

การเพิ่มประสิทธิภาพการจำแนกโรคปอดจากภาพถ่ายรังสีทรวงอก
ด้วยเทคนิค Encoder-Decoder

ไชยยันต์ ชะโกทอง

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมข้อมูลขนาดใหญ่
วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์
มหาวิทยาลัยธุรกิจบัณฑิต
ปีการศึกษา 2564

**AN ENCODER-DECODER BASED APPROACH FOR ENHANCING
PERFORMANCE OF CHEST X-RAY CLASSIFICATION**

CHAIYAN SHAGOTONG

**A Thesis Submitted in Partial Fulfillment of the Requirements
For the Degree of Master of Big Data Engineering
College of innovative Technology and Engineering,
Dhurakij Pundit University
Academic Year 2021**



ใบรับรองงานวิทยานิพนธ์

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิต
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต

หัวข้อวิทยานิพนธ์ การเพิ่มประสิทธิภาพการจำแนกโรคปอดจากภาพถ่ายรังสีทรวงอก
 ด้วยเทคนิค Encoder-Decoder
เสนอโดย ไชยยันต์ ชะโกทอง
สาขาวิชา วิศวกรรมข้อมูลขนาดใหญ่
อาจารย์ที่ปรึกษาสารนิพนธ์ ดร.ธนภัทร นังคะจิตร

ได้พิจารณาเห็นชอบโดยคณะกรรมการสอบวิทยานิพนธ์แล้ว


..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.กฤษณะ ไวยมัย)


..... กรรมการและอาจารย์ที่ปรึกษา
(ดร.ธนภัทร นังคะจิตร)


..... กรรมการ
(ดร.สรวรพฤกษ์ มฤคทัต)


..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ดวงใจ จิตกงชื่น)

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์รับรองแล้ว


.....
(ดร.ชัยพร เขมะภาคะพันธ์)

คณบดีวิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์
วันที่ 30 เดือน พฤศจิกายน พ.ศ. 2564

ชื่อวิทยานิพนธ์	การเพิ่มประสิทธิภาพการจำแนกโรคปอดจากภาพถ่ายรังสี ทรวงอกด้วยเทคนิค Encoder - Decoder
เสนอ โดย	ไชยยันต์ ชะโกทอง
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ดร.ชนภัทร พังคะจิตร
สาขาวิชา	วิศวกรรมข้อมูลขนาดใหญ่
ปีการศึกษา	2564

บทคัดย่อ

การวินิจฉัยโรคปอดจากภาพถ่ายรังสีทรวงอก (*Chest X-ray*) ถือเป็นหนึ่งในปัญหาที่สำคัญทางด้านคอมพิวเตอร์วิทัศน์ เนื่องจากมีปริมาณภาพถ่ายรังสีในบริเวณนี้มากกว่าบริเวณอื่นของร่างกาย ปัจจุบันพบว่าการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (*Deep Learning*) ขั้นสูง เพื่อสร้างแบบจำลองทำนายโรคปอดจากภาพถ่ายรังสีทรวงอกที่มีความแม่นยำในการทำนายเป็นที่น่าพึงพอใจ อย่างไรก็ตาม คุณภาพของภาพถ่ายรังสีทรวงอกที่นำเข้าถือเป็นปัจจัยที่มีความสำคัญในการเรียนรู้รูปแบบการเกิดโรคของเทคนิคการเรียนรู้เชิงลึก ในงานวิจัยนี้จึงเสนอวิธีการเลือกเฉพาะภาพถ่ายรังสีทรวงอกที่มีคุณภาพดี(การคัดกรองภาพผิดปกติ) และใช้เพื่อสกัดคุณลักษณะที่สำคัญ (*Latent Feature*) โดยใช้เทคนิค *Encoder-Decoder* เพื่อนำไปสร้างแบบจำลองการจำแนกโรคอย่างมีประสิทธิภาพ โดยที่ทุกโรคจะต้องทำการคัดกรองภาพที่ผิดปกติออกโดยพิจารณาจากค่าความแตกต่างของภาพที่สร้างขึ้นใหม่กับภาพเดิม (*Reconstruction Error*) ที่สูง หรือ ต่ำ อย่างมีนัยสำคัญจากเทคนิค *Encoder - Decoder* จากนั้นจึงใช้เฉพาะรูปภาพที่ดีเป็นภาพนำเข้าเพื่อสร้างแบบจำลองสำหรับการจำแนก การเป็นโรคนั้นหรือไม่เป็นโรค สุดท้าย คุณลักษณะของโรคที่สกัดออกมาได้จากขั้นตอนการสร้างแบบจำลองสำหรับแต่ละโรค นำมารวมกันแล้วสร้างโมเดลเพื่อการจำแนกโรค 14 ชนิด และที่ไม่เป็นโรค ผลการทดลองแสดงให้เห็นว่าวิธีการที่นำเสนอได้ ค่าประสิทธิภาพความแม่นยำแบบ *AUROC* เท่ากับ 0.69 ซึ่งสูงกว่าวิธีการ *Ensemble* แบบจำลองสำหรับแต่ละโรค ($AUROC = 0.54$) อย่างไรก็ตาม วิธีการที่นำเสนอให้ประสิทธิภาพน้อยกว่าแบบจำลอง *DenseNet121* ที่ใช้เฉพาะภาพที่ดีในการจำแนกประเภทโรค ($AUROC = 0.75$) สาเหตุหลักคือปัญหาข้อมูลที่ไม่สมดุล (*Imbalance Data*) ที่เกิดขึ้นระหว่างขั้นตอนการสร้างแบบจำลองสำหรับแต่ละโรค ซึ่งเมื่อพิจารณาปัญหานี้แล้วแนวทางที่นำเสนอในงานวิจัยนี้ก็จะสามารถเพิ่มประสิทธิภาพให้สูงขึ้นได้อีก

Thesis Title	AN ENCODER – DECODER BASED APPROACH FOR ENHANCING PERFORMANCE OF CHEST X-RAY CLASSIFICATION
Auhor	Chaiyan Shagotong
Thesis Advisor	Dr.Thanapat Kangkachit
Department	Big Data Engineering
Academic Year	2021

ABSTRACT

Pneumonia classification using chest X-Ray images is one of the most crucial problems in computer vision because the chest was filmed more frequently than the other organs. Regarding advanced deep learning techniques, constructed classification models produce satisfying accuracy. The quality of input images is an essential factor that affected the ability to learn patterns of deep learning-based models. This work presents the methodologies based on the encoder-decoder techniques to choose only good-quality images (i.e. filter outlier images) and use them to extract latent features to build effective classifiers. For each disease, we filtered the outlier images by considering the significantly high or low reconstruction error value (RE) resulting from the encoder-decoder model. Then, only good-quality images were used as input data to construct a binary classifier for each disease. Finally, the latent features extracted from each binary classifier were concatenated to build the classifier of 14 disease and no-findings images. Experimental results showed that our approach produced an AUROC score of 0.69, higher than the Ensemble of binary classifiers (0.54 AUROC). However, our approach yields less performance than the DenseNet121 classifier trained on good quality images (0.75 AUROC). The main reason is the imbalanced data problem that occurred during the building binary classifiers phase. By taking this problem into account, our approach is capable of further obtaining higher performance.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปด้วยดี ด้วยความอนุเคราะห์อย่างยิ่งจากอาจารย์หลายๆท่าน โดยผู้เขียน ขอกราบขอบพระคุณ อ.ดร.ชนภัทร ฆังคะจิตร อาจารย์ที่ปรึกษาการทำวิทยานิพนธ์ฉบับนี้ นอกจากนี้ขอกราบขอบพระคุณ รศ.ดร.กฤษณะ ไวยมัย ประธานกรรมการ และคณะกรรมการอันประกอบด้วย ดร.สรรพฤทธิ์ มฤคทัต , ผศ.ดร.ดวงใจ จิตคงชื่น ที่กรุณาให้ความรู้และข้อเสนอแนะที่มีประโยชน์จนทำให้วิทยานิพนธ์สำเร็จได้อย่างสมบูรณ์

ขอกราบขอบพระคุณ อาจารย์ภาควิชาวิศวกรรมข้อมูลขนาดใหญ่ทุกท่าน ที่ได้อบรมสั่งสอน และมอบความรู้อันเป็นประโยชน์อย่างยิ่งในการนำไปใช้ให้เกิดประโยชน์ต่อไปและขอบคุณเจ้าหน้าที่ภาควิชาวิศวกรรมข้อมูลขนาดใหญ่ทุกท่าน ที่ได้ให้ความช่วยเหลือ และคำแนะนำต่างๆ

ด้วยความดีหรือประโยชน์อันใดที่ได้จากผลงานวิทยานิพนธ์ฉบับนี้ ขอมอบให้แก่ คุณพ่อ คุณแม่ และครอบครัวที่ทำให้กำลังใจ ความหวังใจ และความช่วยเหลือ ให้การศึกษาของผู้เขียน ประสบความสำเร็จ ผู้เขียนขอขอบคุณทุกๆท่าน มา ณ โอกาสนี้

ไชยยันต์ ชะโกทอง

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ฅ
บทคัดย่อภาษาอังกฤษ	ง
กิตติกรรมประกาศ	จ
สารบัญตาราง	ช
สารบัญภาพ	ฉ
บทที่	
1. บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	3
1.3 ประโยชน์ที่คาดว่าจะได้รับ	3
1.4 ขอบเขตการวิจัย.....	3
2. แนวคิด ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง.....	4
2.1 บทนำ.....	4
2.2 ลักษณะอาการของโรค 14 โรค ที่ตรวจสอบได้จากภาพถ่ายรังสีทรวงอก.....	4
2.3 ลักษณะภาพรังสีทรวงอก (Chest X-ray) ที่ผิดปกติ	13
2.4 แนวคิดและทฤษฎีที่เกี่ยวข้อง.....	15
2.5 งานวิจัยที่เกี่ยวข้องกับประเด็นปัญหา.....	23
3. ระเบียบวิธีวิจัย	28
3.1 ขั้นตอนที่ 1 คัดกรองภาพที่เป็น Outlier (Step 1 : Filter Outlier Images)	28
3.2 ขั้นตอนที่ 2 สร้างโมเดลเพื่อจำแนกภาพเป็นโรค หรือ ไม่เป็นโรค (Step 2 : Classify Finding / No Finding).....	31
3.3 ขั้นตอนที่ 3 สร้างโมเดลเพื่อจำแนกภาพที่เป็นโรค 14 โรค และไม่เป็นโรค (Step 3 : Classify 15 Classes for 14 Finding and No Finding).....	32
4. ผลการทดลอง.....	38
4.1 การเตรียมการทดลอง (Experimental Setup).....	38
4.2 ผลการคัดกรองภาพในขั้นตอนที่ 1.....	39

สารบัญ (ต่อ)

	หน้า
4.3 ผลการทำนายภาพประเภท Finding / No Finding ในขั้นตอนที่ 2	40
4.4 ผลจากการจำแนกโรคปอด ในขั้นตอนที่ 3	42
5. สรุปผลการทดลอง	49
5.1 สรุปผลการทดลอง	49
5.2 ข้อเสนอแนะ.....	50
บรรณานุกรม.....	51
ภาคผนวก.....	54
ประวัติผู้เขียน.....	62

สารบัญตาราง

ตารางที่	หน้า
2.1 แสดงเปรียบเทียบผลลัพธ์ ค่าความแม่นยำ AUROC จาก โมเดล CheXNet กับโมเดล ของ Wang และ Yao	25
4.1 แสดงรายชื่อโรค และจำนวนภาพถ่ายรังสีทรวงอกของแต่ละโรคที่ได้จากชุดฐานข้อมูล ChestX-ray14	38
4.2 แสดงจำนวนภาพถ่ายรังสีทรวงอกของแต่ละโรคที่ผ่านการคัดกรองในขั้นตอนที่ 1 จะได้ภาพที่ดี (Good Images) กับ ภาพผิดปกติ (Outlier Image)...	39
4.3 แสดงค่า AUROC จาก โมเดลแบบ Ensemble ในช่วงแรก	44
4.4 แสดงค่า AUROC ของชุดทดสอบ Test-1 และ Test-2 จาก 3 โมเดล ในขั้นตอนที่ 3 ทำนาย 15 classes	46
4.5 แสดงค่า AUROC ของชุดทดสอบที่ 1 (Test-1:20%Good Images) เปรียบเทียบกับ โมเดล CheXNet (2017) และ ChestNet (2018).....	48
5.1 แสดงค่าวัดประสิทธิภาพ AUROC ของโมเดลจำแนกภาพเป็น โรคและไม่เป็นโรค.....	49
5.2 แสดงค่าวัดประสิทธิภาพ AUROC ของโมเดลจำแนกโรคปอด.....	50

สารบัญภาพ

ภาพที่	หน้า
2.1 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีอาการปอดแฟบ (Atelectasis).....	5
2.2 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่เป็นโรคหัวใจโต (Cardiomegaly)..	5
2.3 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Consolidation	6
2.4 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pulmonary-Edema	6
2.5 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pleural Effusion	7
2.6 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Emphysema.....	8
2.7 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Fibrosis	8
2.8 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Lung Hernia	9
2.9 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Infiltration Lung.....	10
2.10 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Mass และ Nodule	11
2.11 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pleural Thickening ...	11
2.12 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pneumonia	12
2.13 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pneumothorax	13
2.14 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกที่รับแสงรังสี X-ray น้อยไป หรือ มากไป	14
2.15 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกที่เกิดจากผู้ป่วยยื่นหมอนตัวไปทางด้านข้าง	14
2.16 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกที่เกิดจากผู้ป่วยหายใจไม่ลึกพอในขณะที่ ถ่ายภาพ.....	15
2.17 แสดงชั้น (Layer) ของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN)	16
2.18 แสดงการคูณเมตริกซ์ในชั้นของ Convolution Layer	17
2.19 แสดง Convolution Layer + ReLu	18
2.20 แสดงการลดขนาดรูปภาพในชั้น Pooling Layer	18
2.21 แสดงการทำ Flattening ได้เป็นค่า pixel ใน 1 คอลัมน์	19
2.22 แสดงชั้น Fully Connected Layer	20
2.23 แสดงภาพรวมของสถาปัตยกรรม Convolutional Neural Networks (CNN)...	20
2.24 แสดงสถาปัตยกรรมของ DenseNet121 ประกอบด้วย 5 Layer dense block ..	21

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
2.25 แสดงภาพรวมของสถาปัตยกรรม Encoder-Decoder.....	22
2.26 แสดงภาพถ่ายรังสีทรวงอก 8 ชนิดโรค.....	24
2.27 แสดงแบบจำลอง DCNN ของ Xiaosong Wang และ คณะ.....	24
2.28 แสดงแบบจำลอง ChestNet ของ Hongyu Wang และ Yong Xia.....	26
2.29 แสดงภาพแบบจำลองในการศึกษาของ Zhicheng Huang, Dongmeu Fu.....	26
3.1 แสดงแผนผังแนวคิดสร้างแบบจำลองประกอบด้วย 3 ชั้นตอนหลัก.....	28
3.2 แสดงแผนผังการคัดกรองภาพ Outlier.....	29
3.3 แสดงสำหรับโมเดล แบบ Encoder-Decoder.....	29
3.4 แสดงผลจากโมเดล Encoder-Decoder ในรูปแบบของ Box Plot ของแต่ละโรค.....	30
3.5 แสดงแผนผังในขั้นตอนที่ 2 (Step 2 : Classify Finding / No Finding).....	31
3.6 แสดงสถาปัตยกรรมโมเดล CNN-DenseNet121 + Fully Connection.....	31
3.7 แสดงแผนผังในขั้นตอนที่ 3.1 เป็นโมเดลที่สร้างจาก CNN-DenseNet 121.....	33
3.8 แสดงสถาปัตยกรรมโมเดล CNN-DenseNet+Fully Connection สำหรับ 15 Classes.....	33
3.9 แสดงแผนผังในขั้นตอนที่ 3.2 เป็นโมเดล แบบ Ensemble.....	34
3.10 แสดงแผนผังในการสร้างโมเดล แบบ Ensemble ด้วยวิธี Encoder และต่อด้วย Fully Connection.....	35
3.11 แสดงแผนผังในขั้นตอนที่ 3.3 เป็นโมเดล แบบ Multi-heads.....	36
3.12 แสดงแผนผังในการสร้างโมเดล แบบ Multi-Heads.....	37
4.1 แสดงผลการวัดค่า AUROC จากโมเดลที่สร้างจากข้อมูลชุดภาพที่ดี (Good Images).....	40
4.2 แสดงผลการวัดค่า AUROC จากโมเดลที่สร้างจากข้อมูลชุดภาพทั้งหมดที่เป็นโรคและไม่เป็นโรค.....	41

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.3 แสดงผลการวัดค่า AUROC จากโมเดล แบบ Ensemble ในช่วงแรก ทำนาย 2 Classes.....	42
4.4 แสดงผลการวัดค่า AUROC 15 Classes จากโมเดลที่สร้างโดยวิธี CNN-DenseNet 121.....	45
4.5 แสดงผลการวัดค่า AUROC 15 Classes จากโมเดลที่สร้างโดยวิธี Ensemble...	45
4.6 แสดงผลการวัดค่า AUROC 15 Classes จากโมเดลที่สร้างโดยวิธี Multi-heads	45

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ปัจจุบันในทางการแพทย์ยังมีความจำเป็นที่ต้องใช้ภาพถ่ายรังสีทรวงอก (Chest X-ray) เพื่อพิจารณาการเกิดโรคที่บริเวณปอดอยู่ตลอดเวลาและมีจำนวนมากกว่าภาพถ่ายรังสีในบริเวณอื่นๆ ของร่างกาย การอ่านเพื่อแปลความหมายจากภาพถ่ายรังสีทรวงอกให้มีความแม่นยำได้นั้น จะต้องดำเนินการโดยนักรังสีการแพทย์ที่มีความรู้และประสบการณ์ในการอ่านภาพถ่ายรังสีทรวงอกมานาน องค์การอนามัยโลกได้ระบุว่าในประเทศที่ด้อยพัฒนา มักจะขาดแคลนนักรังสีการแพทย์อยู่มากทำให้เกิดปัญหาในการรักษาผู้ป่วยอย่างมีประสิทธิภาพ นอกจากนี้การอ่านภาพถ่ายรังสีทรวงอกของนักรังสีการแพทย์ที่มีประสบการณ์ก็ยังพบข้อผิดพลาดอยู่เสมอ โดยเฉพาะบางกรณีที่มีความยากในการจำแนกการเกิดโรคที่ภาพถ่ายรังสีทรวงอก เช่นการเกิด Interstitial Infiltrate ที่นักรังสีการแพทย์อ่านจากภาพถ่ายรังสีทรวงอกได้ไม่เหมือนกัน (Mark I Neurman และคณะ 2012) เป็นต้น

ปัจจุบันเทคโนโลยี การวิเคราะห์ข้อมูลขนาดใหญ่ (Big Data Analysis) ได้พัฒนาขึ้นมาก ในปี 2017 Xiaosong Wang, Yifan Peng และคณะ ได้นำเสนองานวิจัยเพื่อสร้างฐานข้อมูลภาพถ่ายรังสีทรวงอก แบบใหม่ที่เรียกว่า “ChestX-ray8” ที่สร้างด้วยแบบจำลองโมเดลที่เรียกว่า Multilabel Deep Convolutional Neural Network(DCNN) Classification โดยใช้ข้อมูลจากคลังข้อมูลภาพถ่ายรังสีทรวงอกของโรงพยาบาลหลายๆแห่ง ที่มีการระบุโรคปอดจากผู้เชี่ยวชาญไว้แล้ว และต่อมา Pranav Raipurkar, Jeremy Irvin และคณะ(2017) ได้พัฒนาฐานข้อมูลภาพถ่ายรังสีทรวงอกขึ้นใหม่มาแทน ChestX-ray8 ที่เรียกว่า “ChestX-ray 14” ที่สร้างจากโมเดลที่เรียกว่า “CheXNet” ประกอบด้วย 121-layer Dense Convolution Network (DenseNet121) และต่อมาก็มีนักวิจัยที่เป็นนักวิทยาศาสตร์ข้อมูล (Data Scientist) อีกหลายๆท่านได้พัฒนาโมเดลเพื่อใช้ทำนายการเกิดโรคปอด จากภาพถ่ายรังสีทรวงอกของผู้ป่วยรายใหม่ อาทิเช่น Hongyu Wang และ Yong

Xia (2018) ได้สร้างโมเดล ที่เรียกว่า ChestNet ที่ประกอบด้วย 2 ส่วน คือ ส่วนที่เรียกว่า Classification Branch และส่วนที่เรียกว่า Attention Branch ซึ่งมีผลการทำนายมีความแม่นยำมากขึ้นกว่า โมเดล CheXNet ดังนั้นในงานวิจัยของนักวิทยาศาสตร์ข้อมูลที่เกี่ยวข้องกับสาขาทางแพทยศาสตร์ ได้ก่อให้เกิดประโยชน์อย่างมากในทางการแพทย์ ที่มีเครื่องมือช่วยในการอ่านและแปลความหมายจากภาพถ่ายรังสีทรวงอกให้มีความแม่นยำมากขึ้น ส่งผลให้การรักษาผู้ป่วยของแพทย์ เป็นไปอย่างถูกต้อง.

ปัจจุบันฐานข้อมูลภาพถ่ายรังสีทรวงอกที่เปิดเผยเป็นสาธารณะและเป็นที่ยอมรับ นำมาสร้างโมเดลได้ ก็คือ ชุดฐานข้อมูลที่เรียกว่า ChestX-ray14. ที่สร้างโดย Pranav Rajpurkar, Jeremy Irvin และคณะ (2017) ซึ่งมีภาพถ่ายรังสีทรวงอก ครอบคลุมโรคที่เกิดในปอดได้ 14 โรคคือ Atelectasis, Cardiomegaly, Consolidation, Edema, Effusion, Emphysema, Fibrosis, Hernia, Infiltration, Mass, Nodule, Pleural Thickening, Pneumonia, Pneumothorax และอีก 1 ชุด ภาพ “No Finding” ที่มีความหมายเป็นภาพรังสีทรวงอกที่ไม่มีลักษณะของ 14 โรคดังกล่าวข้างต้น โดยในบทที่ 2 จะกล่าวถึงลักษณะของภาพถ่ายรังสีทรวงอกของ โรคทั้ง 14 โรคนี้

ในการศึกษาของวิทยานิพนธ์นี้ จะใช้ชุดข้อมูล ChestX-ray 14 ด้วยเช่นกัน โดยเสนอวิธีการเลือกเฉพาะภาพถ่ายรังสีทรวงอกที่มีคุณภาพดี(การคัดกรองภาพผิดปกติ) และใช้เพื่อสกัดคุณลักษณะที่สำคัญ (Latent Feature) โดยใช้เทคนิค Encoder-Decoder เพื่อนำไปสร้างแบบจำลองการจำแนกโรคอย่างมีประสิทธิภาพ ผลการทดลองแสดงให้เห็นว่าวิธีการที่นำเสนอได้ ค่าประสิทธิภาพความแม่นยำสูงกว่าวิธี Ensemble of Binary Classifier อย่างไรก็ตาม วิธีการที่นำเสนอให้ประสิทธิภาพน้อยกว่าโมเดลแบบ DenseNet121 ที่ใช้เฉพาะภาพที่ดีในการจำแนกประเภทโรคสาเหตุหลักคือปัญหาข้อมูลที่ไม่สมดุล (Imbalance Data) ที่เกิดขึ้นระหว่างขั้นตอนการสร้างแบบจำลองสำหรับแต่ละโรค ซึ่งเมื่อพิจารณาปัญหานี้แล้วแนวทางที่นำเสนองานวิจัยนี้ก็จะสามารถเพิ่มประสิทธิภาพให้สูงขึ้นได้อีก.

1.2 วัตถุประสงค์ของการวิจัย

เพิ่มความแม่นยำในการทำนายโรคปอดจากภาพถ่ายรังสีทรวงอก (Chest X-Ray) โดย การคัดกรองภาพที่มีคุณภาพดีสำหรับการสร้าง โมเดลแล้วนำมาสกัด Latent Features ของแต่ละโรคเพื่อใช้ในการสร้างโมเดลที่มีความแม่นยำเพิ่มขึ้นในลำดับต่อไป

1.3 ประโยชน์ที่คาดว่าจะได้รับ

1.3.1 สามารถใช้แบบโมเดล(model) ที่พัฒนาจากการเรียนรู้เชิงลึก (Deep Learning) มาทำการจำแนกประเภทโรค 14 โรค (14 Diseases Classification) และ การไม่พบโรค (NoFinding) ซึ่งรวมเป็นการจำแนก (Classification) ทั้งหมด 15 ประเภท (Class)

1.3.2 สามารถนำโมเดล(model) ที่ได้จากงานวิจัยนี้ ไปช่วยในการอ่านภาพถ่ายรังสีทรวงอกของผู้ป่วยรายใหม่ที่มีอาการของโรค 14 โรคตามงานวิจัยนี้

1.4 ขอบเขตการวิจัย

1.4.1 ใช้ชุดข้อมูล (Dataset) ที่เรียกว่า ChestX-ray 14 ซึ่งเป็นข้อมูลสาธารณะ นำเข้าจาก www.Kaggle.com

1.4.2 ใช้ภาพรังสีทรวงอกที่ระบุชื่อโรคกำกับไว้ 1 โรคต่อ 1 ภาพ

บทที่ 2

แนวคิด ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง

2.1 บทนำ

การวิจัยนี้มีวัตถุประสงค์เพื่อสร้างแบบจำลอง(Model)เพื่อทำนายการเป็นโรค 14 โรคที่เกิดขึ้นในปอดจากภาพถ่ายรังสีทรวงอก (Chest X ray) ที่ได้จากฐานข้อมูลที่มีชื่อว่า ChestXray-14 ที่เป็นชุดข้อมูลสาธารณะ จาก เว็บไซต์ Kaggle.com โดยที่ในบทนี้จะกล่าวถึง ลักษณะอาการของโรค 14 โรคที่จะทำการ ศึกษาวิจัยในครั้งนี้ และจะอธิบายถึงทฤษฎีการใช้ความรู้เชิงลึก (Deep Learning) โดยวิธี Convolutional Neural Network, และวิธี Encoder-Decoder ที่จะนำมาสร้างแบบจำลอง(Model) ในการทำนายโรค 14 โรค และในที่สุดท้ายของบทนี้จะเป็นการรวบรวมข้อสรุปผลงานวิจัยที่เกี่ยวข้อง

2.2 ลักษณะอาการของโรค 14 โรค ที่ตรวจสอบได้จากภาพถ่ายรังสีทรวงอก


2.2.1 Atelectasis อาการปอดแฟบ เป็นภาวะถุงลมในปอดขยายตัวได้ไม่เต็มที่หรือปอดแฟบทำให้ผู้ป่วยไม่สามารถหมุนเวียนก๊าซออกซิเจนและคาร์บอนไดออกไซด์เข้าสู่ถุงลมได้ ส่งผลให้หายใจได้ไม่เต็มที่ หัวใจเต้นเร็ว เจ็บหน้าอก หรือระดับออกซิเจนในเลือดต่ำ (ที่มา://www.pobpad.com/atelectasis) ตัวอย่างภาพถ่ายรังสีทรวงอกที่เป็นโรคปอดแฟบ แสดงตามภาพที่ 2.1



ภาพที่ 2.1 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีอาการปอดแฟบ (Atelectasis)

ที่มา: <https://radiopaedia.org/search> = Atelectasis

2.2.2 Cardiomegaly อาการหัวใจโต เป็นภาวะที่หัวใจมีขนาดใหญ่กว่าปกติ เกิดจากหลากหลายสาเหตุด้วยกัน แต่ส่วนมากเกิดจากภาวะความดันโลหิตสูงหรือโรคหลอดเลือดหัวใจ ซึ่งส่งผลให้หัวใจสูบฉีดเลือดได้ไม่ดีและตามมาด้วยภาวะรุนแรงอย่างหัวใจล้มเหลว ทั้งนี้ ผู้ป่วยหัวใจโตส่วนใหญ่มักได้รับการรักษาในระยะยาวโดยการใช้ยา ภาวะหัวใจโตมักไม่มีอาการอื่น ๆ ปรากฏร่วม แต่หากภาวะหัวใจโตส่งผลให้หัวใจสูบฉีดเลือดได้ไม่ดีพอก็อาจทำให้มีอาการที่แสดงถึงภาวะหัวใจล้มเหลวตามมา บางรายอาจมีอาการเล็กน้อยต่อเนื่องหลายปี หรือบางรายอาจมีอาการหายใจเหนื่อยหอบแย่งลงเรื่อย ๆ (ที่มา://www.pobpad.com/cardiomegaly)



ภาพที่ 2.2 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่เป็นโรคหัวใจโต (Cardiomegaly)

ที่มา: <https://radiopaedia.org/search> = Cardiomegaly


2.2.3 Consolidation ปอดลักษณะเนื้อแข็ง อาจเกิดกลุ่มอาการการหายใจขัดข้องในผู้ใหญ่ (adult respiratory distress syndrome) หากมีการทำลายเซลล์บุถุงลมและหลอดเลือดฝอยในปอดทั่วไปซึ่งมักเกิดจากอันตรายที่รุนแรงฉับพลัน เช่น จากการสูดดมก๊าซ คาร์บอน ปริมาณมาก (ที่มา://www.healthcasethai.com/โรคปอดสิ่งแวดล้อม)



ภาพที่ 2.3 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Consolidation

ที่มา: <https://radiopaedia.org/search> = Consolidation


2.2.4 Edema ปอดบวมน้ำ เป็นภาวะที่เกิดจากการมีของเหลวในถุงลมปอดมากผิดปกติ ส่งผลให้ผู้ป่วยหายใจลำบากหรือหายใจไม่อิ่มเนื่องจากขาดออกซิเจน โดยเกิดขึ้นได้จากหลายสาเหตุ เช่น หัวใจผิดปกติ ปอดบวมติดเชื้อ สัมผัสกับสารพิษหรือการใช้ยาบางชนิด เป็นต้น



ภาพที่ 2.4 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pulmonary-Edema

ที่มา: <https://radiopaedia.org/search> = Edema

2.2.5 Effusion ภาวะน้ำในช่องเยื่อหุ้มปอด คือภาวะที่มีของเหลวปริมาณมากเกินไปใน พื้นที่ระหว่างเยื่อหุ้มปอดและเยื่อหุ้มช่องอก โดยปริมาณน้ำที่มากขึ้นจะไปกดทับปอด ส่งผลให้ ปอดขยายตัวได้ไม่เต็มที่ ผู้ป่วยภาวะนี้มีอาการ โดยทั่วไปคือ ไอ เจ็บหน้าอก หายใจลำบาก หรือรู้สึก เจ็บขณะหายใจ โดยปกติภายในช่องว่างระหว่างเยื่อหุ้มปอดและเยื่อหุ้มช่องอกจะมีของเหลวอยู่ใน ปริมาณเล็กน้อย เพื่อป้องกันไม่ให้ปอดเสียดสีกับช่องอกขณะเกิดการขยายตัวในกระบวนการ หายใจ แต่หากของเหลวนี้นี้มีปริมาณมากเกินไปจะทำให้เกิดเป็น Pleural Effusion (ที่มา://www.pobpad.com/pleural-effusion)



ภาพที่ 2.5 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pleural Effusion

ที่มา: <https://radiopaedia.org/search> = Effusion

2.2.6 Emphysema ถุงลมโป่งพอง เป็นโรคที่อยู่ในกลุ่มของโรคปอดอุดกั้นเรื้อรัง (Chronic Obstructive Pulmonary Disease: COPD) เกิดจากการอักเสบและแตกของเนื้อปอดที่บริเวณถุงลม ปอด ทำให้เนื้อปอดมีถุงลมเล็ก ๆ มากมายคล้ายฟององุ่น และรวมกับถุงลมที่อยู่ติดกันจนกลายเป็น ถุงลมขนาดใหญ่ ทำให้มีพื้นที่ผิวในการแลกเปลี่ยนออกซิเจนในปอดลดลงหรือมีอากาศค้างในปอด มากกว่าปกติ ซึ่งหากเกิดความผิดปกติมากขึ้นก็จะทำให้ผู้ป่วยถุงลม โป่งพองมีอาการผิดปกติ คือมี อาการหายใจสั้น โดยสถานการณ์ปัจจุบันของถุงลมโป่งพองในประเทศไทย มีแนวโน้มสูงขึ้น ตามลำดับเช่นเดียวกับทั่วโลก และเป็นหนึ่งในสาเหตุของการเสียชีวิตลำดับต้น ๆ ของประชากร (ที่มา://www.pobpad.com/ถุงลมโป่งพอง)



ภาพที่ 2.6 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Emphysema

ที่มา: <https://radiopaedia.org/search> = Emphysema

2.2.7 Fibrosis โรคพังผืดสะสมในปอดโดยไม่ทราบสาเหตุ เป็นภาวะสุขภาพเรื้อรังที่ปอดเนื่องจากบาดแผลและทำให้หายใจได้ลำบากขึ้น ยังไม่ทราบว่าอะไรเป็นสาเหตุที่ทำให้เกิดภาวะนี้ขึ้น แต่ก็ เป็นภาวะที่มักเกิดกับผู้ที่อายุ 70-75 ปี และหายากที่จะเกิดกับผู้ที่อายุต่ำกว่า 50 ปี อาการของโรคมักจะเกิดขึ้นอย่างค่อยเป็นค่อยไปอย่างช้าๆ โดยมีอาการดังต่อไปนี้ หายใจติดขัด, ไอแห้งเรื้อรัง, เหน็ดเหนื่อย, ผู้ป่วยหลายรายมักจะไม่นสนใจอาการหายใจติดขัดในช่วงแรก และอาจจะคิดว่าเป็นเพราะการแก่ตัวลงหรืออ้วนขึ้น แต่ระยะหลังๆ จะเริ่มมีอาการนี้ขึ้นแม้จะทำกิจกรรมเบาๆ อย่างการแต่งตัว หรือแม้แต่อาบน้ำ. (ที่มา:// www.honestdocs.com/the-idiopathic-pulmonary-fibrosis)




ภาพที่ 2.7 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Fibrosis

ที่มา: <https://radiopaedia.org/search> = fibrosis

2.2.8 Hernia โรคปอดเคลื่อน หมายถึงส่วนหนึ่งของปอดที่ผ่านกรีกษาคหรือโป่งผ่านจุดที่อ่อนแอในผนังหน้าอกทางเดินคอหรือไคอะแฟรม อาการป่วยของโรคนี้เกิดขึ้นตามธรรมชาติโดยกำเนิดนั้น เกิดขึ้นน้อยครั้งมาก น้อยกว่าหนึ่งในห้าตามที่มีรายงาน คนส่วนใหญ่ที่มีอาการปอดเคลื่อนมาจากการได้รับบาดเจ็บสาหัสเช่นอุบัติเหตุรถชน หน้าอกได้รับบาดเจ็บ ปอดเคลื่อนด้วยตัวเองไม่ได้เป็นอันตรายถึงชีวิต และค่อนข้างง่ายต่อการค้นหาวินิจฉัย

(ที่มา: www.urmc.rochester.edu/encyclpedis/content.aspx?contenttypeid=22&contentid=lunghernia)

ia)



ภาพที่ 2.8 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Lung Hernia

ที่มา: <https://radiopaedia.org/search> = Lunghernia

2.2.9 Infiltration รอยฝ้าที่ปอด ที่การวินิจฉัยแยกโรคตามลำดับ โอกาสที่จะเป็นมากไปน้อย คือ การติดเชื้อเฉียบพลันในปอดจากแบคทีเรียหรือไวรัส, การสำลักสิ่งแปลกปลอมเข้าปอด (กรณีอยู่ปอดส่วนล่าง), วัณโรคปอด, มะเร็งปอด, โรคทางระบบร่างกายอื่นๆที่พบน้อย เช่น โรคของเนื้อเยื่อเกี่ยวพัน โรคภูมิแพ้ เป็นต้น

(ที่มา ://www.visitdrsant.blogspot.com/2012/10/infiltration-ct.html)



ภาพที่ 2.9 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Infiltration Lung


ที่มา: <https://radiopaedia.org/search> = Infiltration

2.2.10 Mass เป็นลักษณะก้อนเนื้อที่ปรากฏในปอด มีขนาด มากกว่า 3 เซนติเมตร ที่มีโอกาสเป็นมะเร็งปอดประมาณ 90% (ที่มา: เอกสาร การอบรมวิชาการระยะสั้น สมาคมศัลยแพทย์ทรวงอกประเทศไทย)

2.2.11 Nodule เป็นลักษณะก้อนเนื้อที่ปรากฏในปอด มีขนาดเล็กกว่า 3 เซนติเมตร โดยมีโอกาสเป็น มะเร็งปอดได้ตามขนาด ของ Nodule ดังนี้

- ถ้า Nodule ขนาด < 5 มิลลิเมตร โอกาสเป็นมะเร็ง ประมาณ 0.1%
- ถ้า Nodule ขนาด 5-10 5 มิลลิเมตร โอกาสเป็นมะเร็ง ประมาณ 6-28%
- ถ้า Nodule ขนาด > 2 เซนติเมตร โอกาสเป็นมะเร็ง ประมาณ 64-85%

(ที่มา: เอกสาร การอบรมวิชาการระยะสั้น สมาคมศัลยแพทย์ทรวงอกประเทศไทย)



ภาพที่ 2.10 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Masses และ Nodule

ที่มา: <https://radiologyassistant.nl/chest/chest-x-ray-lung-disease>

2.2.12 Pleural Thickening เยื่อหุ้มปอดหนาเป็น โรคที่เกี่ยวข้องกับแร่ใยหินซึ่งตามชื่อมีความหมายทำให้เยื่อหุ้มปอดหนาขึ้นด้วยเนื้อเยื่อแผลเป็น ความหนาของเยื่อหุ้มปอดในระยะแรกไม่มีอาการ แต่เนื่องจากเยื่อหุ้มปอดที่แข็งตัวมากขึ้นก่อตัวขึ้นรอบ ๆ ปอดมันจะกลายเป็นเรื่องยากที่ปอดจะขยายตัวเต็มที่เมื่อหายใจเข้า ผู้ป่วยมักพบอาการเจ็บหน้าอกและหายใจไม่ออกและหายใจลำบาก (ที่มา <https://www.asbestos.com/mesothelioma/pleural-thickening/>)



ภาพที่ 2.11 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pleural Thickening

ที่มา: <https://radiopaedia.org/search> = Pleural Thickening

2.2.13 Pneumonia ปอดบวม เป็นอาการปอดติดเชื้อและเกิดภาวะอักเสบ ทำให้มีอาการ เช่น มีไข้ ไอ เจ็บหน้าอก หรือหอบเหนื่อย เป็นต้น โดยอาจเกิดจากเชื้อแบคทีเรีย เชื้อไวรัส เชื้อรา หรือพยาธิ หากเกิดการติดเชื้อจากสารเคมีหรือยาบางอย่าง มักเรียกว่าปอดอักเสบ ทั้งนี้ ปอดบวมหรือปอดอักเสบเกิดได้ในทุกเพศทุกวัย โดยจะพบมากในเด็กที่มีอายุต่ำกว่า 5 ปี ผู้สูงอายุ ผู้ที่มีโรคประจำตัว หรือผู้ที่มีภาวะภูมิคุ้มกันบกพร่อง อาการของปอดบวมที่สำคัญ ได้แก่ มีไข้ ไอ เจ็บหน้าอก และหอบเหนื่อย ซึ่งอาการเหล่านี้อาจมีไม่ครบทุกอย่างก็ได้ ส่วนใหญ่มักมีอาการติดเชื้อของทางเดินหายใจส่วนต้น หรือโรคหวัดนำมาก่อน หลังจากนั้นจึงมีอาการไอ และหายใจหอบตามมา โดยเฉพาะที่เกิดจากเชื้อสเตรปโตค็อกคัส นิวโมเนียอี (Streptococcus Pneumoniae) ผู้ป่วยบางรายอาจมีอาการปวดศีรษะ อ่อนเพลีย ปวดเมื่อยกล้ามเนื้อ เจ็บคอ ปวดท้อง เบื่ออาหาร คลื่นไส้ อาเจียน รวมอยู่ด้วย (ที่มา://www.pobpad.com/ปอดบวม)




ภาพที่ 2.12 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pneumonia

ที่มา: <https://radiopaedia.org/search> = Pneumonia

2.2.14 Pneumothorax ภาวะปอดรั่ว คือภาวะที่มีอากาศเข้าไปแทรกอยู่ภายในช่องปอดจนเบียดเนื้อปอด เป็นเหตุให้ปอดขยายตัวได้ไม่เต็มที่และทำงานได้ไม่ดี ส่งผลต่อการหายใจของผู้ป่วย เป็นภาวะที่ต้องได้รับการรักษาทางการแพทย์อย่างเร่งด่วน เพราะหากปล่อยไว้จะเป็นอันตรายถึงแก่ชีวิตได้ Pneumothorax แบ่งออกเป็น 2 ชนิด ได้แก่

1. ภาวะ Pneumothorax จากอุบัติเหตุ มีสาเหตุมาจากการได้รับความกระทบกระเทือนอย่างรุนแรงจนทำให้ลมจากภายนอกเข้าสู่ช่องปอด ภาวะนี้ต้องได้รับการรักษาอย่างเร่งด่วน เนื่องจากมักทำให้มีอาการรุนแรงและอาจเกิดภาวะแทรกซ้อนที่เป็นอันตรายได้

2. ภาวะ Pneumothorax จากสาเหตุอื่น อาจเกิดจากอาการเจ็บป่วยซึ่งส่งผลกระทบต่อปอดโดยตรง เช่น ปอดอุดกั้นเรื้อรัง การติดเชื้อ โรคมะเร็งปอด โรคทางพันธุกรรมบางชนิด หรือโรคหอบหืด บางครั้งอาจเกิดขึ้นโดยไม่มีสาเหตุหรือสัญญาณเตือนใด ๆ
(ที่มา://www.pobpad.com/pneumothorax-ภาวะปอดรั่ว)



ภาพที่ 2.13 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกผู้ป่วยที่มีปอดเป็น Pneumothorax

ที่มา: <https://radiopaedia.org/search> = Pneumothorax

2.3 ลักษณะภาพรังสีทรวงอก (Chest X-Ray) ที่ผิดปกติ

ลักษณะภาพรังสีทรวงอก (Chest X-Ray) ที่ผิดปกติ มีดังนี้

1) ภาพรังสีทรวงอก ที่รับแสง X-ray มากไป (Over Exposure) ทำให้ภาพที่ได้ดูต่ำกว่าปกติ ดังรูปภาพที่ 2.14 รอยโรคที่ปรากฏบนฟิล์มจะดูจางกว่าที่เป็นจริงทำให้เกิดข้อผิดพลาดในการอ่านฟิล์มได้

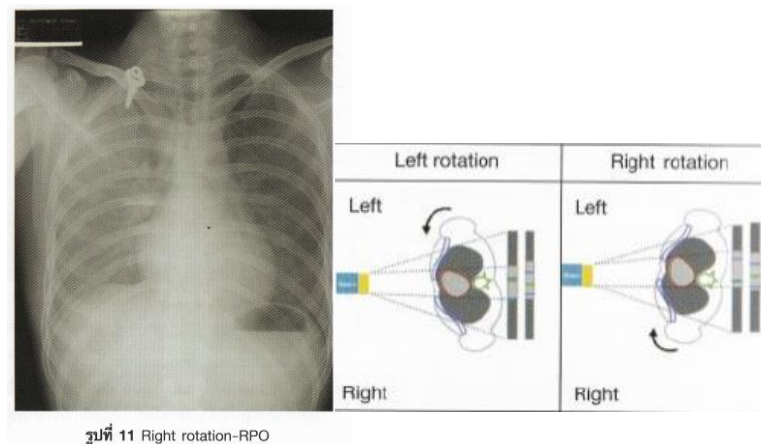
2) ภาพรังสีทรวงอกที่รับแสง X-ray น้อยไป (Under Exposure) ทำให้ภาพที่ได้ดูขาวกว่าปกติ ดังรูปภาพที่ 2.14 ดังนั้น รอยโรคที่ปรากฏบนฟิล์มจะดูเข้มกว่าที่เป็นจริงทำให้เกิดข้อผิดพลาดในการอ่านฟิล์มได้



ภาพที่ 2.14 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกที่รับแสงรังสี X-ray น้อยไป หรือ มากไป

ที่มา: <https://slidetodoc.com/chest-x-ray-anatomy-and-projections-evaluating-chest/>

3) ภาพรังสีทรวงอกที่เกิดจากลักษณะการยื่นถ่ายภาพที่ผู้ป่วยยืนหมุนไปทางด้านข้าง ทำให้ได้ภาพรังสีทรวงอก ที่มีความเข้มไม่เท่ากัน ด้านหนึ่งจะดำกว่าอีกด้านหนึ่ง ดังแสดงในรูปที่ 2.15



ภาพที่ 2.15 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกที่เกิดจากผู้ป่วยยืนหมุนไปทางด้านข้าง

ที่มา: Pocket Chest Radiography โดย วิวิศกร วงศ์ศรีชนาลัย และ อติศร วงษา

4) ภาพรังสีทรวงอกที่เกิดจากการที่ผู้ป่วยมีการหายใจเข้าไม่ลึกพอในขณะที่ถ่ายภาพรังสี X-ray ทำให้ได้ภาพรังสีทรวงอกที่ไม่สมบูรณ์ ดังแสดงในรูปที่ 2.16



ภาพที่ 2.16 แสดงตัวอย่างภาพถ่ายรังสีทรวงอกที่เกิดจากผู้ป่วยหายใจไม่ลึกพอในขณะที่ถ่ายภาพ


ที่มา: https://meded.psu.ac.th/binla/radio3/365_311/Radiographic_Positioning_of_Chest/index2.html

2.4 แนวคิดและทฤษฎีที่เกี่ยวข้อง

2.4.1 Convolutional Neural Networks (CNN) โครงข่ายประสาทเทียมแบบคอนโวลูชัน เป็นสถาปัตยกรรมที่มีประสิทธิภาพในการจำแนกรูปภาพ ด้วยขบวนการการเรียนรู้ (Training) จากคลังข้อมูลรูปภาพที่มีการระบุ (label) ประเภทของรูปภาพไว้แล้วจากผู้เชี่ยวชาญ สร้างแบบจำลอง (model) ที่นำไปใช้ในการทำนายภาพที่ได้มาใหม่ได้ ตามความแม่นยำ (Accuracy) ของแบบจำลอง เช่น ภาพถ่ายรังสีทรวงอกที่มีการระบุลักษณะของโรคที่ปรากฏขึ้นในปอด จากผู้เชี่ยวชาญที่เป็นนักรังสีการแพทย์ เป็นต้น

โครงข่ายประสาทเทียมแบบคอนโวลูชันประกอบด้วยชั้น (Layer) ที่สำคัญ 4 Layer ดังแสดงในภาพที่ 2.17 คือ

- 1) Convolution Layer
- 2) Pooling Layer
- 3) Flattening Layer
- 4) Fully Connection Layer



ภาพที่ 2.17 แสดงชั้น (Layer) ของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN)

ที่มา: <https://www.javatpoint.com/pytorch-convolutional-neural-network>

Convolution Layer เป็นชั้นที่ดำเนินการนำ เข้าภาพ (input image) ที่ค่าเป็น pixel ในรูปของ เมตริกซ์ (Matrix) มาคูณแบบ dot produce กับ ตัวกรอง (Filter) ที่อยู่ในรูปของเมตริกซ์ จะได้ภาพใหม่ ที่เรียกว่า Feature Map ดังแสดงใน ภาพที่ 2.18




Image matrix multiplies kernl or filter matrix

$$\begin{bmatrix} 1 & 1 & 1 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 1 & 1 & 0 \\ 0 & 1 & 1 & 0 & 0 \end{bmatrix} \times \begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 4 & 3 & 4 \\ 2 & 4 & 3 \\ 2 & 3 & 4 \end{bmatrix}$$

Convolved Feature


Input image

Filter

ภาพที่ 2.18 แสดงการคูณเมตริกซ์ในชั้นของ Convolution Layer

ที่มา: <https://www.javatpoint.com/pytorch-convolutional-neural-network>


หลังจากได้ Convolutional Layer แล้วจะต้องทำการ Activation Functions ต่อ ซึ่งมีให้เลือกใช้หลายตัว คือ Sigmoid, tanh, ReLu, Leaky ReLu, Maxout, ELU ดังแสดงในภาพที่ 2.19



ภาพที่ 2.19 แสดง Convolution Layer + ReLu

ที่มา: medium.com/@pradyasin/what-is-convolution-neural-network-bf2e525089f5


Pooling Layer ในขั้นนี้จะทำการลดขนาดของรูปภาพ ที่ได้จากเลเยอร์ก่อนหน้า สามารถเปรียบเทียบกับลดขนาดรูปภาพเพื่อลดความหนาแน่นของพิกเซล แต่ยังคงไว้ซึ่งข้อมูลที่สำคัญ ดังแสดงในภาพที่ 2.20



ภาพที่ 2.20 แสดงการลดขนาดรูปภาพในชั้น Pooling Layer

ที่มา: <https://www.javatpoint.com/pytorch-convolutional-neural-network>


Flattening Layer เป็นการนำภาพที่ได้จากชั้น Pooling Layer โดยภาพที่ได้เรียกว่า Pooled Feature Map นำมาทำ Flattening จะได้ค่า pixel จาก 2 dimensions เป็น 1 dimension เพื่อความสะดวกในการวิเคราะห์ข้อมูล ดังแสดงในภาพที่ 2.21



ภาพที่ 2.21 แสดง การทำ Flattening ได้เป็นค่า pixel ใน 1 คอลัมน์


ที่มา: [//medium.com/@pradyasin/what-is-convolution-neural-network-bf2e525089f5](https://medium.com/@pradyasin/what-is-convolution-neural-network-bf2e525089f5)

Fully Connection Layer คือการนำ Flattening ที่ได้เข้าสู่โมเดล Deep Learning ดังแสดงในภาพที่ 2.22 เมทริกซ์แผนที่คุณลักษณะ (Feature Map) จะถูกแปลงเป็นเวกเตอร์เช่น $x_1, x_2, x_3 \dots x_n$ ทำการคำนวณแบบโครงข่ายในชั้นของ Hidden layer ที่มีการเชื่อมต่ออย่างสมบูรณ์ ผลที่ได้จะรวมคุณสมบัติต่างๆเพื่อสร้างแบบจำลองและใช้ฟังก์ชันการเปิดใช้งานเช่น softmax หรือ sigmoid เพื่อจัดประเภทผลลัพธ์ เป็น Classification X_1, X_2, X_3 เป็นต้น. และภาพที่ 2.23 แสดงภาพรวมของสถาปัตยกรรม Convolutional Neural Networks (CNN)



ภาพที่ 2.22 แสดงชั้น Fully Connected Layer


ที่มา: <https://www.javatpoint.com/pytorch-convolutional-neural-network>



ภาพที่ 2.23 แสดงภาพรวมของสถาปัตยกรรม Convolutional Neural Networks (CNN)

ที่มา: <https://www.javatpoint.com/pytorch-convolutional-neural-network>

2.4.2 DenseNet 121 เป็นสถาปัตยกรรมที่จัดอยู่ใน โครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ Gao Huang, Zhuang Liu, Geoff Pieiss และคณะ ได้คิดสร้างในปี 2017 ประกอบด้วย 5 layer dense block ตามที่แสดงในภาพ ที่ 2.24



ภาพที่ 2.24 แสดงสถาปัตยกรรมของ DenseNet121 ประกอบด้วย 5 layer dense block


ที่มา: <https://pythonawesome.com/densenet-implementation-in-keras/>

DenesNet121 มีข้อดีคือ การแก้ปัญหา vanishing-gradient และมีการปรับปรุงพารามิเตอร์ได้อย่างมีประสิทธิภาพทำให้มีการคำนวณที่น้อยแต่ได้ประสิทธิภาพสูง

2.4.3 Encoder-Decoder เป็นวิธีการสร้างรหัสอัตโนมัติ ด้วยการใช้เครือข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Networks) โดยสร้างจากข้อมูลนำเข้าทำการบีบอัดข้อมูลให้มีขนาดเล็กเรียกว่า Latent Vector จากนั้นก็ทำการขยายข้อมูลสร้างข้อมูลออกมาให้ใกล้เคียงกับข้อมูลต้นฉบับ มีองค์ประกอบที่สำคัญ 2 ประการคือ

1) Encoder : เป็นขบวนการเข้ารหัสจากการนำภาพมาทำการบีบอัดข้อมูลให้มีขนาดเล็ก โดยในที่นี้จะใช้วิธีการเครือข่ายประสาทเทียม(Convolutional Neural Networks) จนได้ข้อมูลที่มีขนาดเล็กที่เรียกว่า Latent vector. ซึ่งข้อมูลขนาดเล็กนี้จะเก็บคุณลักษณะที่โดดเด่นที่สุดของข้อมูลต้นฉบับไว้ โดยที่ข้อมูลอินพุต (Input Data) เป็นค่า x และตัวเข้ารหัสเป็น E ดังนั้น ถ้าค่าเอาต์พุตของ Latent Vector คือ S จะมีค่าเป็น $S = E(x)$ ดังแสดงในภาพที่ 2.25

2) Decoder: เป็นขบวนการถอดรหัสที่จะขยายข้อมูลที่ถูกระบีบอัดให้มีขนาดเล็ก จาก Latent vector จะทำการสร้างภาพขึ้นมาให้คล้ายต้นฉบับ โดยฟังก์ชันถอดรหัสเป็น D และเอาต์พุตของตัวตรวจจับเป็น o ดังนั้นเราสามารถแทนตัวถอดรหัสเป็น $o = D(E(x))$ ดังแสดงในภาพ 2.25 ซึ่งผลลัพธ์จะถูกประเมินเปรียบเทียบภาพที่สร้างใหม่กับภาพต้นฉบับ คำนวณหาค่าแตกต่างด้วยวิธี Mean Square Error (MSE) โดยค่าที่น้อยจะยิ่งคล้ายกับภาพต้นฉบับ.



ภาพที่ 2.25 แสดงภาพรวมของสถาปัตยกรรม Encoder-Decoder

ที่มา: <https://www.pyimagesearch.com/2020/02/17/autoencoders-with-keras-tensorflow-and-deep-learning/>

2.5 งานวิจัยที่เกี่ยวข้องกับประเด็นปัญหา

Mark I. Neumann, Edward Y. Lee และคณะ (2012) ได้ทำการศึกษาความน่าเชื่อถือของนักรังสีวิทยาในการวินิจฉัยโรคปอดบวมในเด็กจากการอ่านภาพรังสีทรวงอก (Chest radiograph (CXR)) โดยใช้เกณฑ์มาตรฐานขององค์การอนามัยโรค (WHO) ในการตีความภาพถ่ายรังสีทรวงอก CXR โดย Neumann และคณะ ได้ทำการประเมินนักรังสีวิทยาที่วินิจฉัยโรคปอดบวมในเด็ก จำนวน 6 คนที่มีจำนวนปีประสบการณ์ต่างกัน โดยใช้รูปแบบการศึกษาที่ระบุไว้ใน WHO เท่านั้น ไม่มีการให้ข้อมูลทางคลินิกเช่น อายุ เพศ หรือข้อบ่งชี้ใดๆจากประวัติทางคลินิก โดยใช้หลักการทางสถิติที่เรียกว่า Kappa มาวัดผล ซึ่งผลจากการศึกษาในการประเมินความน่าเชื่อถือระหว่างผู้ประเมิน (Inter-Rater Reliability) ระบุว่า ในกรณีภาพถ่ายรังสีที่เป็น Alveolar Infiltrate นักรังสีวิทยาทั้ง 6 คนจะตอบเหมือนกันมากที่สุด แต่ถ้าภาพถ่ายรังสีที่เป็น Interstitial Infiltrate จะตอบแตกต่างกันมากที่สุด และผลการศึกษาในการประเมินความน่าเชื่อถือภายในผู้ประเมิน (Intra-Rater Reliability) ของนักรังสีวิทยาทั้ง 6 คน ระบุว่า ในกรณีภาพถ่ายรังสีที่เป็น Alveolar Infiltrate มีค่าความน่าเชื่อถือเกือบจะสมบูรณ์เพราะทุกคนตอบเหมือนกัน แต่ถ้าภาพถ่ายรังสีที่ผู้ป่วยเป็น Interstitial Infiltrate ให้ค่าความน่าเชื่อถือน้อยที่สุดเนื่องจากมีความแตกต่างกันจากการวินิจฉัยจากนักรังสีวิทยา ทั้ง 6 คน

จากผลการศึกษาของงานวิจัยนี้ แสดงให้เห็นว่า การวินิจฉัยของนักรังสีวิทยาในการอ่านภาพถ่ายรังสีทรวงอก บางกรณีการมีความง่ายในการอ่านเป็นที่น่าเชื่อถือได้ แต่บางกรณีก็มีความยาก ไม่เป็นที่น่าเชื่อถือได้ ดังนั้นการใช้ความรู้เชิงลึก (Deep Learning) ในการสร้างโมเดลในการทำนายโรคเพื่อช่วยนักรังสีวิทยาในการอ่านภาพถ่ายรังสีทรวงอกจึงเป็นสิ่งจำเป็นและพัฒนาต่อยอดองค์ความรู้ให้ผลการทำนายมีค่าความแม่นยำสูงขึ้น

Xiaosong Wang, Yifan Peng และคณะ (2017) ได้นำเสนองานวิจัยเพื่อสร้างฐานข้อมูล X-ray แบบใหม่ เรียกว่า “ChestX-ray8” โดยใช้ข้อมูลที่ประกอบด้วย ภาพถ่ายรังสีทรวงอกด้านหน้า (Frontview X-ray image) ของผู้ป่วยที่ไม่ซ้ำกัน 32717 ราย และมีป้ายกำกับภาพ (Label) ระบุ 8 โรคทรวงอกที่ได้จากรายงานทางรังสีวิทยาที่ใช้วิธีการประมวลผล Natural Language Processing (NLP) ดังแสดงในภาพที่ 2.26 และได้สร้างแบบจำลอง (model) ด้วยวิธี Multilabel Deep Convolutional Neural Network (DCNN) Classification Model ดังแสดงในภาพที่ 2.27 ผลจากงานวิจัยนี้ได้ชุดฐานข้อมูลที่ผ่านการตรวจสอบแล้ว ที่เรียกว่า “ChestX-ray8”




Figure 1. Eight common thoracic diseases observed in chest X-rays that validate a challenging task of fully-automated diagnosis.

ภาพที่ 2.26 แสดงภาพถ่ายรังสีทรวงอก 8 ชนิดโรค




Figure 4. The overall flow-chart of our unified DCNN framework and disease localization process.


ภาพที่ 2.27 แสดงแบบจำลอง DCNN ของ Xiaosong Wang และคณะ

Pranav Rajpurkar, Jeremy Irvin และคณะ (2017) ได้ศึกษาการตรวจหาโรคปอดบวมจากภาพถ่ายรังสีทรวงอก ด้วย การเรียนรู้เชิงลึก (Deep Learning) โดยใช้ชุดข้อมูล จาก Chest X-ray14 และได้เสนอ โมเดล ที่เรียกว่า CheXNet ประกอบด้วย 121-layer Dense Convolutional Network (DenseNet) นำมา Train กับข้อมูล ChestX-ray14. ได้ทำการทดสอบเปรียบเทียบผลระหว่าง โมเดล CheXNet กับนักรังสีการแพทย์ 4 ท่านจากมหาวิทยาลัยสแตนฟอร์ด ผลลัพธ์การทำนายจาก โมเดล CheXNet ให้ค่าความแม่นยำ มากกว่าค่าเฉลี่ยของนักรังสีการแพทย์ และ โมเดล CheXNet ให้ค่าความแม่นยำมากกว่าโมเดลของ Wang(2017) และของ Yao (2017) ซึ่งใช้ฐานข้อมูล ChestX-ray14 เหมือนกัน ดังแสดงในตารางที่ 2.1

ตารางที่ 2.1 แสดงเปรียบเทียบผลลัพธ์ ค่าความแม่นยำ AUROC จาก โมเดล CheXNet กับ โมเดลของ Wang และ Yao

Pathology	Wang et al. (2017)	Yao et al. (2017)	CheXNet (ours)
Atelectasis	0.716	0.772	0.8094
Cardiomegaly	0.807	0.904	0.9248
Effusion	0.784	0.859	0.8638
Infiltration	0.609	0.695	0.7345
Mass	0.706	0.792	0.8676
Nodule	0.671	0.717	0.7802
Pneumonia	0.633	0.713	0.7680
Pneumothorax	0.806	0.841	0.8887
Consolidation	0.708	0.788	0.7901
Edema	0.835	0.882	0.8878
Emphysema	0.815	0.829	0.9371
Fibrosis	0.769	0.767	0.8047
Pleural Thickening	0.708	0.765	0.8062
Hernia	0.767	0.914	0.9164

Hongyu Wang และ Yong Xia (2018) ได้นำเสนอแบบจำลองโครงข่ายประสาทเชิงลึก ที่เรียกว่า ChestNet ที่ประกอบด้วย 2 ส่วน คือ ส่วนที่เรียกว่า Classification Branch และส่วนที่เรียกว่า Attention Branch ดังแสดงในภาพที่ 2.28 ชุดข้อมูลที่นำมาทดสอบคือ ChestX-ray 14



ภาพที่ 2.28 แสดงแบบจำลอง ChestNet ของ Hongyu Wang และ Yong Xia

ผลการทดสอบความแม่นยำของการทำนาย โรค 14 โรค ได้ค่าเฉลี่ยความถูกต้อง AUROC = 78.1% ที่มากกว่า โมเดลของ Wang ที่ได้ 74.51% และมากกว่าโมเดลของ Yao ที่ได้ 76.1% ที่ใช้ชุดข้อมูล ChestX-ray 14 เดียวกันในการทดสอบ

Zhicheng Huang, Dongmei Fu (2019) โดยได้นำเสนอรูปแบบของแบบจำลอง (Model) ที่เรียกว่า Multi-Attention Convolution Neural Network ดังแสดงในภาพที่ 2.29

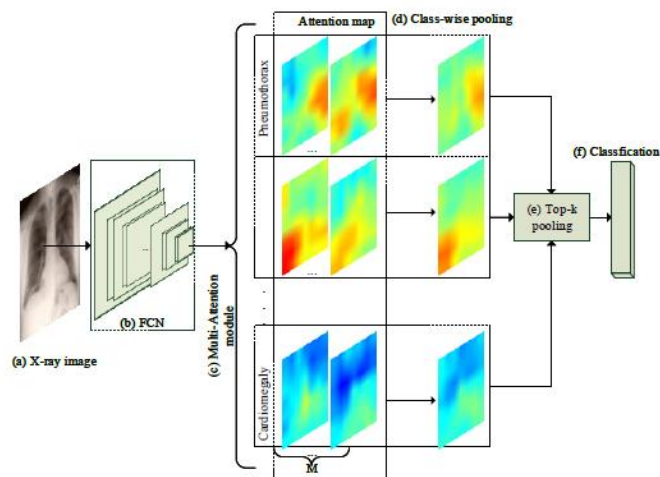


Fig. 2. The framework of the proposed approach. (a) is an input image. (b) is a FCN which can encode spatial information into deep feature maps. (c) is a group of multi-attention layer to produce class-specific attention maps for localizing pathologies and extracting discriminative features to each category. (d) is a channel-wise pooling layer to combine the feature captured from different channels for each category. (e) is a top-k pooling layer which aims to select the high confidence points of each class for the final prediction. (f) is a classification layer to predict the presents of each category by sigmoid activation function.


ภาพที่ 2.29 แสดงภาพแบบจำลองในการศึกษาของ Zhicheng Huang , Dongmei Fu

ผลจากการศึกษานี้ โดยใช้ข้อมูลชุด ChestX-ray14 พบว่า โมเดลที่ได้ ทำนายการเป็นโรคในทรวงอก ทั้ง 14 โรค ให้ผลลัพธ์ความถูกต้อง AUROC เฉลี่ย 85.01% ดีกว่าโมเดลของ Yao ที่ได้ 80.27 % และดีกว่า โมเดล CheXNet ที่ได้ 83.51%

Muhammad Abdulla, Muhammad Rahman และคณะ (2019) ได้ใช้ชุดข้อมูล ChestX-ray14 มาทำการทดสอบ โดยแบ่งข้อมูล ออกเป็น ตามเพศ ชาย-หญิง และแบ่งข้อมูลตามอายุ 53 ปีลงมา และอายุ 54 ปีขึ้นไป นำมาทดสอบกับโมเดล CNN-AlexNet และมีการใช้ตัวกรอง (Filter) 5 ตัวที่มีชื่อเรียกว่า blur, edge, emboss, equalize, และ shapen นำมาใช้ประมวลผลภาพกับภาพก่อนที่จะสร้างแบบจำลอง ผลการทดสอบได้ข้อสรุปว่า การสร้างแบบจำลองเฉพาะกลุ่มตามเพศ และ อายุ นั้น มีความแม่นยำกับโรคบางชนิดเท่านั้น ไม่ทั้งหมด ส่วนการใช้ตัวกรอง(Filter) ทั้ง 5 ตัวนั้น ไม่มีผลในการปรับปรุงความแม่นยำของแบบจำลอง

บทที่ 3 ระเบียบวิธีวิจัย

ในงานวิจัยนี้ ขอนำเสนอวิธีการวิจัยโดยมีขั้นตอนหลัก 3 ขั้นตอน ดังแสดงในภาพที่ 3.1 และมีรายละเอียดในแต่ละขั้นตอนดังนี้




ภาพที่ 3.1 แสดงแผนผังแนวคิดสร้างแบบจำลองประกอบด้วย 3 ขั้นตอนหลัก

3.1 ขั้นตอนที่ 1 คัดกรองภาพที่เป็น Outlier (Step 1 : Filter Outlier Images)

เริ่มดำเนินการโดยนำภาพถ่ายรังสีทรวงอกจากชุดข้อมูล ChestX-ray 14 ที่นำเข้ามาจาก [www. Kaggle.com](http://www.kaggle.com) ที่เป็นภาพที่ระบุ โรค 1 โรค ต่อ 1 ภาพเท่านั้นนำมาใช้ในงานวิจัยครั้งนี้ หลังจากนั้นนำภาพที่ได้ดังกล่าวมาทำการคัดกรองภาพที่เป็น Outlier โดยการสร้างโมเดลจากวิธีการ Encoder-Decoder ตามผังการทำงานแสดงในภาพที่ 3.2 โดยมีรายละเอียดของ Encoder-


Decoder ที่ประกอบด้วย เลเยอร์ (Layer) ทั้งหมด 14 ชั้น ดังแสดงในภาพที่ 3.3 ซึ่งมี Layer_0 เป็นชั้นแรก ที่ นำเข้า ภาพ มีขนาด 224x224 ทำการบีบ



ภาพที่ 3.2 แสดงแผนผังการคัดกรองภาพ Outlier

Layer (type)	Output Shape	Param #
Layer_0 (InputLayer)	[(None, 224, 224, 1)]	0
Layer_1 (Conv2D)	(None, 224, 224, 32)	320
Layer_2 (MaxPooling2D)	(None, 112, 112, 32)	0
Layer_3 (Conv2D)	(None, 112, 112, 64)	18496
Layer_4 (MaxPooling2D)	(None, 56, 56, 64)	0
Layer_5 (Conv2D)	(None, 56, 56, 128)	73856
Layer_6 (MaxPooling2D)	(None, 28, 28, 128)	0
Layer_7 (Conv2D)	(None, 28, 28, 256)	295168
Layer_8 (UpSampling2D)	(None, 56, 56, 256)	0
Layer_9 (Conv2D)	(None, 56, 56, 64)	147520
Layer_10 (UpSampling2D)	(None, 112, 112, 64)	0
Layer_11 (Conv2D)	(None, 112, 112, 32)	18464
Layer_12 (UpSampling2D)	(None, 224, 224, 32)	0
Layer_13 (Conv2D)	(None, 224, 224, 1)	289

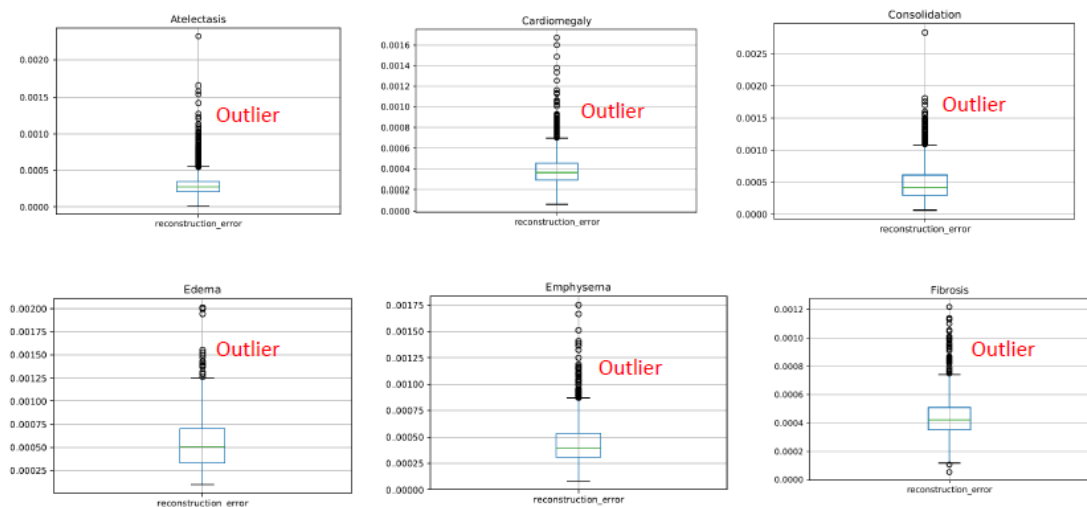
Total params: 554,113
Trainable params: 554,113
Non-trainable params: 0



ภาพที่ 3.3 แสดงสำหรับโมเดล แบบ Encoder-Decoder

อัดข้อมูล ด้วย Layer_1 - Conv2D แล้วตามด้วย Layer_2 – Maxpooling2D ทำต่ออีก 2 ครั้ง จะได้ Layer_7 ที่บีบอัดข้อมูลได้ภาพขนาดเล็ก 28x28 pixel. ต่อจากนั้นทำการขยายภาพด้วย Layer_8 UpSampling2D และตามด้วย Layer_9 Con2D แล้วทำซ้ำอีก 2 ครั้ง จะได้ชั้นสุดท้าย Layer_13 จะได้ขนาดภาพ กลับคืนมา ที่ขนาด 224x224 pixel. และใช้ Loss function เป็น mean square error (mse) , และ ใช้ “Adam” เป็น Optimizer , ซึ่งจะได้จำนวน Trainable parameter = 554,113 ดังแสดงในภาพที่ 3.3

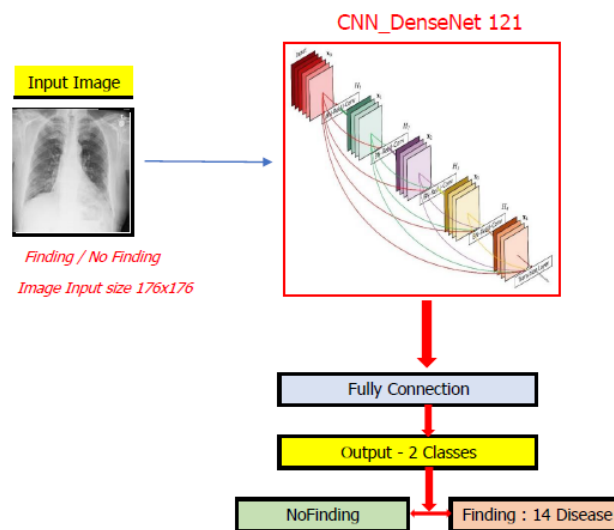
ซึ่งต้องทำการเข้าโมเดลเพื่อการคัดกรองภาพในแต่ละโรค จนครบ 14 โรค และ ภาพที่ไม่เป็นโรค (No Finding) ด้วย การคัดกรองภาพ จะใช้ค่า Mean Square Error (mse) ที่ได้จากค่า loss ระหว่าง ภาพที่เป็น original กับภาพที่เกิดจากการ Reconstruction จากโมเดล Encoder-Decoder โดย นำเสนอในรูปกราฟแบบ Boxplot แล้วทำการเก็บบันทึกภาพที่มีค่า mse อยู่ระหว่าง ค่า Upper และ Lower เป็นภาพที่ดี (good image) ส่วนภาพที่อยู่นอกเหนือ ค่า Upper bound ถือว่าเป็นภาพ Outlier ให้ทำการเก็บแยกต่างหาก ดังแสดง ในภาพที่ 3.4



ภาพที่ 3.4 แสดงผลจากโมเดล Encoder-Decoder ในรูปแบบของ Box Plot ของแต่ละโรค

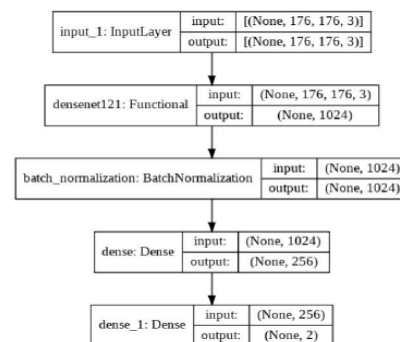
3.2 ขั้นตอนที่ 2 สร้างโมเดลเพื่อจำแนก ภาพเป็นโรค หรือ ไม่เป็นโรค (Step 2 : Classify Finding / No Finding)

เมื่อได้ ภาพที่ดี (good images) จากขั้นตอนแรก ให้ทำการรวมภาพที่เป็นโรค (Finding) จากทั้ง 14 โรค ให้เป็น 1 Class และ ภาพที่ไม่เป็นโรค (No Finding) อีก 1 Class นำเข้าโมเดลที่สร้างจากสถาปัตยกรรม CNN-DenseNet121 และ ต่อ โดย ชั้น Fully Connection ดังแสดงแผนผังในภาพที่ 3.5 และภาพที่ 3.6 แสดงรายละเอียดของชั้น Fully Connection



ภาพที่ 3.5 แสดงแผนผังในขั้นตอนที่ 2 (Step 2 : Classify Finding / No Finding)

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 176, 176, 3)]	0
densenet121 (Functional)	(None, 1024)	7037504
batch_normalization (BatchNo)	(None, 1024)	4096
dense (Dense)	(None, 256)	262400
dense_1 (Dense)	(None, 2)	514
Total params: 7,304,514		
Trainable params: 7,218,818		
Non-trainable params: 85,696		



ภาพที่ 3.6 แสดงสถาปัตยกรรมโมเดล CNN-DenseNet121 + Fully Connection

ในการสร้างโมเดลในขั้นตอนที่ 2 นี้ จะมีการสร้าง 2 โมเดลเพื่อนำผลมาเปรียบเทียบกัน โดยโมเดลที่ 1 เป็นโมเดลที่ใช้ภาพที่นำเข้าโมเดลจะเป็นภาพที่ดี (good images) ไม่มีภาพที่เป็น Outlier โดยทำการลดขนาดของภาพจาก ภาพต้นฉบับ 1024x1024 เป็นภาพขนาด 176x176 สำหรับในส่วนของ CNN-DenesNet 121 จะใช้ Pretrained โดยการใช้ Image Net ช่วยในการสร้างโมเดล แล้วต่อด้วยชั้น Fully Connection ที่ประกอบด้วยชั้น Batch Normalization, Dense 256 และ ชั้น out put จะแสดงผลออกมาแบบ 2 classes คือ class 0 : No Finding และ class 1 : Finding และ กำหนด พารามิเตอร์อื่น ดังนี้

- Activation = “sigmoid”
- Optimizer = “Adam”
- Loss = “binary crossentropy”
- Batch size = 64
- Trainable parameter = 7,218,818

ข้อมูลภาพที่นำมาใช้จะเป็นภาพที่ผ่านการคัดกรองจากขั้นตอนที่ 1 แล้ว ที่เป็นภาพที่ดี (good image) โดยแบ่งเป็น ภาพที่ใช้ Train 70% , Validation 10% และ ข้อมูลทดสอบ(Test) 2 ชุด Test-1 = 20% (Good Images), Test-2 = 20% (Good Images) รวมกับภาพ Outlier ที่มีทั้งหมดของภาพที่เป็นโรค 2055 ภาพ และภาพที่ไม่เป็นโรคในจำนวนที่เท่ากัน 2055 ภาพ.


ในส่วนของโมเดลที่ 2 เป็นโมเดลที่สร้างจากจำนวนรูปภาพทั้งหมดของภาพที่เป็นโรค แต่ในส่วนของภาพที่ไม่เป็นโรค (No Finding) ที่มีจำนวนมากจะถูกทำการลดจำนวนรูปภาพ โดยวิธีการ Random ให้จำนวนรูปภาพเท่ากับจำนวนรูปภาพรวมทั้งหมดของภาพที่เป็นโรค (Finding) โดยทำการ Random ภาพ 3 ครั้ง และในการสร้างโมเดลได้ใช้สถาปัตยกรรมเดียวกับ โมเดลที่ 1

3.3 ขั้นตอนที่ 3 สร้างโมเดลเพื่อจำแนกภาพที่เป็นโรค 14 โรค และไม่เป็นโรค

(Step 3 : Classify 15 classes for 14 Findings and No Finding)

การสร้างโมเดลนี้จะทำการสร้างจากข้อมูลภาพที่ดี(good images) จากภาพที่เป็นโรค 14 โรค เป็น และภาพที่ไม่เป็นโรค (No Finding) รวมเป็น 15 classes ในขั้นตอนนี้จะมีการสร้างโมเดล 3 รูปแบบ เพื่อนำผลลัพธ์มาเปรียบเทียบความแม่นยำกัน โดยมีรายละเอียดดังนี้


3.3.1 โมเดลที่สร้างจาก CNN-DenseNet 121 + Fully Connection ดังแสดงในภาพที่ 3.7 และภาพที่ 3.8



ภาพที่ 3.7 แสดงแผนผังในขั้นตอนที่ 3.1 เป็น โมเดลที่สร้างจาก CNN-DenseNet 121

Layer (type)	Output Shape	Param. #
input_1 (InputLayer)	[(None, 176, 176, 3)]	0
densenet121 (Functional)	(None, 1024)	7037504
batch_normalization (BatchNo)	(None, 1024)	-4096
dense (Dense)	(None, 256)	262400
dense_1 (Dense)	(None, 15)	3855

Total params: 7,307,855
Trainable params: 7,222,159
Non-trainable params: 85,696




ภาพที่ 3.8 แสดงสถาปัตยกรรมโมเดล CNN-DenseNet121 + Fully Connection สำหรับ 15 classes


ในการสร้างโมเดลในขั้นตอนที่ 3 ในส่วนของโมเดลย่อยที่ 3.1 นี้ จะใช้ภาพที่นำเข้าโมเดลจะเป็นภาพที่ดี (good images) ไม่มีภาพที่เป็น Outlier โดยทำการลดขนาดของภาพจาก ภาพต้นฉบับ 1024x1024 เป็นภาพขนาด 176x176 สำหรับในส่วนของ CNN-DenseNet 121 จะใช้ Pretrained โดยการใช้ Image Net ช่วยในการสร้างโมเดล แล้วต่อด้วยชั้น Fully Connection ที่ประกอบด้วยชั้น Batch Normalization, Dense 256 และ ชั้น out put จะแสดงผลออกมาแบบ 15 classes คือ class 0 คือ ไม่เป็นโรค (No Finding) และ class 1-14 คือ 14 โรค (Finding) และกำหนดพารามิเตอร์อื่น ดังนี้

- Activation = “softmax”
- Optimizer = “Adam”
- Loss = “categorical crossentropy”
- Batch size = 128
- Trainable parameter = 7,222,159

3.3.2 โมเดลที่ใช้วิธี Ensemble สร้างโดยการนำภาพที่ดี (good images) ขนาดภาพ 176x176 pixel มาสร้าง โมเดลแบบ Encoder เพื่อทำการเข้ารหัสบีบอัดข้อมูล เพื่อหา Latent Feature ที่จะเก็บคุณลักษณะเด่นไว้ จากนั้นนำไปเข้าชั้น Fully Connection Network ที่เป็นโครงข่ายประสาทเทียม ทำการสร้าง Binary Classification



ภาพที่ 3.9 แสดงแผนผังในการสร้างโมเดลแบบ Ensemble



ภาพที่ 3.10 แสดงแผนผังในการสร้างโมเดล แบบ Ensemble ด้วยวิธี Encoder และต่อด้วย


Fully connection

เพื่อที่ทำการทำนายเป็นโรคนั้น กับการไม่เป็นโรค ซึ่งต้องทำ 15 classes โดยในแต่ละ class จะให้ผลการทำนายแบบ Yes/No หลังจากนั้น นำมา มารวมกันด้วยคำสั่ง Concatenate แล้วต่อ ด้วย Fully Connection Network ที่เป็นโครงข่ายประสาทเทียมอีกชุดหนึ่ง จากโมเดล จะได้ผลการ ทำนาย 15 classes ดังแสดงในรูปภาพที่ 3.9 และภาพที่ 3.10


กำหนด พารามิเตอร์ที่ใช้สร้างโมเดล มี ดังนี้

- Activation = “softmax”
- Optimizer = “Adam”
- Loss = “categorical crossentropy”
- Trainable parameter = 182,607

3.3.3 โมเดลที่ใช้วิธีแบบ Multi-heads สร้างโดยการนำภาพที่ดี (good images) ขนาดภาพ 176x176 pixel มาสร้าง โมเดลแบบ Encoder- Decoder ทั้ง 15 classes โดยใช้โมเดล Ensemble ในข้อ 3.3.2 แต่นำในส่วนที่เป็น ชั้นสุดท้าย (Last Layer) ของโครงข่ายประสาทเทียมที่สร้างสำหรับ Binary Classification ซึ่งเป็นการดึงข้อมูลแบบ Feature Extraction ทั้ง 15 classes แล้วนำมารวมกันด้วยคำสั่ง Concatenate แล้วต่อด้วย Fully connection ผลลัพธ์ จากโมเดล จะได้ผลการทำนาย 15 classes ดังแสดงในรูปภาพที่ 3.11 และ ภาพที่ 3.12



ภาพที่ 3.11 แสดงแผนผังในขั้นตอนที่ 3.3 เป็น โมเดลแบบ Multi-heads



Layer (type)	Output Shape	Param #
dense (Dense)	(None, 512)	492032
dense_1 (Dense)	(None, 512)	262656
dense_2 (Dense)	(None, 256)	131328
dense_3 (Dense)	(None, 128)	32896
dense_4 (Dense)	(None, 15)	1935
Total params: 920,847		
Trainable params: 920,847		
Non-trainable params: 0		

ภาพที่ 3.12 แสดงแผนผังในการสร้างโมเดล แบบ Multi-Heads.

กำหนด พารามิเตอร์ที่ใช้สร้างโมเดล Multi-heads มีดังนี้

- Activation = “softmax”
- Optimizer = “Adam”
- Loss = “categorical crossentropy”
- Trainable parameter = 920,847

บทที่ 4

ผลการทดลอง

4.1 การเตรียมการทดลอง (Experimental Setup)

การวิจัยนี้ได้ใช้ชุดข้อมูลภาพถ่ายรังสีทรวงอก (Chest X ray) ที่มีชื่อว่า “ChestX-ray14” ที่เป็นชุดข้อมูลสาธารณะ จาก www.kaggle.com ประกอบด้วยภาพถ่ายรังสีทรวงอก จำนวน 112,120 ภาพ จากจำนวนคนไข้ 30,805 คน แต่ละภาพมีการระบุชื่อโรคกำกับไว้โดยผู้เชี่ยวชาญ บางภาพระบุไว้ 1 โรค บางภาพระบุไว้มากกว่า 2 โรค แต่ในงานวิจัยนี้จะใช้เฉพาะภาพถ่ายรังสีทรวงอกที่มีการระบุชื่อโรค 1 โรคต่อ 1 ภาพเท่านั้น ซึ่งมีทั้งหมด 14 โรค และอีก 1 ชุดภาพที่ระบุว่า “No Finding” ตารางที่ 4.1 แสดง รายชื่อโรค และจำนวนภาพถ่ายรังสีทรวงอกที่ระบุ 1 โรค

ตารางที่ 4.1 แสดงรายชื่อโรค และจำนวนภาพถ่ายรังสีทรวงอกของแต่ละโรคที่ได้จากชุดฐานข้อมูล ChestX-ray14

ชื่อโรค	จำนวนภาพ
1. โรคปอดแฟบ (Atelectasis)	4215
2. โรคหัวใจโต (Cardiomegaly)	1093
3. โรคปอดเนื้อแข็ง (Consolidation)	1310
4. โรคปอดบวมน้ำ (Edema)	628
5. โรคน้ำในช่องเยื่อหุ้มปอด (Effusion)	3955
6. โรคถุงลมโป่งพอง (Emphysema)	892
7. โรคพังคืดสะสมในปอด (Fibrosis)	727
8. โรคปอดเลื่อน (Hernia)	110
9. โรครอยฝ้าที่ปอด (Infiltration)	9547
10. ก้อนเนื้อที่ปอดแบบ Mass	2139
11. ก้อนเนื้อที่ปอดแบบNodule	2705
12. โรคเยื่อหุ้มปอดหนา (Pleural Thickening)	1126
13. โรคปอดบวม (Pneumonia)	322
14. โรคปอดรั่ว (Pneumothorax)	2194
15. ปกติ (No Finding)	60361

4.2 ผลการคัดกรองภาพในขั้นตอนที่ 1 (Step 1 : Filter Outlier Images- Result)

จากการคัดกรองภาพโดยวิธีการ Encoder-Decoder และใช้ค่า Upper และ Lower ทำการเก็บบันทึกภาพที่ดี (Good Images) และภาพที่เป็น Outlier ออกจากกัน ผลลัพธ์ที่ได้จะได้จำนวนภาพที่ดีของแต่ละโรคและที่ไม่เป็นโรค ดังแสดงจำนวนภาพในตารางที่ 4.2

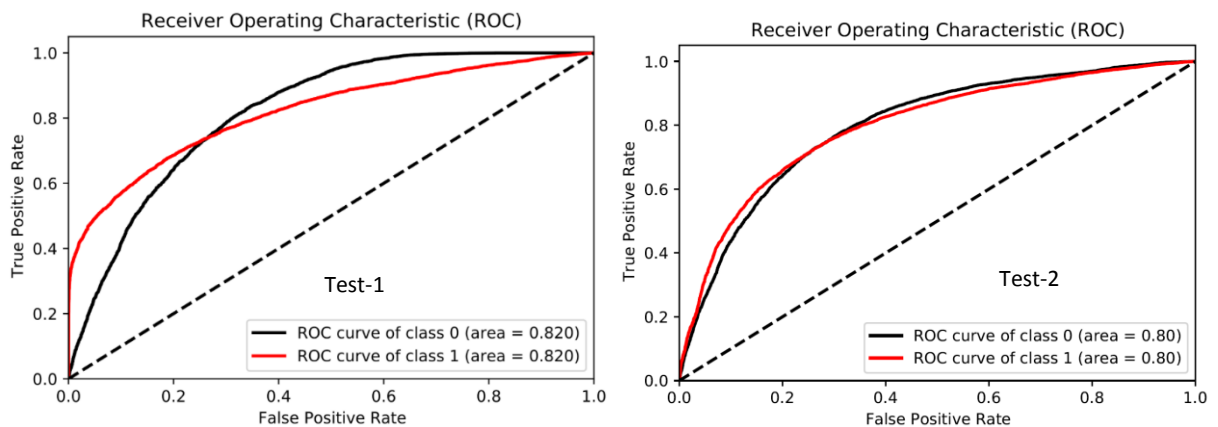
ตารางที่ 4.2 แสดงจำนวนภาพถ่ายรังสีทรวงอกของแต่ละโรคที่ผ่านการคัดกรองในขั้นตอนที่ 1 จะได้ภาพที่ดี (Good Images) กับ ภาพผิดปกติ (Outlier Images)

No.	Diseases Classification	Total Image	Encoder-Decoder	
			Good Image (Upper-Lower)	Outlier Image
1	Atelectasis (โรคปอดแฟบ)	4215	3973	242
2	Cardiomegaly(โรคหัวใจโต)	1093	1032	61
3	Consolidation (โรคปอดเนื้อแข็ง)	1310	1255	55
4	Edema (โรคปอดบวมน้ำ)	628	611	17
5	Effusion (โรคน้ำในช่องเยื่อหุ้มปอด)	3955	3683	272
6	Emphysema (โรคถุงลมโป่งพอง)	892	885	7
7	Fibrosis (โรคพังศืดสะสมในปอด)	727	687	40
8	Hernia (โรคปอดเคลื่อน)	110	102	8
9	Infiltration (โรครอยฝ้าที่ปอด)	9547	8809	738
10	Mass (ก้อนเนื้อที่ปอด > 3 ซม.)	2139	2004	135
11	Nodule (ก้อนเนื้อที่ปอด <3 ซม.)	2705	2530	175
12	Pleural Thickening (โรคเยื่อหุ้มปอดหนา)	1126	1033	93
13	Pneumonia (โรคปอดบวม)	322	301	21
14	Pneumothorax (โรคปอดรั่ว)	2194	2003	191
	Total Finding (ภาพเป็นโรค) =	30963	28908	2055
15	No Finding (ภาพไม่เป็นโรค) =	60361	30068 **	30293
**	ภาพ Good Images อยู่ในช่วง Q3 - Q1			

4.3 ผลการทำนายภาพประเภท Finding / No Finding ในขั้นตอนที่ 2 (Step 2 : Classify Finding / No Finding)

ในขั้นตอนที่ 2 จะมีการสร้างโมเดล 2 โมเดล เพื่อนำผลลัพธ์มาเปรียบเทียบความแม่นยำในการทำนาย โดยมีรายละเอียดในแต่ละโมเดล ดังนี้


โมเดลที่ 1 เป็นโมเดลที่นำข้อมูลภาพที่ดี (good images) ที่ผ่านการคัดกรองจากในขั้นตอนที่ 1 เท่านั้น มาสร้างโมเดล โดยทำการแบ่งเป็นข้อมูลชุดสอน (Train) 70% , Validation 10% และข้อมูลทดสอบ(Test) 2 ชุด Test-1 = 20% (Good Images), Test-2 = 20% (Good Images) รวมกับภาพ Outlier ที่มีทั้งหมดของภาพที่เป็นโรค 2055 ภาพ และภาพที่ไม่เป็นโรคในจำนวนที่เท่ากัน 2055 ภาพ นำมาใช้สร้างโมเดลและวัดผล โดยใช้ค่า AUROC (Area Under Receiver Operating Characteristic) ได้เท่ากับ 0.82 และ 0.80 ตามลำดับ ดังแสดงใน ภาพที่ 4.1



ภาพที่ 4.1 แสดงผลการวัดค่า AUROC จากโมเดลที่สร้างจากข้อมูลชุดภาพที่ดี (Good Images)

โมเดลที่ 2 เป็นโมเดลที่นำข้อมูลภาพทั้งหมด มาสร้างโมเดล โดยสร้างเป็นโมเดลย่อย 3 โมเดล เนื่องจาก ภาพที่ไม่เป็นโรคมียังมีจำนวนมาก เกินกว่าจะ ความสามารถของคอมพิวเตอร์จะรับได้ในครั้งเดียว จึงมีการใช้วิธีการ Random ภาพที่ไม่เป็นโรค 3 ครั้ง และรวมกับภาพที่เป็นโรคทั้งหมด มาทำการสร้างโมเดล โดยยังคงแบ่งข้อมูลเป็น Train 70% , Validation 10% และ Test

20% ผลที่ได้จะได้ค่าเฉลี่ย AUROC ทั้ง 3 โมเดลย่อย คือ 0.68 ม 0.68 และ 0.69 ตามลำดับ ดังแสดง
ในภาพ ที่ 4.2




ภาพที่ 4.2 แสดงผลการวัดค่า AUROC จากโมเดลที่สร้างจากข้อมูลชุดภาพทั้งหมดที่เป็น โรคและ
ไม่เป็นโรค


4.4 ผลการจำแนกโรคปอด 15 โรค ในขั้นตอนที่ 3

ในขั้นตอนที่ 3 จะมีการสร้างโมเดลย่อย 3 โมเดล เพื่อนำผลลัพธ์มาเปรียบเทียบความแม่นยำในการทำนาย เป็นโมเดลที่นำข้อมูลภาพที่ดี (good images) ที่ผ่านการคัดกรองจากในขั้นตอนที่ 1 เท่านั้น มาสร้างโมเดล โดยทำการแบ่งเป็นข้อมูลชุดสอน (Train) 70% , Validation 10% และข้อมูลทดสอบ(Test) 2 ชุด Test-1 = 20% (Good Images), Test-2 = 20% (Good Images) รวมกับภาพ Outlier ที่มีทั้งหมดของภาพที่เป็นโรค 2055 ภาพ และภาพที่ไม่เป็นโรคในจำนวนที่เท่ากัน 2055 ภาพ นำมาใช้สร้างโมเดลเพื่อทำนายภาพที่เป็นโรค 14 โรค และภาพที่ไม่เป็นโรค รวม 15 Classes

ในโมเดลแบบ Ensemble ในช่วงแรกจะเป็นการสร้างโมเดลด้วยวิธี Encoder และต่อด้วย Fully connection อีก ตามภาพที่ 3.10 จะทำนายการเป็นโรค กับ ไม่เป็นโรค 2 classes วัดประสิทธิภาพ ด้วยค่า AUROC แสดงในภาพที่ 4.3 และสรุปค่า AUROC ในตารางที่ 4.3



ภาพที่ 4.3 แสดงผลการวัดค่า AUROC จากโมเดล แบบ Ensemble ในช่วงแรก ทำนาย 2 class





ภาพที่ 4.3 (ต่อ) แสดงผลการวัดค่า AUROC จากโมเดล แบบ Ensemble ในช่วงแรก ทำนาย 2 class

ตารางที่ 4.3 แสดงค่า AUROC จาก โมเดลแบบ Ensemble ในช่วงแรก



Class No.	Diseases Classification	Good Image	ค่า AUROC
0	No Finding (ภาพไม่เป็นโรค)	30068	0.74
1	Atelectasis (โรคปอดแฟบ)	3973	0.78
2	Cardiomegaly(โรคหัวใจโต)	1032	0.78
3	Consolidation (โรคปอดเนื้อแข็ง)	1255	0.83
4	Edema (โรคปอดบวมน้ำ)	611	0.92
5	Effusion (โรคน้ำในช่องเยื่อหุ้มปอด)	3683	0.81
6	Emphysema (โรคถุงลมโป่งพอง)	885	0.71
7	Fibrosis (โรคพังคืดสะสมในปอด)	687	0.61
8	Hernia (โรคปอดเคลื่อน)	102	0.53
9	Infiltration (โรครอยฝ้าที่ปอด)	8809	0.61
10	Mass (ก้อนเนื้อที่ปอด > 3 ซม.)	2004	0.67
11	Nodule (ก้อนเนื้อที่ปอด <3 ซม.)	2530	0.52
12	Pleural Thickening (โรคเยื่อหุ้มปอดหนา)	1033	0.65
13	Pneumonia (โรคปอดบวม)	301	0.69
14	Pneumothorax (โรคปอดรั่ว)	2003	0.76

ในขั้นตอนสุดท้ายของแต่ละโมเดล วัดประสิทธิภาพด้วยค่าเฉลี่ยของ AUROC (Area Under Receiver Operating Characteristic) โดยในแต่ละโมเดลให้ค่าเฉลี่ย AUROC สำหรับ Test-1 และ Test-2 ดังนี้



1. โมเดลที่สร้างโดยวิธี CNN-DenesNet 121 ได้ค่าเฉลี่ย AUROC = 0.75 และ 0.73 ดังแสดงตามภาพที่ 4.4
2. โมเดลที่สร้างโดยวิธี Ensemble ได้ค่าเฉลี่ย AUROC = 0.54 และ 0.53 ดังแสดงตามภาพที่ 4.5
3. โมเดลที่สร้างโดยวิธี Multi-heads ได้ค่าเฉลี่ย AUROC = 0.69 และ 0.66 ดังแสดงตามภาพที่ 4.6
4. สรุป ค่า AUROC ของ Test-1 และ Test-2 จากทั้ง 3 โมเดล แสดงใน ตารางที่ 4.4



ภาพที่ 4.4 แสดงผลการวัดค่า AUROC 15 classes จากโมเดลที่สร้างโดยวิธี CNN-DenesNet 121



ภาพที่ 4.5 แสดงผลการวัดค่า AUROC 15 classes จากโมเดลที่สร้างโดยวิธี Ensemble



ภาพที่ 4.6 แสดงผลการวัดค่า AUROC 15 classes จากโมเดลที่สร้างโดยวิธี Multi-heads

ตารางที่ 4.4 แสดงค่า AUROC ของชุดทดสอบ Test-1 และ Test-2 จาก 3 โมเดล ในขั้นตอนที่ 3
ทำนาย 15 classes

Class no.	Diseases Classification	Good Image	AUROC			AUROC		
			Test 1 = 20% Good Images			Test 2 = 20% Good Images + Outlier		
			DenseNet121	Ensemble	Multi head	DenseNet121	Ensemble	Multi head
0	No Finding (ภาพไม่เป็นโรค)	30068	0.79	0.70	0.73	0.78	0.67	0.71
1	Atelectasis (โรคปอดแฟบ)	3973	0.80	0.62	0.71	0.77	0.51	0.67
2	Cardiomegaly (โรคหัวใจโต)	1032	0.93	0.47	0.72	0.90	0.57	0.70
3	Consolidation (โรคปอดเนื้อแข็ง)	1255	0.81	0.68	0.78	0.75	0.63	0.74
4	Edema (โรคปอดบวมน้ำ)	611	0.89	0.59	0.87	0.84	0.51	0.84
5	Effusion (โรคน้ำในช่องเยื่อหุ้มปอด)	3683	0.89	0.41	0.79	0.88	0.53	0.76
6	Emphysema (โรคถุงลมโป่งพอง)	885	0.81	0.48	0.71	0.73	0.46	0.67
7	Fibrosis (โรคพังทลายสะสมในปอด)	687	0.62	0.57	0.63	0.62	0.42	0.61
8	Hernia (โรคปอดเคลื่อน)	102	0.59	0.50	0.65	0.60	0.52	0.64
9	Infiltration (โรครอยฝ้าที่ปอด)	8809	0.67	0.53	0.57	0.69	0.48	0.59
10	Mass (ก้อนเนื้อที่ปอด > 3 ซม.)	2004	0.73	0.54	0.58	0.71	0.51	0.58
11	Nodule (ก้อนเนื้อที่ปอด < 3 ซม.)	2530	0.66	0.50	0.60	0.65	0.50	0.58
12	Pleural Thickening (โรคเยื่อหุ้มปอดหนา)	1033	0.64	0.53	0.62	0.62	0.53	0.55
13	Pneumonia (โรคปอดบวม)	301	0.63	0.49	0.61	0.60	0.48	0.62
14	Pneumothorax (โรคปอดคว่ำ)	2003	0.82	0.55	0.61	0.82	0.59	0.69
ค่าเฉลี่ย AUROC =			0.75	0.54	0.69	0.73	0.53	0.66

จากตารางที่ 4.4 เมื่อพิจารณาในผลลัพธ์จากชุด Test-1 (20% Good Images) จะพบว่า โมเดล DenseNet121 จะให้ค่า AUROC ที่สูงกว่า อีก 2 โมเดล 13 Classes คือ AUROC ของ Class 0 (No Finding), Class 1 (Atelectasis), Class 2 (Cardiomegaly), Class 3 (Consolidation), Class 4 (Edema), Class 5 (Effusion), Class 6 (Emphysema), Class 9 (Infiltration), Class 10 (Mass), Class 11 (Nodule), Class 12 (Pleural Thickening), Class 13 (Pneumonia) and Class 14 (Pneumothorax) และสำหรับ โมเดล Multi heads จะให้ค่า AUROC สูงกว่า 2 Classes คือ Class 7 (Fibrosis), Class 8 (Hernia).

จากผลลัพธ์ที่ได้ แสดงว่า โมเดล Ensemble และ โมเดล Multi-heads ให้ค่าเฉลี่ย AUROC จากทั้ง 15 Classes ต่ำกว่า โมเดล CNN-DenseNet121 มีสาเหตุดังนี้

1) การนำเข้าภาพปกติ (Good Images) ที่ผ่านการคัดกรองแล้ว มีการลดขนาดภาพเหลือ 176x176 pixel จากนั้นเข้า โมเดล Encoder ทำการเข้ารหัสบีบอัดข้อมูล เพื่อหา Latent Feature ที่จะเก็บคุณลักษณะเด่นไว้นั้น การลดขนาดภาพดังกล่าวอาจเป็นการลดที่มากเกินไป จึงส่งผลให้การบีบอัดข้อมูลภาพในชั้น Latent ขาดคุณลักษณะที่สำคัญในแต่ละโรค.

2) จาก Latent Feature ที่ได้ โมเดล Ensemble ได้นำไปเข้า ชั้น Fully Connection network ซึ่งเป็นโครงข่ายประสาทเทียม ทำการสร้าง Binary Classification เพื่อทำนาย การเป็น โรคนั้น กับ การไม่เป็นโรค ซึ่งเมื่อ Latent Feature มีคุณลักษณะที่ด้อยลงจากการลดขนาดภาพนำเข้า จึงทำให้ ผลลัพธ์การสร้าง Binary Classification ให้ค่า AUROC ที่ไม่ค่อนยี่ดต่ำกว่า 0.70 ในจำนวน 7 โรคนั้น จากตารางที่ 4.3 คือ โรคนั้น Fibrosis , Hernia, Infiltration, Mass, Nodule, Pleural Thickening และ Pneumonia ซึ่งส่งผลทำให้การนำไปทำต่อโดยการ Concatenate ทั้ง 15 โมเดล แล้วต่อด้วย ชั้น Fully Connection network เพื่อทำนายการเป็นโรค 14 โรคนั้น และ การไม่เป็นโรค จึงให้ค่าเฉลี่ย AUROC ต่ำกว่า โมเดล CNN-DenseNet 121.

3) นอกจากนี้ ในขบวนการเรียนรู้ (Training) เพื่อทำ Binary Classification ของแต่ละโรคนั้น อาจจะยังดำเนินการไม่ถึงจุดที่ให้ผลลัพธ์ที่ดีที่สุด เพราะการสร้างชั้นโครงข่ายประสาทเทียมที่ต่อมาจาก Latent Feature ไม่จำเป็นต้องเหมือนกัน จะต้องสร้างรูปแบบเฉพาะของโรคนั้นๆเพื่อหาผลลัพธ์ที่ดีที่สุดของแต่ละโรคนั้น.

4) ในส่วนของโมเดล Multi-heads ได้ใช้ในส่วนแรกของ โมเดล Ensemble ที่เรียกว่า Binary Classification โดยทำการดึงข้อมูล ชั้นสุดท้ายของโครงข่ายประสาทเทียมก่อนที่จะเข้าชั้น output 2 classes เพื่อทำนาย การเป็น โรคนั้น กับ การไม่เป็นโรค ซึ่งเป็นการทำ Feature extraction มาต่อโดยการรวม แบบ Concatenate ของทั้ง 15 โมเดล แล้วต่อด้วย โครงข่ายประสาทเทียม เพื่อการทำนาย 15 Classes, ซึ่งด้วยเหตุผลตามข้อ 2) และ 3) จึงส่งผลให้ ค่าเฉลี่ย AUROC ทั้ง 15 Classes ของโมเดล Multi-heads มีค่าน้อยลงไปด้วย ถึงแม้ว่าจะได้ค่าที่สูงกว่า โมเดล Ensemble แต่ก็ต่ำกว่า โมเดล CNN-DenseNet121. และเมื่อนำค่า AUROC ของทั้ง 3 โมเดล คือ DenseNet 121 , Ensemble และ Multi heads เปรียบเทียบกับงานวิจัยก่อนหน้านี้ คือ โมเดล CheXNet (2017) และ ChestNet (2018) ดังแสดงในตารางที่ 4.5 จะพบว่า ค่าเฉลี่ย AUROC ของ 14 โรคนั้น จากทั้ง 3 โมเดลที่นำเสนอในงานวิจัยนี้ มีค่าต่ำกว่า CheXNet(2017) และ ChestNet(2018) แต่เมื่อพิจารณา ค่า AUROC ของแต่ละโรคนั้น จะพบว่า มีหลายๆ โรคนั้น ที่ โมเดลจากงานวิจัยนี้ให้ค่าที่สูงกว่า ดังนี้

ตารางที่ 4.5 แสดงค่า AUROC ของชุดทดสอบที่ 1 (Test-1: 20% Good Images) เปรียบเทียบกับ
โมเดล CheXNet (2017) และ ChestNet (2018)

NO.	Pathology	CheXNet	ChestNet	Our-DenseNet121*	Our Multi heads*	Our-Binary Classifier*
		(2017)	(2018)			
1	Atelectasis	0.81	0.74	0.80	0.71	0.78
2	Cardiomegaly	0.92	0.87	0.93	0.72	0.78
3	Effusion	0.86	0.81	0.89	0.79	0.81
4	Infiltration	0.73	0.68	0.67	0.57	0.61
5	Mass	0.57	0.78	0.73	0.58	0.67
6	Nodule	0.78	0.70	0.66	0.60	0.53
7	Pneumonia	0.77	0.70	0.63	0.61	0.69
8	Pneumothorax	0.89	0.81	0.82	0.71	0.76
9	Consolidation	0.79	0.73	0.81	0.78	0.83
10	Edema	0.89	0.83	0.89	0.87	0.92
11	Emphysema	0.94	0.82	0.81	0.71	0.71
12	Fibrosis	0.80	0.80	0.62	0.63	0.61
13	Pleural Thickening	0.81	0.75	0.64	0.62	0.65
14	Hernia	0.92	0.90	0.59	0.65	0.53
AUROC.average =		0.82	0.78	0.75	0.68	0.71
15	No Finding	-	-	0.79	0.73	0.74
หมายเหตุ :				(* จาก Test-1 = 20% Good Images)		
1)	CheXNet และ ChestNet ใช้ภาพนำเข้าแบบ Multi Labels.					
2)	CheXNet และ ChestNet ไม่ได้รายงาน ค่า AUROC ของ No Finding					

- 1) โมเดล DenseNet121 ให้ค่า AUROC ของโรค Cardiomegaly , Effusion, Consolidation และ Edema มากกว่า ค่า AUROC ของทั้ง CheXNet และ ChestNet
 - 2) โมเดล DenseNet121 ให้ค่า AUROC ของโรค Atelectasis , Mass, Pneumothorax, มากกว่าค่า AUROC ของ CheXNet หรือ ChestNet อันใดอันหนึ่ง
 - 3) โมเดล Multi-heads ให้ค่า AUROC ของโรค Consolidation และ Edema มากกว่า ค่า AUROC ของ CheXNet หรือ ChestNet อันใดอันหนึ่ง
- แต่โมเดล CheXNet และ ChestNet ใช้ภาพนำเข้าเป็นแบบ Multi-Label คือ 1 ภาพ มีการระบุชื่อโรค มากกว่า 1 โรค ซึ่งแตกต่างจากงานวิจัยนี้ที่ใช้แบบ Single Label คือ 1 ภาพระบุ 1 โรค เท่านั้น.

บทที่ 5

สรุปผลการทดลอง

5.1 สรุปผลการทดลอง

ผลลัพธ์ที่ได้จากโมเดล เพื่อจำแนกภาพ 2 ประเภท คือ ภาพที่เป็นโรค (Finding) และ ภาพที่ไม่เป็นโรค (No Finding) โดยที่โมเดลที่สร้างจากชุดข้อมูลภาพที่ดี (Good Images) ได้ค่าเฉลี่ย AUROC = 0.82 และ 0.80 จากชุดทดสอบที่ 1 (Test-1 = 20% Good Images) และชุดทดสอบที่ 2 (Test-2 = 20% Good Images + Outlier) สูงกว่าค่าเฉลี่ย AUROC จากโมเดลที่สร้างจากชุดข้อมูลภาพทั้งหมดที่เป็นโรคและไม่เป็นโรค ที่ได้ค่าเฉลี่ย AUROC จากการสุ่มทั้ง 3 ครั้ง = 0.68 ดังแสดงในตาราง ที่ 5.1 ซึ่งให้เห็นว่า การคัดกรองภาพเพื่อคัดแยก ภาพ ที่เป็น Outlier ออก แล้วนำภาพที่ดี (Good Images) มาสร้างเป็นโมเดลเพื่อทำนายภาพการเป็นโรคและไม่เป็นโรค เป็นแนวทางหนึ่งในการเพิ่มประสิทธิภาพของโมเดลให้มีความแม่นยำมากยิ่งขึ้น ดีกว่าการไม่มีการคัดกรองภาพอย่างมีนัยสำคัญ.

ตารางที่ 5.1 แสดงค่าวัดประสิทธิภาพ AUROC ของโมเดลจำแนกภาพเป็นโรคและไม่เป็นโรค

โมเดลที่ใช้เฉพาะภาพแบบ Good Images		โมเดลที่ใช้ภาพทั้งหมด		
AUROC		AUROC		
Test-1 = 20% Good Images	Test-2 = 20% Good Images+Outlier	สุ่มครั้งที่ 1**	สุ่มครั้งที่ 2**	สุ่มครั้งที่ 3**
0.82	0.80	0.68	0.68	0.69

ผลลัพธ์ที่ได้จากโมเดลเพื่อจำแนกภาพที่เป็นโรค 14 โรค และ ภาพที่ไม่เป็นโรค รวมเป็น 15 ประเภท โดยที่โมเดลที่สร้างจาก สถาปัตยกรรม CNN-DenesNet 121 ให้ค่าความแม่นยำ ที่วัดได้ค่าเฉลี่ย AUROC = 0.75 สูงกว่าอีก 2 โมเดล ที่นำเสนอ ดังแสดงในตารางที่ 5.2

ตารางที่ 5.2 แสดงค่าวัดประสิทธิภาพ AUROC ของโมเดลจำแนกโรคปอด

ค่าเฉลี่ย AUROC			
ชุดทดสอบ (Test)	โมเดล CNN-DenseNet121	โมเดล Ensemble	โมเดล Multi-heads
Test-1 = 20% Good Images	0.75	0.54	0.69
Test-2 = 20% Good Images + Outlier	0.73	0.53	0.66

5.2 ข้อเสนอแนะ

งานวิจัยนี้สามารถนำไปพัฒนาต่อไปให้มีประสิทธิภาพในการพยากรณ์โรค และไม่เป็นโรค ให้มีค่า AUROC สูงมากขึ้น ซึ่งจะมีผลให้การทำนายมีความแม่นยำมากขึ้น โดยมีข้อเสนอแนะดังนี้

1. เพิ่มจำนวนภาพของโรคบางโรคที่มีจำนวนน้อยในชุดฐานข้อมูล Chest X-Ray 14
2. เพิ่มประสิทธิภาพของคอมพิวเตอร์ให้สูงขึ้น เพื่อรองรับการวิเคราะห์ภาพรังสีทรวงอกที่ขนาดของภาพที่ใหญ่ขึ้น
3. ปรับปรุงเทคนิคการสร้างโมเดลให้มีประสิทธิภาพในการทำนายให้ผลลัพธ์ที่มีความแม่นยำมากขึ้น เช่น
4. เพิ่ม Attention Layers
5. เพิ่มการปรับความคมชัด (contrast) ของรูปภาพที่นำเข้า (Input) ด้วยวิธี Contrast Limited Adaptive Histogram Equalization (CLAHE)
6. เพิ่มขั้นตอนการ detect ว่าภาพที่นำเข้าเป็นภาพที่ดี (Good Images) หรือไม่ ถ้าพบว่ามีคุณภาพต่ำให้นำไปทำนายต่อว่าเป็นภาพที่เป็นโรคหรือไม่เป็นโรค และ ถ้าเป็นภาพที่ไม่ดี ก็ไม่มีการนำไปทำนายต่อ.

บรรณานุกรม

บรรณานุกรม

- Anuj Rohilla, Rahul Hooda², et al., “ TB Detection in Chest Radiograph Using Deep Learning Architecture”, *International Journal of Advance Research in Science and Engineering*, Vol. No.6, Issue No.08, August 2017
- Emanuele Pesce, Samuel Wthey.,et al.,”Learning to detect chest radiographs containing pulmonary using visual attention networks” *arXiv: 1712.00996v3*,7 Feb 2019
- F. Pasa, V. Golkov.,et al., “ Efficient Deep Network Architectures for Fast Chest X-Ray Tuberculosis Screening and Visualization”, *from www.nature.com/scientificreports/*,
Published on line, 18April2019
- Gao Huang , Zhuang Liu,et al, “ Densely Connected Convolutional Network”., *Computer Science, Computer Vision and Pattern Recognition*,: 25 August 2016
- Hongyu Wang, Yong Xiaet., et al., “ChestNet: A Deep Neural Network for Classification of Thoracic Diseases on Chest Radiography.”, *arXiv :1807.03058*, 9 Jul 2018
- Mark I. Neuman., et al., “Variability in the Interpretation of Chest Radiographs for theDiagonosis of Pneumonia in Children”.,*Journal of Hospital Medicine* Vol.7/No.4/April 2012
- Mir Muhammad Abdullah, Mir Muhammad Abdur Rahman., et al., “ Convolutional Neural Networks Model Improvement using Demographics and Image processing filter on Chest X-Rays”., *Compurt Science, Engineering. Corpus ID: 208527361*. November 2019
- Okeke Stephen., et al., “ An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare”., *Journal of Healthcare Engineering*, Volume 2019, Article ID 4180949.
- Qiwen Que, Ze Tang .,et al., “ CardioXNet : Automated Detection for Cardiomegaly Based on Deep Learning”, *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Sociery*,2018

Rajpurkar, P., et al., “CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning.”, *arXiv 25 Dec 2017*

Wang, X., et al., “ChestX-Ray8: HospitalScale Chest X-Ray Database and Benchmarkson Weakly-Supervised Classification and Localization of Common Thorax Diseases”., *IEEE Conference on Computer Vision and Pattern Recognition, 2017*

Zhicheng Huang, Dongmei Fu., “Diagnose Chest Pathology in X-Ray Image by Learning Multi-Attention Convolutional Neural Networks.”, *IEEE 8th Joint International Information Technology and Artificial Intelligence Conference, 2019.*

ภาคผนวก



The 17th National Conference on Computing and Information Technology

Proceedings of NCCIT 2021

The 17th National Conference on Computing and Information Technology

13th - 14th May 2021

at Faculty of Information Technology and Digital Innovation

King Mongkut's University of Technology North Bangkok

Bangkok, Thailand

www.nccit.net

บทความวิจัย

การประชุมทางวิชาการระดับชาติด้านคอมพิวเตอร์และเทคโนโลยีสารสนเทศ ครั้งที่ 17

13-14 พฤษภาคม 2564

ณ คณะเทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัล

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



คณะเทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัล
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



การเพิ่มประสิทธิภาพการจำแนกโรคปอดจากภาพถ่ายรังสีทรวงอก โดยการคัดกรองภาพผิดปกติ

A Filtering-Based Approach For Enhancing Chest X-Ray Classification

ไชยันต์ ชะโกทอง (Chaiyan Shagotong)¹ และชนภัทร มังคะจิตร (Thanapat Kangkachit)²
หลักสูตรวิศวกรรมข้อมูลขนาดใหญ่ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี
มหาวิทยาลัยธุรกิจบัณฑิต
¹615162020037@dpu.ac.th, ²thanapat.kan@dpu.ac.th

บทคัดย่อ

การวินิจฉัยโรคปอดจากภาพถ่ายรังสีทรวงอก (Chest X-ray) ถือเป็นหนึ่งในปัญหาที่สำคัญทางด้านคอมพิวเตอร์วิชั่น เนื่องจากมีปริมาณภาพถ่ายรังสีในบริเวณนี้มากกว่าบริเวณอื่นของร่างกาย ปัจจุบันพบว่ามีการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) เพื่อสร้างโมเดลทำนายโรคปอดจากภาพถ่ายรังสีทรวงอกที่มีความแม่นยำในการทำนายสูงขึ้นอยู่ตลอดเวลา อย่างไรก็ตาม คุณภาพของภาพถ่ายรังสีทรวงอกถือเป็นสิ่งสำคัญ ซึ่งส่งผลกระทบต่อความสามารถในการเรียนรู้รูปแบบการเกิดโรคของเทคนิคการเรียนรู้เชิงลึก ในงานวิจัยนี้จึงเสนอวิธีการเลือกเฉพาะภาพถ่ายรังสีทรวงอกที่มีคุณภาพดีโดยใช้โมเดล Encoder-Decoder ในการเรียนรู้รูปแบบการเกิดโรคของแต่ละโรคปอดทั้ง 14 โรค และภาพถ่ายรังสีทรวงอกที่ไม่เป็นโรค การคัดกรองภาพถ่ายที่พิจารณาจากค่า RE (Reconstruction Error) จากโมเดล Encoder-Decoder ที่สูงผิดปกติหรือต่ำกว่าปกติเมื่อพิจารณาจากภาพถ่ายรังสีอื่นในโรคเดียวกัน หลังจากนั้นจึงนำภาพถ่ายรังสีที่มีคุณภาพดีทั้งหมดมาสร้างโมเดลทำนายการเกิดโรคหรือไม่เกิดโรคโดยใช้โมเดล Dense-Net 121 จากผลการทดลองพบว่าโมเดลที่สร้างจากวิธีการที่นำเสนอให้ค่า AUROC เป็น 0.80 ซึ่งแม่นยำกว่าโมเดลที่สร้างจากภาพถ่ายที่ไม่มีการคัดกรองภาพผิดปกติโดยให้ค่า AUROC เป็น 0.68

คำสำคัญ: การวินิจฉัยโรคปอดบวม ภาพถ่ายรังสีทรวงอก คอมพิวเตอร์วิชั่น การเรียนรู้เชิงลึก การคัดกรองภาพผิดปกติ.

Abstract

Pneumonia classification using chest X-Ray images is one of the most crucial problems in computer vision because chest was filmed more frequently than that of the other organs. By applying deep learning techniques to construct classification models, higher accuracy can be obtained. Obviously, the quality of input images was known as an important factor affected the ability to learn patterns of deep-learning based models. This work presents the methodology to select only good-quality images (i.e. filter outlier images) by construction Encoder-Decoder models for each type of pneumonia (14 types) and no-finding images. The outlier images are considered from significantly high or low RE (Reconstruction Error) resulted from each Encoder-Decoder model. Finally, all good-quality images are used as input to construct the DenseNet-121 model to classify two classes of images i.e. (findings and no-findings). Experimental results show that our model produces 0.80 AUROC which higher than the based-line model without filtering outlier images (0.68 AUROC).

Keyword: pneumonia classification, chest X-ray images, computer vision, deep learning, outlier image filtering.

1. บทนำ (Introduction)

ปัจจุบันในทางการแพทย์ยังมีความจำเป็นที่ต้องใช้ภาพถ่ายรังสีทรวงอก (Chest X-ray) เพื่อพิจารณาการเกิดโรคที่บริเวณปอดอยู่ตลอดเวลาและมีจำนวนมากว่าภาพถ่ายรังสีในบริเวณอื่น ๆ ของร่างกาย อย่างไรก็ตามการวินิจฉัยโรคปอดจากภาพถ่ายรังสีทรวงอกจำเป็นต้องใช้นักรังสีการแพทย์ที่มีความรู้และประสบการณ์ในการอ่านภาพถ่ายรังสีทรวงอกมานานซึ่งอาจพบข้อผิดพลาดในการวินิจฉัยในบางโรคที่มีความยากในการอ่านและแปลความหมาย [1]

ปัจจุบัน ในงานวิจัยทางด้านคอมพิวเตอร์วิทัศน์มีการประยุกต์ใช้การเรียนรู้เชิงลึก (Deep Learning) ในการสร้างโมเดลที่ให้ความแม่นยำสูง สำหรับการเกิดโรคที่ปอดนั้นมีการนำการเรียนรู้เชิงลึกมาสร้างโมเดลที่ให้ประสิทธิภาพสูงซึ่งอยู่ตลอดเวลา โดยมีการนำเสนอเทคนิคการเรียนรู้เชิงลึกที่หลากหลายวิธีการ สถาปัตยกรรม ซึ่งส่งผลให้การทำงานผลลัพธ์มีความถูกต้องแม่นยำมากขึ้น ดังรายละเอียดในหัวข้อที่ 2 อย่างไรก็ตามเป็นที่ทราบกันดีว่าคุณภาพของภาพถ่ายรังสีส่งผลต่อความแม่นยำของโมเดลการเรียนรู้เชิงลึก

ในงานวิจัยนี้จึงได้เสนอแนวทางในการคัดกรองภาพถ่ายรังสีทรวงอกที่มีความผิดปกติ (Outliers) โดยจะใช้เฉพาะภาพถ่ายที่มีความปกติเท่านั้นในการสร้างโมเดลสำหรับทำนายว่าเป็นโรคปอดหรือไม่เป็นโรค แนวทางคัดกรองภาพที่ผิดปกติสำหรับแต่ละโรคใช้การสร้างโมเดล Encoder-Decoder แล้วคัดกรองภาพที่ให้ค่า RE สูงผิดปกติหรือต่ำผิดปกติ (จากการพิจารณาค่า Inter Quartile Range) หลังจากนั้นนำภาพถ่ายที่มีคุณภาพดีมาสร้างโมเดลโดยใช้สถาปัตยกรรม DenseNet-121 [12] สำหรับทำนายว่าเป็นโรคปอดหรือไม่เป็นโรคปอด ซึ่งพบว่าแนวทางที่นำเสนอให้ความแม่นยำสูงกว่า (AUROC เท่ากับ 0.80) โมเดลที่สร้างโดยไม่มีการคัดกรองภาพถ่ายที่ผิดปกติ (AUROC เฉลี่ยเท่ากับ 0.68)

2. งานวิจัยที่เกี่ยวข้อง (Literature Review)

มีหลายงานวิจัยที่ประยุกต์ใช้การเรียนรู้เชิงลึกในการสร้างแบบจำลองเพื่อช่วยในการอ่านและแปลความหมายจากภาพถ่ายรังสีทรวงอก โดยขอลกล่าวเฉพาะงานวิจัยที่สำคัญดังนี้ เริ่มจากในปี 2017 งานวิจัย [2] ได้นำเสนองานวิจัยเพื่อสร้างฐาน ข้อมูล ภาพถ่ายรังสีทรวงอกแบบใหม่ เรียกว่า "ChestX-ray8" ที่มีภาพถ่ายรังสีทรวงอกที่ระบุโรคไว้ 8 โรค ด้วยวิธี Multi-label Deep Convolutional Neural Network (DCNN) Classification Model และ วิธีประมวลผล Natural Language Processing (NLP) สกัดข้อมูลจากรายงานการแพทย์ นำมาสร้างเป็นฐานข้อมูลใหม่ ต่อมาในปี 2017 งานวิจัย[3] ได้ศึกษาการใช้ความรู้เชิงลึกเพื่อตรวจหาโรค 14 โรค จากภาพถ่ายรังสีทรวงอก จากชุดฐานข้อมูล ChestX-ray14 โดยเสนอโมเดลที่เรียกว่า "CheXNet" ประกอบด้วย 121-Layer Dense Convolutional Network (DenseNet) ให้ค่าความถูกต้อง AUROC เฉลี่ย = 0.84 , ต่อมาในปี 2018 งานวิจัย[4] ได้นำเสนอ โมเดลที่ปรับปรุงใหม่ในชื่อ "ChestNet" ที่ประกอบด้วย 2 ส่วน คือ ส่วนที่เรียกว่า Classification Branch และ ส่วนที่เรียกว่า Attention Branch ที่ให้ค่าความถูกต้อง AUROC เฉลี่ย = 0.78 ต่อมาในปี 2019 งานวิจัย[5] ได้เสนอโมเดล Multi-Attention Convolution Neural Network ที่ให้ผลลัพธ์ความถูกต้อง AUROC เฉลี่ย = 0.85 คิดว่า โมเดล CheXNet (2017) และ ChestNet (2018) นอกจากนี้มีงานวิจัย[7]ในปี 2018 ที่ใช้ความรู้เชิงลึกสร้างโมเดลที่เรียกว่า "Cardio XNet" เพื่อวินิจฉัยโรคหัวใจจากภาพถ่ายรังสีทรวงอก โดยใช้วิธี U-Net และ CNN-DenseNet และมิงานวิจัย [8] ในปี 2017 ใช้วิธี Deep Convolution Neural Network ที่เรียกว่า "AlexNet" และ "VGGNet" ทำการตรวจจับการเป็นวัณโรคจากภาพถ่ายรังสีทรวงอก

3. วิธีการดำเนินการวิจัย

ในงานวิจัยนี้มี 2 ขั้นตอนหลักคือขั้นตอนที่ 1 การคัดกรองภาพที่ผิดปกติ (Outlier) และขั้นตอนที่ 2 การสร้างโมเดลเพื่อจำแนกภาพที่เป็นโรคหรือไม่เป็นโรค ดังรายละเอียดในหัวข้อ 3.1 และ 3.2 ตามลำดับ


3.1 การคัดกรองภาพที่ผิดปกติ (Outlier)

นำภาพถ่ายรังสีทรวงอกจากชุดฐานข้อมูล ChestX-ray-14 จาก www.Kaggle.com โดยเป็นภาพที่ระบุโรค 1 โรคต่อ 1 ภาพเท่านั้น ทำการคัดกรองภาพที่ผิดปกติของแต่ละโรคแยกออกมา โดยใช้วิธีการสร้างโมเดลแบบ Encoder-Decoder ตามผังการทำงานที่แสดงในภาพที่ 1 ในการนี้ต้องทำการสร้างโมเดลทั้งหมด 15 โมเดลสำหรับแต่ละโรค (14 โรค) และภาพที่ไม่เป็นโรค (No Finding)



ในการคัดกรองภาพผิดปกติจะทำการวัดค่า MSE (Mean Square Error) ที่เกิดจากค่า loss ระหว่างภาพนำเข้าดั้งเดิม (Original) กับภาพที่เกิดจากการสร้าง (Reconstruction) จากโมเดล Encoder-Decoder โดยนำเสนอในรูปแบบกราฟแบบ Boxplot แล้วทำการเก็บบันทึกเฉพาะภาพปกติ (Good Images) ที่มีค่า MSE อยู่ระหว่างค่าขอบเขตบน (Quartile 3 - IQR) และ-ขอบเขตล่าง (Quartile 3 - IQR) เป็นภาพที่ดี ส่วนภาพที่อยู่นอกเหนือจากนี้ถือว่าเป็นภาพที่ผิดปกติ (Outlier Images) ซึ่งมีการเก็บภาพแยกต่างหาก ดังแสดงในภาพที่ 2

3.2 การสร้างโมเดลเพื่อจำแนกภาพที่เป็นโรคหรือภาพไม่เป็นโรค


ภายหลังจากคัดกรองภาพที่ผิดปกติในขั้นตอนแรกให้ทำการรวมภาพที่เป็นโรค (Findings) จากทั้ง 14 โรคให้เป็น 1 ประเภท (ภาพที่เป็นโรค) และ แยกภาพที่ไม่เป็นโรค (No Finding) ออกมาเป็นอีก 1 ประเภท แล้วจึงนำมาเป็นข้อมูลนำเข้าสำหรับโมเดลสถาปัตยกรรม CNN-DenseNet 121 ดังแสดงในภาพที่ 3 โดยทำการลดขนาดภาพจากภาพต้นฉบับ 1024x1024 (gray) ให้เป็นภาพขนาด 176 x176 (RGB) นอกจากนี้มีการใช้ Pretrained CNN-DenseNet 121 ที่สร้างจากฐานข้อมูล ImageNet การสร้าง โมเดล



ภาพที่ 1 : แสดงการคัดกรองภาพที่ผิดปกติทั้ง โรค และ ภาพ 14 ที่ไม่เป็นโรค(No Finding) โดยใช้โมเดล Encoder-Decoder



ภาพที่ 2 : แสดงหลักการแยกภาพที่ปกติและภาพที่ผิดปกติโดยใช้กราฟ Boxplot



ภาพที่ 3 : แสดงแผนผังในการสร้างโมเดลเพื่อจำแนกภาพที่เป็นโรคหรือไม่เป็นโรค โดยใช้สถาปัตยกรรม DenseNet-121

4. ผลการดำเนินงาน

4.1 การเตรียมการทดลอง

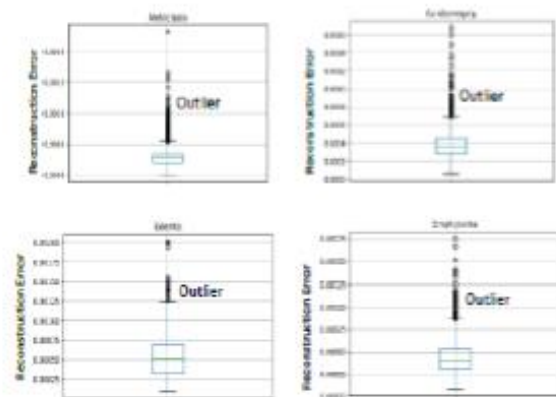
การวิจัยนี้ได้ใช้ชุดข้อมูลภาพถ่ายรังสีทรวงอกที่มีชื่อว่า "ChestX-ray14" ที่เป็นชุดข้อมูลสาธารณะ จาก www.Kaggle.com ประกอบด้วยภาพถ่ายรังสีทรวงอกจำนวน 112,120 ภาพ จากจำนวนคนไข้ 30,805 คน แต่ละภาพมีการระบุชื่อโรคกำกับไว้โดยผู้เชี่ยวชาญ ในงานวิจัยนี้จะใช้เฉพาะภาพถ่ายรังสีทรวงอกที่มีการระบุชื่อโรค 1 โรคต่อ 1 ภาพเท่านั้น ซึ่งมีทั้งหมด 14 โรค และอีก 1 ชุดภาพที่ระบุว่าไม่เป็นโรค "No Finding" ดังในตารางที่ 1 ซึ่งแสดงรายชื่อโรค และจำนวนภาพถ่ายรังสีทรวงอกของแต่ละโรคได้จำนวนภาพตามตารางที่ 1

4.2 ผลการคัดกรองภาพที่ผิดปกติ (Outliers)

การคัดกรองภาพที่ผิดปกติ โดยใช้โมเดล Encoder-Decoder และโดยใช้ค่า MSE ที่อยู่นอกเหนือช่วงขอบเขตด้านบนและด้านล่าง(Upper-Lower limit) สำหรับภาพโรค 14 โรค ดังแสดงในภาพที่ 2 และใช้ค่าในช่วง Q3-Q1 สำหรับภาพที่ไม่เป็นโรค ได้จำนวนภาพตามตารางที่ 1 และแสดงตัวอย่างผลที่ได้ในรูปแบบของกราฟ Boxplot ดังในภาพที่ 4

ตารางที่ 1. แสดงรายชื่อโรคและจำนวนภาพถ่ายรังสีทรวงอกของแต่ละโรคในชุดข้อมูล Cbest X-ray14 และจำนวนภาพที่ปกติ (Good Images) และจำนวนภาพที่ผิดปกติ (Outlier Images)

No.	Diseases Classification	Total Image	Encoder-Decoder	
			Good Image	Outlier Image
1	Atelectasis	4215	3973	242
2	Cardiomegaly	1093	1032	61
3	Consolidation	1310	1255	55
4	Edema	628	611	17
5	Effusion	3955	3683	272
6	Emphysema	892	885	7
7	Fibrosis	727	687	40
8	Hernia	110	102	8
9	Infiltration	9547	8809	738
10	Mass	2139	2004	135
11	Nodule	2705	2530	175
12	Pleural Thickening	1126	1033	93
13	Pneumonia	322	301	21
14	Pneumothorax	2194	2003	191
	Total Finding (1-14)	30963	28908	2055
15	No Finding	60361	30068	30293




ภาพที่ 4 แสดงตัวอย่างผลที่ได้จากโมเดล Encoder-Decoder ในรูปแบบของ Box Plot ของแต่ละโรค

4.3 ความแม่นยำในการจำแนกประเภทภาพที่เป็นโรคและไม่เป็นโรค




โมเดลที่ใช้ภาพแบบปกติ: สร้างจากรูปภาพที่ผ่านการคัดกรองจากในขั้นตอนที่ เท่านั้น โดยทำการแบ่งเป็น 1

ข้อมูลชุดสอนระบบ(Train) 70% , Validation 10% และ ทดสอบ (Test) 20% รวมกับภาพ Outlier ที่มีทั้งหมดของ ภาพที่เป็นโรค (2,055 ภาพ) และภาพที่ไม่เป็นโรคใน จำนวนที่เท่ากัน(2055 ภาพ) แล้วทำการวัดผล โดยใช้ค่า AUROC (Area Under Receiver Operating Characteristic) ได้เท่ากับ 0.80 ดังแสดงในภาพที่ 5

โมเดลแบบสุ่มข้อมูล: สร้างจากจำนวนรูปภาพ ทั้งหมดของภาพที่เป็นโรค แต่ในส่วนของภาพที่ไม่เป็น โรค (No Finding) ที่มีจำนวนมากจะถูกลดจำนวน รูปภาพ โดยวิธีการ Random ให้จำนวนรูปภาพเท่ากับ จำนวนรูปภาพรวมทั้งหมดของภาพที่เป็นโรค โดยทำการ Random ภาพ ครั้ง ซึ่งในแต่ละครั้งจะทำการแบ่งข้อมูล 3 เป็นข้อมูลเป็น 3 ชุดเช่นเดียวกับโมเดลที่นำเสนอ เมื่อทำ การวัด AUROC ของข้อมูลแต่ละชุดได้ผลเป็น 0.68, 0.68, และ 0.69 ตามลำดับ ซึ่งได้ค่า AUROC เฉลี่ยเป็น 0.68 ดัง แสดงในภาพ ที่ 6 และในตารางที่ 2



ภาพที่ 5 แสดงผลการวัดค่า AUROC จากโมเดลที่นำเสนอ ซึ่งใช้ เฉพาะภาพที่ปกติในการสร้างโมเดล



ภาพที่ 6 แสดงผลการวัดค่า AUROC จากโมเดลแบบสุ่มข้อมูล ที่ ทำการสุ่มภาพที่ไม่เป็นโรค (จำนวน 3ชุดข้อมูล)

ค่า

โมเดลที่ใช้ข้อมูลแบบสุ่ม

โมเดลที่ใช้ ภาพแบบปกติ	โมเดลที่ใช้ข้อมูลแบบสุ่ม (ค่า AUROC)		
	ชุดครั้งที่ 1	ชุดครั้งที่ 2	ชุดครั้งที่ 3
ค่า AUROC	0.68	0.68	0.69

5 สรุป

งานวิจัยนี้เสนอแนวทางในการเพิ่มความแม่นยำใน การทำนายภาพถ่ายรังสีทรวงอกว่าเป็นภาพถ่ายที่เป็นโรค หรือไม่เป็นโรค (Findings / No Findings) โดยการคัดกรอง ภาพถ่ายรังสีทรวงอกที่ผิดปกติออกก่อนจะทำการสร้าง

โมเดลโดยใช้เทคนิคการเรียนรู้เชิงลึก การคัดกรองภาพถ่ายตัดปกติในแต่ละโรคจะใช้โมเดล Encoder-Decoder โดยภาพที่ให้ค่า MSE สูงผิดปกติหรือค่าผิดปกติจะถูกคัดทิ้ง หลังจากนั้นนำภาพปกติที่ได้มาจัดประเภทเป็นภาพที่เป็นโรคและภาพไม่เป็นโรคแล้วนำมาสร้างโมเดลโดยใช้ CNN-DenseNet 121 ที่เป็น Pre-trained Model จากฐานข้อมูล Image-Net ผลการทดลองพบว่าโมเดลที่สร้างจากวิธีการที่นำเสนอให้ค่า AUROC เป็น 0.80 สูงกว่าโมเดลที่สุ่มข้อมูลไม่เป็นโรคซึ่งให้ AUROC เป็น 0.68 เท่านั้น อย่างไรก็ตามในขั้นตอนการทำนายภาพเป็นโรคหรือไม่นั้น สามารถปรับแต่งประสิทธิภาพของโมเดลเพิ่มเติมเพื่อให้ทำนายภาพที่เป็นโรคได้ถูกต้องทั้งหมด ถึงแม้จะมีภาพที่ไม่เป็นโรคถูกทำนายว่าเป็นโรคบ้างก็ตาม (False Alarms) เพื่อช่วยลดการทำงานของนักรังสีวิทยาได้มากขึ้นในขั้นตอนการทำงานจริง

เอกสารอ้างอิง

- [1] Mark I. Neuman., et al., "Variability in the Interpretation of Chest Radiographs for theDiagonosis of Pneumonia in Children"., *Journal of Hospital Medicine* Vol.7/No.4/April 2012
- [2] Wang, X., et al., "ChestX-Ray8: HospitalScale Chest X-Ray Database and Benchmarkson Weakly-Supervised Classification and Localization of Common Thorax Diseases"., *IEEE Conference on Computer Vision and Pattern Recognition*, 2017
- [3] Rajpurkar, P., et al., "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning.", *arXiv 25 Dec 2017*
- [4] Hongyu Wang, Yong Xiaet., et al., "ChestNet: A Deep Neural Network for Classification of Thoracic Diseases on Chest Radiography.", *arXiv :1807.03058*, 9 Jul 2018
- [5] Zhicheng Huang, Dongmei Fu., "Diagnose Chest Pathology in X-Ray Image by Learning Multi-Attention Convolutional Neural Networks.", *IEEE 5th Joint International Information Technology and Artificial Intelligence Conference*, 2019.
- [6] Okeke Stephen., et al., " An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare"., *Journal of Healthcare Engineering*, Volume 2019, Article ID 4180949.
- [7] Qiwen Que, Ze Tang .,et al., " CardioXNet : Automated Detection for Cardiomegaly Based on Deep Learning", *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*,2018
- [8] Anuj Rohilla, Rahul Hooda2., et al., " TB Detection in Chest Radiograph Using Deep Learning Architecture", *International Journal of Advance Research in Science and Engineering*, Vol. No.6, Issue No.08, August 2017
- [9] F. Pasa, V. Golkov.,et al., " Efficient Deep Network Architectures for Fast Chest X-Ray Tuberculosis Screening and Visualization", *from www.nature.com/scientificreports/*, Published on line, 18April2019
- [10] Emanuele Pesce, Samuel Wthey.,et al., "Learning to detect chest radiographs containing pulmonary using visual attention networks" *arXiv: 1712.00996v3*,7 Feb 2019
- [11] Mir Muhammad Abdullah, Mir Muhammad Abdur Rahman., et al., " Convolutional Neural Networks Model Improvement using Demographics and Image processing filter on Chest X-Rays"., *Comput Science, Engineering, Corpus ID: 208527361*. November 2019
- [12] Gao Huang , Zhuang Liu, et al, " Densely Connected Convolutional Network"., *Computer Science, Computer Vision and Pattern Recognition.*: 25 August 2016

ประวัติผู้เขียน

ชื่อ-นามสกุล

นายไชยยันต์ ชะโกทอง

ประวัติการศึกษา

วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมชลประทาน
มหาวิทยาลัยเกษตรศาสตร์ ปีการศึกษา 2526

วิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมโครงสร้าง
พื้นฐาน และการบริหาร, มหาวิทยาลัยเกษตรศาสตร์
ปีการศึกษา 2551

วิทยาศาสตรบัณฑิต สาขาเทคโนโลยีสารสนเทศและ
การสื่อสาร

มหาวิทยาลัยสุโขทัยธรรมราช

ปีการศึกษา 2560

ตำแหน่งและสถานที่ทำงานปัจจุบัน

Consultant, Civil Engineering

Foster Wheeler (Thailand) Limited.