 นำสถาปัตยกรรม VGG16 และ VGG19 มาใช้โดยการถ่ายโอนความรู้และปรับแต่งชั้น Fully Connected (Fc) โดยใช้รูปแบบในการปรับแต่งโหนด 6 รูปแบบ จากชุดข้อมูลของ (Kermany, Zhang, & Goldbaum, 2018) และมีการทำ k-fold Cross-Validation (K=5) กับชุดข้อมูลที่น่ามาสร้างและทดสอบแบบจำลองโดยแต่ละ Fold แบ่งข้อมูลออกเป็น 70:20:10 (Training Set : Validation Set : Test Set)

กลุ่มการทดลองที่ 1 ทั้งสองสถาปัตยกรรม VGG16 และ VGG19 ได้ค่าความแม่นยำที่ใกล้เคียงกันคือร้อยละ 95.42 และ 94.89 เมื่อเปรียบเทียบกับความแม่นยำในการนำแบบจำลองทั้งสองไปใช้งานกับบทความอื่นๆ พบความมีความแม่นยำที่ไม่แตกต่างกันอย่างมีนัยสำคัญมากนัก และเมื่อเปรียบเทียบทั้งสองสถาปัตยกรรมพบว่าค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) มีว่าการกระจายตัวไม่แตกต่างกันมากนักที่ของค่าความแม่นยำ 0.006 ของค่าความสูญเสีย 0.008 และค่าเฉลี่ย (Average) ของค่าความแม่นยำ 0.36 ของค่าความสูญเสีย 0.01

กลุ่มการทดลองที่ 2 เป็นการพัฒนาเพิ่มเติมในชั้นของ Fully connected โดยใช้เทคนิคการถ่ายโอนความรู้จากสถาปัตยกรรม VGG16 และสถาปัตยกรรม VGG19 จำนวน 6 รูปแบบ

รูปแบบที่ 1 ในการทดลองทั้งหมดพบว่าแบบจำลองที่ได้ผลดีที่สุดคือ VGG16 + FC (64) เพียงหนึ่งชั้นได้ค่าความแม่นยำสูงถึงร้อยละ 97.77

และค่าความสูญเสียร้อยละ 0.08 และที่ได้ผลดีน้อยที่สุดคือ VGG16 + FC (64-128-256-512) ได้ค่าความแม่นยำสูงถึงร้อยละ 93.87 และค่าความสูญเสียเพิ่มมากถึงร้อยละ 2.41 และเมื่อเปรียบเทียบพบว่ามียะห่างของความแม่นยำสูงถึงร้อยละ 3.9 และค่าความสูญเสียมากถึงร้อยละ 2.33 และค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) มีการกระจายตัวไม่แตกต่างกันมากนักที่ค่าสูงสุดที่ 0.010 และน้อยที่สุดที่ 0.005 ส่วนค่าเฉลี่ย (Average) ของค่าความแม่นยำที่สุดคือ 97.10 ต่ำที่สุดคือ 96.14 ของค่าความสูญเสียสูงที่สุดคือ 0.14 ต่ำที่สุดคือ 0.08 อีกทั้งเมื่อนำค่าความแม่นยำมาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักไม่เกิน 0.82 โดยเฉลี่ยแล้วค่าความแม่นยำที่ดีที่สุดในรูปแบบนี้คือการถ่ายโอนความรู้ของแบบจำลอง VGG19

รูปแบบที่ 2 ในการทดลองทั้งหมดพบว่าแบบจำลองที่ได้ผลดีที่สุดคือ VGG16 + FC (64-128-256-512-1024-2048-1024-512-256-128-64) ได้ค่าความแม่นยำสูงถึงร้อยละ 97.54 และค่าความสูญเสียร้อยละ 0.11 และที่ได้ผลดีน้อยที่สุดคือ VGG16 + FC (64-128-256-512-1024-512-256-128-64) ค่าความแม่นยำสูงถึงร้อยละ 96.07 และค่าความสูญเสียเพิ่มมากถึงร้อยละ 0.23 และเมื่อเปรียบเทียบพบว่ามียะห่างของความแม่นยำร้อยละ 1.47 และค่าความสูญเสียมากถึงร้อยละ 0.12 และค่าเบี่ยงเบนมาตรฐานมีการกระจายตัวไม่แตกต่างกันมากนักที่ค่าสูงสุดที่ 0.060 และน้อยที่สุดที่ 0.005 ส่วนค่าเฉลี่ยของค่าความแม่นยำสูงที่สุดคือ 97.10 ต่ำที่สุดคือ 93.71 ของค่าความสูญเสียสูงที่สุดคือ 0.18 ต่ำที่สุดคือ 0.08 อีกทั้งเมื่อนำค่าความแม่นยำมาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักไม่เกิน 1.32 โดยเฉลี่ยแล้วค่าความแม่นยำที่ดีที่สุดในรูปแบบนี้คือการถ่ายโอนความรู้ของแบบจำลอง VGG16 แต่ไม่ได้มีความแตกต่างกันมากกับ VGG19

รูปแบบที่ 3 ในการทดลองทั้งหมดพบว่าแบบจำลองที่ได้ผลดีที่สุดคือ VGG16 + FC (2048-1024-512-256-128-64-32-16-8) ได้ค่าความแม่นยำสูงถึงร้อยละ 97.83 และค่าความสูญเสียร้อยละ 0.11 และที่ได้ผลดีน้อยที่สุดคือ VGG16 + FC (2048-1024-512-256-128) ค่าความแม่นยำสูงร้อยละ 85.59 และค่าความสูญเสียร้อยละ 0.19 และเมื่อเปรียบเทียบพบว่ามึระยะห่างของความแม่นยำมากถึงร้อยละ 12.24 และค่าความสูญเสียเพียงร้อยละ 0.08 และค่าเบี่ยงเบนมาตรฐานมีการกระจายตัวไม่แตกต่างกันมากนักที่ค่าสูงสุดที่ 0.021 และน้อยที่สุดที่ 0.004 ส่วนค่าเฉลี่ย ของค่าความแม่นยำสูงที่สุดคือ 97.61 ต่ำที่สุดคือ 95.93 ของค่าความสูญเสียสูงที่สุดคือ 0.13 ต่ำที่สุดคือ 0.09 อีกทั้งเมื่อนำค่าความแม่นยำมาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักไม่เกิน 1.37 โดยเฉลี่ยแล้วค่าความแม่นยำที่ดีที่สุดในรูปแบบนี้คือการถ่ายโอนความรู้ของแบบจำลอง VGG19

รูปแบบที่ 4 ในการทดลองทั้งหมดพบว่าแบบจำลองที่ได้ผลดีที่สุดคือ VGG16 + FC (20248-20248-20248) ได้ค่าความแม่นยำสูงถึงร้อยละ 97.59 และค่าความสูญเสียร้อยละ 0.13 และที่ได้ผลดีน้อยที่สุดคือ VGG19 + FC (256-256-256) มีค่าความแม่นยำสูงถึงร้อยละ 96.54 และค่าความสูญเสียร้อยละ 0.15 และเมื่อเปรียบเทียบพบว่ามึระยะห่างของความแม่นยำเพียงถึงร้อยละ 1.05 และค่าความสูญเสียเพียงร้อยละ 0.02 และค่าเบี่ยงเบนมาตรฐานมีการกระจายตัวไม่แตกต่างกันมากนักที่ค่าสูงสุดที่ 0.027 และน้อยที่สุดที่ 0.008 ส่วนค่าเฉลี่ยของค่าความแม่นยำสูงที่สุดคือ 97.10 ต่ำที่สุดคือ 95.56 ของค่าความสูญเสียสูงที่สุดคือ 0.49 ต่ำที่สุดคือ 0.09 อีกทั้งเมื่อนำค่าความแม่นยำมาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักไม่เกิน 1.68 โดยเฉลี่ยแล้วค่าความแม่นยำที่ดีที่สุดในรูปแบบนี้คือการถ่ายโอนความรู้ของแบบจำลอง VGG16



รูปแบบที่ 5 ในการทดลองทั้งหมดพบว่าแบบจำลองที่ได้ผลดีที่สุดคือ VGG16 + FC (128-64-128-64-128-64) ได้ค่าความแม่นยำสูงถึงร้อยละ 97.59 และค่าความสูญเสียร้อยละ 0.12 และที่ได้ผลดีน้อยที่สุดคือ VGG19 + FC (512-256-512-256-512-256) มีความแม่นยำร้อยละ 82.90 และค่าความสูญเสียร้อยละ 1.06 และเมื่อเปรียบเทียบพบว่ามึระยะห่างของความแม่นยำมากถึงร้อยละ 14.69 และค่าความสูญเสียมากถึงร้อยละ 0.94 และค่าเบี่ยงเบนมาตรฐานมีการกระจายตัวไม่แตกต่างกันมากนักที่ค่าสูงสุดที่ 0.088 และน้อยที่สุดที่ 0.025 ส่วนค่าเฉลี่ยของค่าความแม่นยำสูงที่สุดคือ 96.78 ต่ำที่สุดคือ 94.46 ของค่าความสูญเสียสูงที่สุดคือ 0.15 ต่ำที่สุดคือ 0.09 อีกทั้งเมื่อนำค่าความแม่นยำมาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักไม่เกิน 2.26 โดยเฉลี่ยแล้วค่าความแม่นยำที่ดีที่สุดในรูปแบบนี้คือการถ่ายโอนความรู้ของแบบจำลอง VGG16

รูปแบบที่ 6 ในการทดลองทั้งหมดพบว่าแบบจำลองที่ได้ผลดีที่สุดคือ VGG16 + FC (32-2048-32-16-8) ได้ค่าความแม่นยำสูงถึงร้อยละ 97.65 และค่าความสูญเสียร้อยละ 0.13 และที่ได้ผลดีน้อยที่สุดคือ VGG19 + FC (2048-1024-2048-1024-512-256-128) มีความแม่นยำร้อยละ 50.00 และค่าความสูญเสียร้อยละ 3,556.00 ซึ่งเป็นการทดลองที่ไม่สามารถพยากรณ์โรคได้อีกทั้งไม่เหมาะสมกับชั้น FC ที่ทดลองและเมื่อเปรียบเทียบพบว่ามึระยะห่างของความแม่นยำสูงถึงถึงร้อยละ 47.65 และค่าความสูญเสียมากถึงร้อยละ 3,555.87 และค่าเบี่ยงเบนมาตรฐานมีการกระจายตัวไม่แตกต่างกันมากนักที่ค่าสูงสุดที่ 0.023 และน้อยที่สุดที่ 0.072 ส่วนค่าเฉลี่ยของค่าความแม่นยำสูงที่สุดคือ 97.15 ต่ำที่สุดคือ 96.00 ของค่าความสูญเสียสูงที่สุดคือ 0.12 ต่ำที่สุดคือ 0.09 อีกทั้งเมื่อนำค่าความแม่นยำมาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักไม่เกิน 1.07 โดยเฉลี่ยแล้ว

ค่าความแม่นยำที่ดีที่สุดในรูปแบบนี้คือการถ่ายโอนความรู้ของแบบจำลอง VGG16

และเมื่อเปรียบเทียบทั้ง 6 รูปแบบการทดลองแล้วพบว่าการทดลองที่ใช้สถาปัตยกรรม VGG16 ร่วมกับชั้น Fully connected โดยมีจำนวนโหนด คือ 2048-1024-512-256-128-64-32-16-8 ตามลำดับซึ่งแสดงดังภาพประกอบ 19 ได้ค่าความแม่นยำมากที่สุดคือ 97.83 และค่าความสูญเสีย 0.11 และค่าเบี่ยงเบนมาตรฐานมีการกระจายตัวที่ 0.004 ส่วนค่าเฉลี่ยของค่าความแม่นยำคือ 97.61 ของค่าความสูญเสียคือ 0.09 อีกทั้งเมื่อนำค่าความแม่นยำ


มาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักคือ 0.22 ซึ่งอยู่ในรูปแบบที่ 3 ในภาพประกอบ 17 ได้แสดงค่าความแม่นยำและค่าความสูญเสียระหว่างการเรียนรู้ของแบบจำลองที่นำเสนอและเป็นแบบจำลองที่มีความแม่นยำสูงที่สุดและภาพประกอบ 18 แสดง Confusion Matrix ของการพยากรณ์ เมื่อนำมาเปรียบเทียบกับสถาปัตยกรรม VGG16 และ VGG19 ที่ไม่ได้มีการปรับแต่งพบว่ามีค่าความแม่นยำเพิ่มขึ้น 2.41 และค่าความสูญเสียลดลง 0.07 เมื่อเปรียบเทียบกับ VGG16 ค่าความแม่นยำเพิ่มขึ้น 2.94 และค่าความสูญเสียลดลง 0.10 เมื่อเปรียบเทียบกับ VGG19



ภาพประกอบ 17 แสดงค่าความแม่นยำ (ซ้าย) และค่าความสูญเสีย (ขวา) ของแบบจำลองที่นำเสนอ

	ปกติ (Normal)	โรคปอดบวม (Pneumonia)
ปกติ (Normal)	420	8
โรคปอดบวม (Pneumonia)	10	418

ภาพประกอบ 18 แสดง Confusion Matrix ของแบบจำลองที่นำเสนอ



ภาพประกอบ 19 โครงสร้างแบบจำลองของแบบจำลองที่นำเสนอ

5. อภิปรายผล (Discussion)

การทดลองได้แบ่งออกเป็น 2 กลุ่ม กลุ่มที่ 1 การทดลองโดยใช้สถาปัตยกรรม VGG16 และ VGG19 โดยที่ไม่มีการปรับแต่งใดๆ และกลุ่มที่ 2 นำสถาปัตยกรรม VGG16 และ VGG19 มาใช้โดยการถ่ายโอนความรู้และปรับแต่งชั้น Fully connected (FC) 6 รูปแบบเพื่อให้เห็นความแตกต่างของของแบบจำลองที่ไม่ได้มีการปรับแต่งค่าใดๆ ในกลุ่มที่ 1 และที่มีการปรับแต่งค่าของแบบจำลองในกลุ่มที่ 2 นั้นแสดงให้เห็นว่าการปรับแต่งในชั้น Fully Connected สามารถเพิ่มประสิทธิภาพและความแม่นยำในการพยากรณ์โรคปอดบวมเพิ่มมากขึ้นจากแบบจำลองตั้งต้น ในแต่ละรูปแบบของการทดลองในกลุ่มที่ 2 ให้ผลที่ไม่แตกต่างกันมากนักเนื่องจากการใช้เทคนิคการถ่ายโอนความรู้ที่มีประสิทธิภาพพอสมควรอยู่แล้ว ทำให้การปรับแต่งในชั้น Fully Connected ไม่ได้มีผลความแม่นยำที่เพิ่มขึ้นอย่างมีนัยสำคัญ ถึงอย่างนั้น การทดลองในการปรับแต่งทั้ง 6 รูปแบบ โดยชุดข้อมูลมีจำนวนภาพทั้งหมด 8,546 ภาพ ทำการแบ่งจำนวนข้อมูลสำหรับการสร้างการเรียนรู้ของแบบจำลองเป็น Training set ร้อยละ 70 จำนวน 2,991 ภาพ Validation Set ร้อยละ 20 จำนวน 854 ภาพ Test Set ร้อยละ 10 จำนวน 428 ภาพ ของแต่ละกลุ่มข้อมูล และมีการทำ k-fold Cross-Validation (K=5) โดยใช้การจัดกลุ่มข้อมูลจากการสุ่มให้เป็นชุดข้อมูลใหม่

ทั้ง 5 กลุ่ม สามารถนำมาใช้เป็นแนวทางในการพัฒนาแบบจำลองทั้งในส่วนของการปรับแต่งชั้น Features Extraction รวมทั้ง Fully Connected ที่ปรับแต่งในการทดลองนี้ได้และผลจากการทดลอง เมื่อนำแบบจำลองที่นำเสนอและได้ความแม่นยำมากที่สุดนั้นได้ค่าความแม่นยำมากที่สุดคือ 97.83 และค่าความสูญเสีย 0.11 และค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) มีการกระจายตัวที่ 0.004 ส่วนค่าเฉลี่ย (Average) ของค่าความแม่นยำคือ 97.61 ของค่าความสูญเสียคือ 0.09 อีกทั้งเมื่อนำค่าความแม่นยำมาเปรียบเทียบกับค่าเฉลี่ยความแม่นยำแล้วมีความแตกต่างไม่มากนักคือ 0.22 การนำผลมาเปรียบเทียบกับกับผลการทดลองของแบบจำลองต่างๆ จากบทความอื่นๆ จากตาราง 9 แสดงให้เห็นว่าวิธีการและรูปแบบที่นำมาใช้ในการทดลองมีประสิทธิภาพสามารถเพิ่มความแม่นยำให้กับแบบจำลองได้และสามารถนำไปใช้ในการตรวจหาโรคและคัดกรองผู้ป่วยได้

6. สรุปผลการวิจัย (Conclusion)

ผลการทดลองในบทความนี้ชี้ให้เห็นว่าสามารถนำแบบจำลองที่พัฒนาขึ้นไปใช้ในการตรวจหาโรคปอดบวมจากภาพเอ็กซเรย์ทรวงอกเบื้องต้นได้ก่อนให้แพทย์วินิจฉัยอย่างละเอียดอีกครั้งเพื่อลดการทำงานของบุคลากรที่เกี่ยวข้อง โดยที่แบบจำลองที่ได้พัฒนาขึ้นมีความแม่นยำร้อยละ 97.83 ซึ่งแบบจำลอง

ที่นำเสนอสามารถนำมาใช้วินิจฉัยโรคปอดบวมและลดอัตราการเสียชีวิตในเด็กและผู้สูงอายุได้ แต่เนื่องด้วยการใช้งานจริงภายใต้ความเสี่ยงของการวินิจฉัยโรคการนำไปใช้งานควรให้แพทย์เป็นผู้ยืนยันผลและวินิจฉัยเพิ่มเติมให้มีความแม่นยำและถูกต้องอีกครั้งเพื่อป้องกันความผิดพลาดที่จะกระทบต่อผู้ป่วย

ข้อเสนอแนะ ในการทดลองนี้จะเห็นได้ว่าชุดข้อมูลมีข้อจำกัด ซึ่งมีเพียง 5,232 ภาพ แบ่งออกเป็นภาพที่บ่งบอกว่าปกติ (Normal) จำนวน 1,583 ภาพและที่บ่งบอกว่าไม่ปกติหรือเป็นโรคปอดบวม (Pneumonia) จำนวน 4,273 ภาพ ซึ่งผู้วิจัยมีความเห็นว่าไม่เพียงพอต่อการนำมาใช้ในการเรียนรู้ของแบบจำลอง เพื่อวัตถุประสงค์ของการใช้งานจริงถึงแม้จะใช้เทคนิคในการเพิ่มข้อมูลและให้วิธีการถ่ายโอนความรู้แล้วนั้น ผู้วิจัยจึงเสนอแนะให้มีการนำชุดข้อมูลจากภาพเอกซเรย์ทรวงอกจากชุดข้อมูลอื่นๆ ที่เป็นโรคอื่นๆ เข้ามาร่วมด้วยเพื่อให้ปริมาณข้อมูลและความหลากหลายของข้อมูลมากขึ้น

เอกสารอ้างอิง

- Cherdsom, P., & Kanarkard, W. (2023). Analysis of student engagement in online classroom using convolutional neural networks (CNN). *ECTI Transaction on Application Research and Development*, 3(3), 39-52. <https://doi.org/10.37936/ectiard.2023-3-3.250499> [In Thai]
- Chiwariro, R., & Wosowei, J. B. (2023). comparative analysis of deep learning convolutional neural networks based on transfer learning for pneumonia detection. *International Journal for Research in Applied Science and Engineering Technology*, 11(1), 1161–1170. <https://doi.org/10.22214/ijraset.2023.48685>
- Chouhan, V., Singh, S. K., Khamparia, A., Gupta, D., Tiwari, P., Moreira, C., Damaševičius, R., & de Albuquerque, V. H. C. (2020). A novel transfer learning based approach for pneumonia detection in chest X-ray images. *Applied Sciences*, 10(2), 559. <https://doi.org/10.3390/app10020559>
- Department of Disease Control. (2022). *Pneumonia*. Retrieved 6 December 2023, from https://ddc.moph.go.th/disease_detail.php?d=21 [In Thai]
- Department of Disease Control. (2023). *prevention of diseases and health hazards during the winter season in Thailand, 2023*. Retrieved 6 December 2023, from <https://ddc.moph.go.th/uploads/publish/1501520231123052757.pdf> [In Thai]
- Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A review of deep transfer learning and recent advancements. *Technologies*, 11(2), 40. <https://doi.org/10.3390/technologies11020040>
- Karen, S. & Andrew, Z. (2015). *very deep convolutional networks for large-scale image recognition*. The International Conference on Learning Representations (ICLR). <https://doi.org/10.48550/arXiv.1409.1556>

- Kermany, D., Zhang, K., & Goldbaum, M. (2018). *Labeled optical coherence tomography (OCT) and chest X-ray images for classification* [Data set]. Mendeley Data. <https://data.mendeley.com/datasets/rscbjbr9sj/2>
- Mabrouk, A., Díaz Redondo, R. P., Dahou, A., Abd Elaziz, M., & Kayed, M. (2022). Pneumonia detection on chest X-ray images using ensemble of deep convolutional neural networks. *Applied Sciences*, 12(13), 6448. <https://doi.org/10.3390/app12136448>
- Papadimitriou, O., Kanavos, A., & Maragoudakis, M. (2023). automated pneumonia detection from chest X-ray images using deep convolutional neural networks. *2023 14th International Conference on Information, Intelligence, Systems & Applications (IISA)*, 1–4. <https://doi.org/10.1109/iisa59645.2023.10345859>
- Racic, L., Popovic, T., Cakic, S., & Sandi, S. (2021). pneumonia detection using deep learning based on convolutional neural network. *2021 25th International Conference on Information Technology (IT)*, 1–4. <https://doi.org/10.1109/it51528.2021.9390137>
- Sengupta, S., Basak, S., Saikia, P., Paul, S., Tsalavoutis, V., Atiah, F., Ravi, V., & Peters, A. (2020). A review of deep learning with special emphasis on architectures, applications and recent trends. *Knowledge-Based Systems*, 194, 105596. <https://doi.org/10.1016/j.knosys.2020.105596>
- Shankar, A. P., Shah, S., Ghosh, S., Ismail, Z., M, V., J, J., & S, D. (2023). Comparative performance analysis of machine learning and deep learning techniques in pneumonia detection: A study. *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1–8. <https://doi.org/10.1109/iccncnt56998.2023.10306711>
- Singh, S., Kumar, M., Kumar, A., Verma, B. K., & Shitharth, S. (2023a). Pneumonia detection with QCSA network on chest X-ray. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-35922-x>
- Singh, S., Singh Rawat, S., Gupta, M., K. Tripathi, B., Alanzi, F., Majumdar, A., Khuwuthyakorn, P., & Thinnukool, O. (2023b). Deep attention network for pneumonia detection using chest X-ray images. *Computers, Materials & Continua*, 74(1), 1673–1691. <https://doi.org/10.32604/cmc.2023.032364>

Varshni, D., Thakral, K., Agarwal, L., Nijhawan, R., & Mittal, A. (2019). Pneumonia detection using CNN based feature extraction. *2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)*, 1–7. <https://doi.org/10.1109/icecct.2019.8869364>

Zhang, D., Ren, F., Li, Y., Na, L., & Ma, Y. (2021). pneumonia detection from chest X-ray images based on convolutional neural network. *Electronics*, 10(13), 1512. <https://doi.org/10.3390/electronics10131512>