

การจำแนกรอยโรควินิจฉัยโรคปอดด้วยโครงข่ายแคปซูล



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2561

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

CLASSIFICATION OF PULMONARY TUBERCULOSIS LESION WITH CAPSULE NETWORKS



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2018

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การจำแนกรอยโรควัฒนธรรมโรคปอดด้วยโครงข่ายแคปซูล
โดย	นายตะวันส่องแสง การย์กวินพงศ์
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.ญาใจ ลิ้มปิยะกรณ์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(รองศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.สุกรี สินธุภิญโญ)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(รองศาสตราจารย์ ดร.ญาใจ ลิ้มปิยะกรณ์)

..... กรรมการภายนอกมหาวิทยาลัย
(อาจารย์ ดร.ภาสกร อภิรักษ์วรพินิต)

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ตะวันส่องแสง การยกวินพงษ์ : การจำแนกรอยโรควัณโรคปอดด้วยโครงข่ายแคปซูล. (CLASSIFICATION OF PULMONARY TUBERCULOSIS LESION WITH CAPSULE NETWORKS) อ.ที่ปรึกษาหลัก : รศ. ดร.ญาใจ ลิ้มปิยะกรณ

การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกสำหรับการจำแนกภาพทางการแพทย์ได้มีการขยายตัวเติบโตเป็นอย่างมากในช่วงหลายปีที่ผ่านมา โครงข่ายประสาทคอนโวลูชันหรือซีเอ็นเอ็นเป็นหนึ่งในหลายแบบจำลองสมรรถนะสูงที่รู้จักกันดีสำหรับการจำแนกและการแบ่งส่วนภาพ งานวิจัยนี้เสนอแนวคิดการใช้คอมพิวเตอร์ที่สามารถช่วยวินิจฉัยในเบื้องต้นการติดเชื้อวัณโรค ผู้วิจัยได้ปรับแต่งสถาปัตยกรรมซีเอ็นเอ็นสามโครงสร้างประกอบด้วย อเล็กซ์เน็ต วีจีจี-16 และแคปส์เน็ต เพื่อจำแนกรอยโรควัณโรคบนภาพเอกซเรย์ทรวงอกหรือซีเอกซ์อาร์ที่ได้มาจากไลบรารีทางการแพทย์แห่งชาติและชุดข้อมูลไทยส่วนตัว ตัววัดที่ใช้ประเมินสมรรถนะตัวจำแนกประเภททั้งสาม ได้แก่ ความแม่นยำ ความไว และความจำเพาะ การทดสอบแบบจำลองทั้งสามบนชุดข้อมูลที่เพิ่มจำนวนด้วยการสุ่มตัวอย่างแบบสับเปลี่ยนให้ผลลัพธ์ค่าความแม่นยำที่เพิ่มขึ้นทุกแบบจำลอง นอกจากนี้ ยังได้มีการประเมินสมรรถนะแบบจำลองบนชุดข้อมูลที่เพิ่มจำนวนตัวอย่างด้วยการหมุนภาพ เนื่องจากในความเป็นจริงภาพซีเอกซ์อาร์อาจไม่ได้ตั้งตรงในแนวตั้ง ผลการประเมินพบว่าแคปส์เน็ตให้ค่าตัววัดที่ดีกว่าแบบจำลองอเล็กซ์เน็ต และวีจีจี-16 เมื่อทำนายภาพแอฟฟิน



สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2561

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

5971007321 : MAJOR COMPUTER SCIENCE

KEYWORD: Capsule Network, Convolutional Neural Networks, Chest X-ray,
Tuberculosis, Computer-aided Diagnosis

Tawansongsang Karnkawinpong : CLASSIFICATION OF PULMONARY
TUBERCULOSIS LESION WITH CAPSULE NETWORKS. Advisor: Assoc. Prof.
Yachai Limpiyakorn, Ph.D.

Applying deep learning techniques for classification of medical images has seen considerable growth in recent years. Among several, Convolutional Neural Networks (CNNs) are a class of powerful models well known for image classification and segmentation. This research presents the concept of computer-aided diagnosis that could help in early diagnosis of Tuberculosis infection. The three CNN architectures: AlexNet, VGG-16 and CapsNet, were customized to classify tuberculosis lesions in Chest X-Ray (CXR) images acquired from National Library of Medicine and private Thai datasets. The performance of the three classifiers was evaluated with the measures: accuracy, sensitivity and specificity. Testing on the dataset augmented with shuffle sampling resulted in increasing accuracy of all the three models. As in the real world, CXR images may not be precisely vertical, further assessment of the model performance using data augmented with rotating was carried out. We found that CapsNet outperformed the other models when predicting affined images.

Field of Study: Computer Science

Student's Signature

Academic Year: 2018

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความอนุเคราะห์อย่างยิ่งของรองศาสตราจารย์ ดร.ญาใจ ลิ้มปิยะกรณ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ซึ่งท่านได้กรุณาสละเวลาให้ความรู้ ให้คำปรึกษา ตรวจสอบ ให้คำแนะนำแนวทางการวิจัย และสนับสนุนจนทำให้การวิจัยในครั้งนี้สำเร็จลุล่วงด้วยดี ข้าพเจ้าจึงขอกราบระลึกพระคุณรองศาสตราจารย์ ดร.ญาใจ ลิ้มปิยะกรณ ไว้ ณ ที่นี้

ข้าพเจ้าขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.สุกรี สิ้นธุภิณูญ และ ดร.ภาสกร อภิรักษ์วรพินิต กรรมการสอบวิทยานิพนธ์ ที่ได้กรุณาสละเวลา ให้คำแนะนำ ตรวจสอบ และแก้ไข วิทยานิพนธ์ฉบับนี้ให้ถูกต้องสมบูรณ์ยิ่งขึ้น

ข้าพเจ้าขอขอบพระคุณเจ้าหน้าที่กรมควบคุมโรค กระทรวงสาธารณสุขเป็นอย่างยิ่ง ที่ได้ให้คำแนะนำทางวิชาการและการสืบค้นแหล่งข้อมูลที่สำคัญในการวิจัยครั้งนี้

ท้ายนี้ข้าพเจ้าขอกราบขอบพระคุณ คุณพ่อ คุณแม่ และครอบครัวสำหรับกำลังใจที่มีค่ายิ่ง รวมถึงขอขอบพระคุณผู้บังคับบัญชาในสายงาน เพื่อนร่วมงาน และมิตรสหาย ที่คอยติดตามให้กำลังใจ ให้การสนับสนุนและความช่วยเหลือในด้านต่าง ๆ และท่านอื่น ๆ ที่มีได้กล่าวชื่อไว้ ณ ที่นี้ที่มีส่วนช่วยให้ วิทยานิพนธ์ของข้าพเจ้าสำเร็จไปได้ด้วยดี

ตะวันส่องแสง การย์กวินพงศ์

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตการดำเนินงาน.....	3
1.4 ขั้นตอนการวิจัย.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.6 ลำดับการจัดเรียงเนื้อหาในวิทยานิพนธ์.....	3
1.7 ผลงานที่ตีพิมพ์จากวิทยานิพนธ์.....	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 ทฤษฎีที่เกี่ยวข้อง.....	5
2.1.1 การวินิจฉัยวัณโรคปอดจากฟิล์มเอกซเรย์ [8].....	5
2.1.2 การเรียนรู้เชิงลึก (Deep Learning) [9].....	5
2.1.3 โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network) [10].....	6

2.1.4	โครงข่ายแคปซูล (Capsule Network).....	9
2.2	งานวิจัยที่เกี่ยวข้อง	10
2.2.1	Learning to Read Chest X-Ray Images from 16000+ Examples Using CNN [14] 10	
2.2.2	A novel approach for tuberculosis screening based on deep convolutional neural networks [15]	11
2.2.3	Improving Tuberculosis Diagnostics using Deep Learning and Mobile Health Technologies among Resource-poor and Marginalized Communities [16]	11
2.2.4	Deep-learning: A Potential Method for Tuberculosis Detection using Chest Radiography [18].....	12
2.2.5	TX-CNN: DETECTING TUBERCULOSIS IN CHEST X-RAY IMAGES USING CONVOLUTIONAL NEURAL NETWORK [19]	13
2.2.6	Comparing deep learning models for population screening using chest radiography [20].....	15
2.2.7	Chest X-Ray Analysis of Tuberculosis by Deep Learning with Segmentation and Augmentation [22].....	16
2.2.8	Automated Tuberculosis Classification of Chest Radiographs by Using Convolutional Neural Networks [23]	17
บทที่ 3	แนวคิดและวิธีวิจัย	18
3.1	การเตรียมชุดข้อมูล	18
3.1.1	การเพิ่มข้อมูลด้วยเทคนิค shuffle sampling	19
3.1.2	การเพิ่มชุดข้อมูลด้วยเทคนิคหมุนภาพ (Rotation)	20
3.1.3	การเตรียมชุดข้อมูลสำหรับการทดสอบภาพผิดปกติ	21
3.2	การสร้างแบบจำลองการทำนายวัณโรคปอด.....	22
3.2.1	โครงข่ายประสาทคอนโวลูชันแบบอเล็กซ์เน็ต.....	23

3.2.2	โครงข่ายประสาทคอนโวลูชันแบบ วีจีจี-16.....	25
3.2.3	โครงข่ายโครงข่ายแคปซูล (Capsule Network).....	26
3.3	การประเมินแบบจำลองทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอก.....	27
บทที่ 4	การทดลองและผลการทดลอง	29
4.1	ระบบที่ใช้ในการทดลอง	29
4.1.1	คอมพิวเตอร์ที่ใช้ในการทดลอง.....	29
4.1.2	การเขียนโปรแกรมและเฟรมเวิร์กที่ใช้ในการทดลอง	29
4.2	ชุดข้อมูลที่ใช้ในการทดลอง.....	29
4.2.1	การเพิ่มขนาดชุดข้อมูลด้วยเทคนิค Shuffle sampling	30
4.2.2	การเพิ่มชุดข้อมูลด้วยเทคนิคการหมุนภาพ	32
4.2.3	การแบ่งข้อมูล	32
4.2.4	การเตรียมชุดข้อมูลทดสอบภาพเอกซเรย์ทรวงอกที่บิดเบี้ยว	33
4.3	การดำเนินการทดลอง	33
4.3.1	การสอนแบบจำลอง (Model Training)	33
4.3.2	การทดสอบแบบจำลอง (Model Testing).....	34
4.4	ผลการทดลอง.....	35
4.4.1	ผลการทดลองของ อเล็กซ์เน็ต.....	35
4.4.2	ผลการทดลองของ วีจีจี-16	36
4.4.3	ผลการทดลองของโครงข่ายแคปซูล (แคปส์เน็ต).....	38
4.4.4	เปรียบเทียบผลการทดลองทั้ง 3 แบบจำลองกับจำนวนชุดข้อมูลที่แตกต่างกัน	39
4.4.5	ผลการทดลองการทำนายรอยโรควัณโรคปอดจากภาพที่บิดเบี้ยว.....	41
4.5	วิเคราะห์ผลการทดลอง	45
บทที่ 5	สรุปผลการวิจัยและข้อเสนอแนะ	48
5.1	สรุปการวิจัย	48

5.2 ข้อเสนอแนะ.....	49
บรรณานุกรม.....	51
ประวัติผู้เขียน.....	54



สารบัญตาราง

	หน้า
ตารางที่ 1 ค่าเฉลี่ยความถูกต้องของแบบจำลอง [16]	12
ตารางที่ 2 ค่าความแม่นยำของ optimizer แต่ละตัว [18].....	13
ตารางที่ 3 คำอธิบายฐานข้อมูลที่ใช้ในงานวิจัย [19].....	14
ตารางที่ 4 ชุดข้อมูลของ Shenzhen, Montgomery, Kenya และ India [20].....	15
ตารางที่ 5 ค่าความแม่นยำและ AUC ของ customized model [20]	16
ตารางที่ 6 ค่าความแม่นยำแบบจำลอง CNN ที่มีโครงสร้างแบบต่าง ๆ [20]	16
ตารางที่ 7 รายละเอียดโครงสร้างของอเล็กซ์เน็ตที่ปรับแต่งแล้วแต่ละชั้น	24
ตารางที่ 8 รายละเอียดของโครงสร้างของ วีจีจี-16 ที่ปรับแต่งแล้วแต่ละชั้น	26
ตารางที่ 9 รายละเอียดโครงสร้างโครงข่ายแคปซูลที่ปรับแต่งแล้ว	27
ตารางที่ 10 รายละเอียดของคอนฟิวชันเมทริกซ์	28
ตารางที่ 11 รายละเอียดฐานข้อมูลทั้ง 5 ฐาน.....	30
ตารางที่ 12 รายละเอียดจำนวนภาพที่แบ่งเป็น 3 category	32
ตารางที่ 13 สรุปจำนวนภาพทั้งหมดที่เพิ่มขึ้นด้วยเทคนิคต่าง ๆ.....	32
ตารางที่ 14 การประเมินสมรรถนะแบบจำลองอเล็กซ์เน็ตที่ใช้ชุดข้อมูลที่มีจำนวนต่างกัน	36
ตารางที่ 15 การประเมินสมรรถนะแบบจำลองวีจีจี-16 ที่ใช้ชุดข้อมูลที่มีจำนวนต่างกัน	37
ตารางที่ 16 การประเมินสมรรถนะแบบจำลองแคปซูลเน็ตที่ใช้ชุดข้อมูลที่มีจำนวนต่างกัน	38
ตารางที่ 17 ประสิทธิภาพของแบบจำลองทั้ง 3 แบบ	39
ตารางที่ 18 ผลการทดลองแบบจำลองที่สร้างจากข้อมูลที่ไม่ได้เพิ่มข้อมูลด้วยการหมุนภาพ.....	42
ตารางที่ 19 ผลการทดลองแบบจำลองที่สร้างจากข้อมูลที่ได้เพิ่มข้อมูลด้วยการหมุนภาพ	45

สารบัญภาพ

	หน้า
ภาพที่ 1 ภาพเอกซเรย์ทรวงอกที่ปกติ	5
ภาพที่ 2 โครงสร้างโครงข่ายประสาทเทียม	6
ภาพที่ 3 โครงสร้างโครงข่ายประสาทคอนโวลูชัน [11].....	6
ภาพที่ 4 ตัวอย่างเอาต์พุตเมื่อเมทริกซ์อินพุตผ่านตัวกรอง [12].....	7
ภาพที่ 5 ตัวอย่างการทำขั้นการรวม	8
ภาพที่ 6 ตัวอย่างโครงสร้างเต็มรูปแบบของโครงข่ายประสาทคอนโวลูชัน [13].....	8
ภาพที่ 7 โครงสร้างส่วนเข้ารหัสของแคปซูล [7].....	10
ภาพที่ 8 โครงสร้างส่วนถอดรหัสของแคปซูล [7].....	10
ภาพที่ 9 ตัวอย่างภาพเอกซเรย์ทรวงอกที่เป็นโรคต่าง ๆ [14].....	11
ภาพที่ 10 ชุดข้อมูลภาพเอกซเรย์ทรวงอก [16].....	12
ภาพที่ 11 โครงสร้าง CNN ที่เสนอใน [18].....	13
ภาพที่ 12 ขั้นตอนการทำ shuffle sampling เพื่อจัดการข้อมูล imbalanced data [19].....	14
ภาพที่ 13 โครงสร้างของ Customized model [20].....	15
ภาพที่ 14 ตัวอย่างของภาพเอกซเรย์ทรวงอกที่ตัดบริเวณเฉพาะส่วนที่เป็นปอด [22].....	17
ภาพที่ 15 โครงสร้าง ResNet [23]	17
ภาพที่ 16 ตัวอย่างภาพที่ปกติ (ซ้าย) และมีรอยโรควิณโรค (ขวา).....	18
ภาพที่ 17 ตัวอย่างกระบวนการย่อขนาดภาพเอกซเรย์ทรวงอก.....	19
ภาพที่ 18 แผนภาพขั้นตอนวิธี shuffle sampling.....	19
ภาพที่ 19 กระบวนการเพิ่มข้อมูลด้วยเทคนิค shuffle sampling	20
ภาพที่ 20 ตัวอย่างภาพเอกซเรย์ทรวงอก ก) ภาพต้นฉบับไม่มีการหมุน ข) ภาพหมุนด้วยมุม 90 องศา ค) ภาพหมุนด้วยมุม 180 องศา ง) ภาพหมุนด้วยมุม 270 องศา	21

ภาพที่ 21	ขั้นตอนการเพิ่มข้อมูลด้วยเทคนิคการหมุนภาพ.....	21
ภาพที่ 22	ตัวอย่างภาพที่หมุนด้วยมุมที่มีค่าน้อย.....	21
ภาพที่ 23	ตัวอย่างภาพเอกซเรย์ทรวงอกที่บิดเบี้ยวและภาพเอกซเรย์ทรวงอกของผู้ป่วยที่มีกระดูกสันหลังผิดปกติ.....	22
ภาพที่ 24	ตัวอย่างภาพเปรียบเทียบระหว่างรูปร่างปอด.....	22
ภาพที่ 25	โครงสร้างของอเล็กซ์เน็ตที่ปรับแต่งแล้ว	24
ภาพที่ 26	โครงสร้างของ วิธีจี-16 ที่ปรับแต่งแล้ว	25
ภาพที่ 27	โครงสร้างโครงข่ายแคปซูลที่ปรับแต่งแล้ว.....	27
ภาพที่ 28	ภาพจำลองนิยามของ TP, TN, FP และ FN	28
ภาพที่ 29	ภาพขั้นตอนวิธี Shuffle sampling ที่แบ่งข้อมูลเป็น 5 category	31
ภาพที่ 30	ภาพขั้นตอนวิธี Shuffle sampling ที่แบ่งข้อมูลเป็น 3 category	31
ภาพที่ 31	ตัวอย่างการเลือกใช้แบบจำลองที่ดีที่สุด.....	34
ภาพที่ 32	ตัวอย่างการหยุดการเรียนรู้ของแบบจำลอง.....	34
ภาพที่ 33	ตัวอย่างการไหลค่าน้ำหนักของแบบจำลอง.....	35
ภาพที่ 34	กราฟการเรียนรู้ อเล็กซ์เน็ต.....	36
ภาพที่ 35	กราฟการเรียนรู้ วิธีจี-16	37
ภาพที่ 36	กราฟการเรียนรู้ แคปส์เน็ต.....	38
ภาพที่ 37	กราฟการเรียนรู้ทั้ง 3 แบบจำลองกับชุดข้อมูลที่ไม่ได้เพิ่มจำนวน.....	40
ภาพที่ 38	กราฟการเรียนรู้ทั้ง 3 แบบจำลองกับชุดข้อมูลที่เพิ่มจำนวนข้อมูลเป็น 1986 ภาพ.....	40
ภาพที่ 39	กราฟการเรียนรู้ทั้ง 3 แบบจำลองกับชุดข้อมูลที่เพิ่มจำนวนข้อมูลเป็น 3310 ภาพ.....	41
ภาพที่ 40	ตัวอย่างชุดข้อมูลทดสอบภาพเอกซเรย์ทรวงอก.....	42
ภาพที่ 41	กราฟการเรียนรู้ของแบบจำลอง อเล็กซ์เน็ต ด้วยชุดข้อมูลสอนที่เพิ่มด้วยเทคนิคการหมุน	44
ภาพที่ 42	กราฟการเรียนรู้ของแบบจำลอง วิธีจี-16 ด้วยชุดข้อมูลสอนที่เพิ่มด้วยเทคนิคการหมุน..	44

ภาพที่ 43 กราฟการเรียนรู้ของแบบจำลอง แคปส์เน็ต ด้วยชุดข้อมูลสอนที่เพิ่มด้วยเทคนิคการหมุน

..... 45



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

โรคที่เกิดขึ้นกับบริเวณทรวงอกที่สำคัญโรคหนึ่งคือ วัณโรคปอด จากข้อมูลสถิติปีพ.ศ. 2559 ขององค์การอนามัยโลก (The World Health Organization, WHO) พบผู้ที่ตายจากวัณโรคทั่วโลกมี 1.8 ล้านคน และเจอผู้ป่วยรายใหม่มากกว่า 9 ล้านคน ส่วนมากพบในแถบภาคเอเชียตะวันออกเฉียงใต้ แอฟริกาตะวันตกและแอฟริกามากกว่าร้อยละ 80 [1] ในประเทศไทย ข้อมูลสถิติปีพ.ศ. 2560 ของกรมควบคุมโรค กระทรวงสาธารณสุข พบผู้ป่วย 40,000 ราย ผู้ติดเชื้อประมาณ 20 ล้านคน วัณโรคเป็นโรคติดต่อและโรคระบาดที่มักพบในแถบที่มีการควบคุมด้านสุขอนามัยไม่ดีพอ ผู้ที่ติดเชื้อส่วนใหญ่ยังไม่แสดงอาการป่วยในทันที แต่หากร่างกายอ่อนแอ เช่น เป็นโรคเบาหวาน โรคเอดส์ ร่างกายจะเกิดอาการป่วยของวัณโรคปอด ซึ่งถ้าหากไม่รักษาอย่างถูกวิธีจะทำให้เกิดการเสียชีวิตและจะแพร่เชื้อไปสู่บุคคลอื่น ทำให้เกิดโรคระบาดขึ้นได้ วัณโรคพบมากบริเวณปอดซึ่งจะเรียกว่า วัณโรคปอด (Pulmonary Tuberculosis- PTB) รอยโรคที่พบส่วนใหญ่จะเกิดขึ้นที่บริเวณช่วงปอดส่วนบน โดยแพทย์จะวินิจฉัยวัณโรคปอดเบื้องต้นจากภาพฟิล์มเอกซเรย์ทรวงอก (Chest X-ray)

การถ่ายภาพฟิล์มเอกซเรย์ทรวงอกเป็นขั้นตอนเบื้องต้นในการตรวจหาสาเหตุความผิดปกติของอวัยวะในร่างกายนอกบริเวณทรวงอก เช่น โรคกระดูก วัณโรค น้ำท่วมปอด ฯลฯ ซึ่งทางโรงพยาบาลมีให้บริการแทบทุกแห่ง เนื่องจากเป็นวิธีที่สะดวกรวดเร็ว ค่าใช้จ่ายไม่แพงมาก ราคาเครื่องมืออุปกรณ์มีราคาถูกกว่าการตรวจด้วยวิธีอื่น ภาพถ่ายเอกซเรย์ทรวงอกสามารถแสดงถึงโครงสร้าง อวัยวะภายในร่างกายนอกบริเวณทรวงอกได้เป็นอย่างดี ทั้งนี้ การอ่านผลฟิล์มเอกซเรย์ทรวงอก แพทย์จะนำภาพเอกซเรย์ทรวงอกมาดูประกอบร่วมกับอาการที่แสดง เพื่อการวินิจฉัยโรคของผู้ป่วยจากลักษณะที่ผิดปกติบริเวณทรวงอกในฟิล์มเอกซเรย์ ซึ่งจำเป็นต้องใช้ความชำนาญของแพทย์ในการตรวจหาวัณโรคปอด อย่างไรก็ตาม ความชัดของรายละเอียดบนฟิล์มเอกซเรย์ของผู้ป่วยแต่ละคนไม่เท่ากัน เนื่องจากการปรับค่ารังสีของนักรังสีเทคนิคที่มีความชำนาญต่างกันหรือจากสรีระคนไข้เอง เช่น อ้วน ผอม หรือกระดูกบิดเบี้ยว ฯลฯ ทำให้ภาพฟิล์มเอกซเรย์คนไข้บางรายแสดงรายละเอียดได้ไม่ชัดเจนเท่าที่ควรและแพทย์ไม่ได้มีเวลามากพอที่จะวินิจฉัย ส่งผลให้อาจเกิดข้อผิดพลาดในการวินิจฉัยโรคได้ การใช้แบบจำลองช่วยทำนายวัณโรคปอดจากภาพฟิล์มเอกซเรย์จะสามารถช่วยให้แพทย์ลดระยะเวลาที่ใช้ในการวินิจฉัยและเพิ่มความถูกต้องในการวินิจฉัยได้

การเรียนรู้ด้วยเครื่อง (Machine Learning) เป็นเทคนิคที่ใช้วิเคราะห์และหาความสัมพันธ์ของข้อมูลที่มีอยู่เพื่อให้ได้ค่าที่เหมาะสมที่สุดในทางคณิตศาสตร์ การเรียนรู้เชิงลึก (Deep Learning) เป็นเซตย่อยของการเรียนรู้ด้วยเครื่อง ซึ่งเลียนแบบการทำงานของสมองมนุษย์ในกระบวนการประมวลผล

ข้อมูลและสร้างแพทเทิร์นสำหรับใช้ในการตัดสินใจ ปัจจุบัน มีงานวิจัยต่าง ๆ มากมายที่ใช้เทคนิคการเรียนรู้เชิงลึกมาประยุกต์ใช้กับงานหลายๆด้านอย่างแพร่หลายทั้งในเชิงพาณิชย์ ทางการแพทย์ วิศวกรรม ฯลฯ โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Networks- CNN) เป็นรูปแบบหนึ่งของการเรียนรู้เชิงลึก ประกอบด้วยโครงสร้างหลากหลายรูปแบบมาเชื่อมต่อกัน ปัจจุบันการจำแนกประเภทรูปภาพด้วยโครงข่ายประสาทคอนโวลูชันเป็นเทคนิคที่ให้ประสิทธิภาพในการจำแนกได้ดีที่สุดเมื่อเทียบกับการใช้เทคนิคเก่า เช่น ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) หรือโครงข่ายประสาทเทียม (Artificial Neural Networks) เป็นต้น โครงข่ายประสาทคอนโวลูชันไม่ต้องทำการแบ่งส่วน (Segmentation) และการคัดเลือกคุณลักษณะ (Feature Selection) โครงข่ายประสาทคอนโวลูชันจะทำการคัดเลือกคุณลักษณะให้โดยอัตโนมัติด้วยโครงสร้างของโครงข่ายในรูปแบบต่าง ๆ ด้วยตัวเอง

นักวิจัยได้พัฒนาโครงข่ายประสาทคอนโวลูชันให้เกิดโครงสร้างแบบต่าง ๆ ตั้งแต่ AlexNet ในปี 2555 [2] VGG ในปี 2557 [3] Inception ในปี 2558 [4] ResNet ในปี 2558 [5] และ Xception ในปี 2559 [6] โครงข่ายประสาทคอนโวลูชันที่เป็นโครงสร้างล่าสุดเสนอโดย Hinton ในปี 2560 คือโครงข่ายแคปซูลหรือแคปส์เน็ต (Capsule Network- CapsNet) [7] โครงข่ายแคปซูลเป็นแบบจำลองที่มีประสิทธิภาพในการจำแนกประเภทรูปภาพได้ดีกว่าโครงสร้างอื่น ๆ โดยใช้ข้อมูล MNIST และนักวิจัยได้อ้างว่าโครงข่ายแคปซูลสามารถจำแนกข้อมูลประเภทการแปลงแอฟฟิน (Affine Transformation) ได้ดีกว่าโครงสร้างแบบเดิมๆ โดยข้อมูลแอฟฟินไม่จำเป็นต้องถูกนำมาเรียนรู้ในแบบจำลอง งานวิจัยนี้จึงมีแนวคิดว่าเสนอการประยุกต์ใช้โครงข่ายแคปซูลสำหรับการจำแนกภาพดิจิทัลเอกซเรย์ทรวงอกที่มีรอยโรคฉีกขาดจากปอดปกติด้วยชุดข้อมูลภาพดิจิทัลเอกซเรย์ทรวงอกที่ไม่บิดเบี้ยวและชุดข้อมูลภาพดิจิทัลเอกซเรย์ทรวงอกที่บิดเบี้ยว เพื่อช่วยให้ขั้นตอนต่อไปของการวินิจฉัยโรคด้วยแพทย์ รวดเร็ว มีประสิทธิภาพยิ่งขึ้น และเพื่อให้แบบจำลองสามารถจำแนกภาพดิจิทัลเอกซเรย์ทรวงอกของผู้ป่วยที่มีโรคกระดูกสันหลังคดได้ การประเมินความแม่นยำของแบบจำลองผลลัพธ์โครงข่ายแคปซูล จะเปรียบเทียบกับความแม่นยำของแบบจำลองโครงข่ายประสาทคอนโวลูชัน ซึ่งใช้กันอย่างแพร่หลายในงานรู้จำภาพ (Image Recognition)

1.2 วัตถุประสงค์ของงานวิจัย

ศึกษาและพัฒนาแบบจำลองโครงข่ายแคปซูลสำหรับตรวจหาโรคการติดเชื้อวัณโรคปอดจากภาพดิจิทัลเอกซเรย์ทรวงอก และประเมินเปรียบเทียบสมรรถนะของแบบจำลองผลลัพธ์ที่ได้จากวิธีการที่นำเสนอกับโครงข่ายคอนโวลูชันอื่นที่นิยมใช้ในการจำแนกภาพ

1.3 ขอบเขตการดำเนินงาน

- 1) ชุดข้อมูลสอนคือ ภาพดิจิทัลเอกซเรย์ทรวงอกจากฐานข้อมูล NLM และฐานข้อมูลไทยจากกระทรวงสาธารณสุข
- 2) สร้างแบบจำลอง CNNs และโครงข่ายแคปซูล โดยใช้ไลบรารีภาษา Python คือ Tensorflow และ Keras โดยใช้ตัวประมวลผล GPU
- 3) เปรียบเทียบสมรรถนะในการจำแนกรอยโรคผิวหนังโรคปอดของแบบจำลองโครงข่ายแคปซูลกับแบบจำลอง CNNs โดยใช้ชุดข้อมูลปกติกับชุดข้อมูลที่มีการเพิ่มจำนวนตัวอย่าง
- 4) เปรียบเทียบสมรรถนะในการจำแนกรอยโรคผิวหนังโรคปอดของแบบจำลองโครงข่ายแคปซูลกับแบบจำลอง CNNs กรณีที่ชุดข้อมูลมีการเพิ่มตัวอย่างด้วยการแปลงแอฟฟิน และทดสอบกับชุดทดสอบที่มีภาพดิจิทัลเอกซเรย์ทรวงอกที่สร้างขึ้นเพื่อจำลองภาพของผู้ป่วยที่กระดุกสันหลังคด

1.4 ขั้นตอนการวิจัย

- 1) ศึกษาและทำความเข้าใจทฤษฎีและงานวิจัยที่เกี่ยวข้อง
- 2) ศึกษาและเลือกเครื่องมือสำหรับสร้างแบบจำลองการเรียนรู้โครงข่ายประสาทคอนโวลูชัน
- 3) เก็บรวบรวมข้อมูลสอนภาพดิจิทัลเอกซเรย์ทรวงอก
- 4) เตรียมชุดภาพข้อมูลให้เหมาะสมกับการสร้างแบบจำลอง
- 5) สร้างแบบจำลอง ทดสอบ และปรับแต่งเพิ่มความแม่นยำ
- 6) วิเคราะห์และประเมินผลการวิจัย
- 7) สรุปผลการวิจัยและข้อเสนอแนะ
- 8) ตีพิมพ์ผลงานทางวิชาการ
- 9) จัดทำวิทยานิพนธ์

1.5 ประโยชน์ที่คาดว่าจะได้รับ

ได้แบบจำลองทำนายรอยโรคผิวหนังโรคปอดจากภาพดิจิทัลเอกซเรย์ทรวงอก ซึ่งสามารถลดระยะเวลาการตรวจวินิจฉัยโรคปอดของแพทย์ในเบื้องต้นได้

1.6 ลำดับการจัดเรียงเนื้อหาในวิทยานิพนธ์

วิทยานิพนธ์นี้มีทั้งหมด 6 บท ดังต่อไปนี้ บทที่ 1 บทนำความเป็นมาและความสำคัญของปัญหา วัตถุประสงค์ของการวิจัย ขอบเขตการวิจัย ประโยชน์ที่คาดว่าจะได้รับ และผลงานตีพิมพ์ บท

ที่ 2 ทฤษฎีที่เกี่ยวข้อง บทที่ 3 งานวิจัยที่เกี่ยวข้อง บทที่ 4 แนวคิดและวิธีวิจัย บทที่ 5 ผลการทดลอง และวิเคราะห์ผล และบทที่ 6 สรุปผลการวิจัย

1.7 ผลงานที่ตีพิมพ์จากวิทยานิพนธ์

ส่วนหนึ่งของวิทยานิพนธ์ได้รับการตีพิมพ์บทความวิชาการ 2 บทความ ประกอบด้วย

- 1) T. Karnkawinpong and Y. Limpiyakorn, “ Classification of Pulmonary Tuberculosis Lesion with Convolutional Neural Networks” ในรายงานการประชุมวิชาการนานาชาติสืบเนื่องจาก 11th International Conference on Computer and Electrical Engineering (ICCEE 2018), October 12-14, 2018, Tokyo, Japan.
- 2) T. Karnkawinpong and Y. Limpiyakorn, “Chest X-Ray Analysis of Tuberculosis by Convolutional Neural Networks with Affine Transforms” ในรายงานการประชุมวิชาการนานาชาติสืบเนื่องจาก 2nd International Conference on Computer Science and Artificial Intelligence (CSAI 2018) , December 8-10, 2018, Shenzhen University, Shenzhen, China.

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 การวินิจฉัยวัณโรคปอดจากฟิล์มเอกซเรย์ [8]

การถ่ายภาพรังสีเอกซเรย์ทรวงอกมีพื้นฐานมาจากการค้นพบรังสีชนิดหนึ่งโดยวิลเฮล์ม คอนราด เรินต์เกน (Wilhelm Conrad Röntgen) ซึ่งมีคุณสมบัติพิเศษที่สามารถทะลุผ่านวัตถุต่าง ๆ และเมื่อแปลงใส่ฟิล์มเอกซเรย์จะมีความเข้มขึ้นของการทะลุผ่านวัตถุแตกต่างกันเป็นระดับ ถ้าเป็นวัตถุที่มีความหนาแน่นสูง เช่น โลหะ จะเห็นเป็นสีขาวในภาพฟิล์มเอกซเรย์ แต่ถ้ารังสีผ่านความหนาแน่นต่ำเช่น อากาศ จะเห็นเป็นสีดำ ส่วนเนื้อเยื่อ น้ำ จะเห็นเป็นสีกึ่งขาวจางเทา ทำให้แพทย์อ่านผลจากฟิล์มเอกซเรย์เห็นเป็นรูปร่างอวัยวะและเห็นลักษณะผิดปกติได้

ในภาพฟิล์มเอกซเรย์ทรวงอกจะเห็นอวัยวะปอดมีลักษณะสีดำดังภาพที่ 1 เนื่องจากปอดมีลักษณะที่โปร่งมีลมหรืออากาศอยู่มาก ส่วนเส้นเลือดและหัวใจจะเห็นเป็นลักษณะสีขาวเป็นมีความหนาแน่นมากกว่า แต่เมื่อผู้ป่วยเป็นวัณโรคปอดจะเห็นลักษณะสำคัญที่ใช้วินิจฉัยโรคได้คือ จะมีพยาธิสภาพที่ปอดด้านบน เมื่อมีการติดเชื้อจะเกิดการอักเสบทำให้เห็นบริเวณติดเชื้อมีสีขาวกว่าปอดปกติ บางครั้งเห็นเป็นโพรง (Cavity) เห็นเป็นน้ำหนองหรือมีน้ำในช่องเยื่อปอด ลักษณะเช่นนี้ทำให้แพทย์วินิจฉัยโรคได้




ภาพที่ 1 ภาพเอกซเรย์ทรวงอกที่ปกติ

2.1.2 การเรียนรู้เชิงลึก (Deep Learning) [9]

การเรียนรู้เชิงลึกเป็นส่วนหนึ่งในการเรียนรู้ของเครื่อง (Machine learning) มีพื้นฐานมาจากโครงข่ายประสาทเทียม (Artificial Neural Network- ANN) ซึ่งโครงสร้างของโครงข่ายประสาทเทียมแบบปกติ ดังภาพที่ 2 จะประกอบด้วยชั้นอินพุต (Input Layer) ชั้นฮิดเด้น (Hidden Layer)


และชั้นเอาต์พุต (Output Layer) แต่ละชั้นจะประกอบด้วยเพอร์เซปตรอน (Perceptron) ในการเรียนรู้เชิงลึก โครงสร้างของโครงข่ายประสาทเทียมจะประกอบด้วยชั้นจำนวนมากระหว่างชั้นอินพุต และชั้นเอาต์พุต ซึ่งไม่จำเป็นต้องเป็นชั้นที่สร้างจากเพอร์เซปตรอนเท่านั้น ยังสามารถประกอบด้วยส่วนอื่นๆ เพื่อช่วยให้การเรียนรู้จำแนกประเภทข้อมูลที่ซับซ้อน เช่น รูปภาพ ได้ดียิ่งขึ้น การเรียนรู้เชิงลึกจะมีโครงสร้างที่น่าสนใจดังนี้ โครงข่ายประสาทคอนโวลูชัน หรือ เหมาะกับการเรียนรู้ข้อมูลประเภทรูปภาพ และโครงข่ายประสาทแบบย้อนคืนกลับ (Recurrent Neural Network- RNN) เหมาะกับการเรียนรู้ข้อมูลที่มีความต่อเนื่อง เช่น ข้อมูลเสียง เป็นต้น



ภาพที่ 2 โครงสร้างโครงข่ายประสาทเทียม

2.1.3 โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network) [10]


CNN เป็นเทคนิคที่พัฒนาต่อยอดมาจากโครงข่ายประสาทเทียม ซึ่งเป็นการเรียนรู้ของเครื่องแบบมีการชี้นำ (Supervised Learning) เนื่องจาก ANN เพียงอย่างเดียวไม่สามารถใช้ทำนายให้ได้ผลลัพธ์ที่ดีกับข้อมูลประเภทรูปภาพจึงมีการพัฒนา CNN ขึ้นมา โครงสร้างของโครงข่ายประสาทคอนโวลูชัน แสดงดังภาพที่ 3 ประกอบด้วยชั้นหลาย ๆ ประเภท ดังนี้



ภาพที่ 3 โครงสร้างโครงข่ายประสาทคอนโวลูชัน [11]

1) ชั้นคอนโวลูชัน (Convolution Layer)

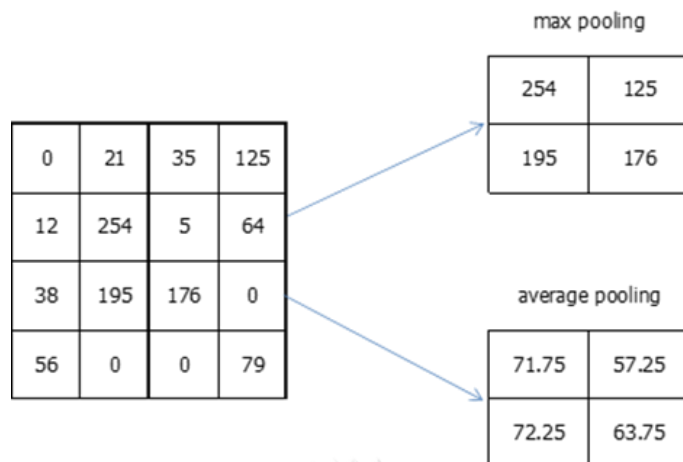
เป็นชั้นที่ทำการหาคุณลักษณะจากกลุ่มของข้อมูลอินพุตที่อยู่ใกล้ ๆ กันโดยใช้วิธีการคูณเมทริกซ์ (Dot matrix) กับตัวกรอง (Filter) หรือบางครั้งเรียกว่า เคอร์เนล (Kernel) โดยที่น้ำหนักของตัวกรองจะใช้ร่วมกันในทุก ๆ การทำคอนโวลูชันของข้อมูลอินพุต ดังภาพที่ 4 เมื่อคูณเสร็จจะได้ผลลัพธ์ชั้นเอาต์พุตเกิดขึ้นใหม่ ซึ่งจำนวนของเอาต์พุตที่เกิดขึ้นจะขึ้นกับจำนวนของตัวกรอง ดังตัวอย่างภาพที่ 3 จะใช้ตัวกรอง 5 ตัวในการทำคอนโวลูชัน จึงเกิดเอาต์พุตจำนวน 5 ตัว



ภาพที่ 4 ตัวอย่างเอาต์พุตเมื่อเมทริกซ์อินพุตผ่านตัวกรอง [12]

2) ชั้นการรวม (Pooling Layer)


ชั้นการรวมทำหน้าที่ลดขนาดของข้อมูล (Dimensionality Reduction) เพื่อให้เหลือเฉพาะข้อมูลที่สำคัญ ๆ เท่านั้น จะช่วยให้การเรียนรู้แบบจำลองไม่ต้องคำนวณมากเกินไป ซึ่งมักจะนำมาต่อกับชั้นคอนโวลูชัน โดยทั่วไปนิยมใช้การเลือกข้อมูลที่มีค่ามากที่สุด (Max Pooling) หรือค่าเฉลี่ย (Average Pooling) มาจากแต่ละช่วงของเมทริกซ์เพื่อสร้างเป็นเมทริกซ์ที่มีขนาดเล็กลง ดังภาพที่ 5



ภาพที่ 5 ตัวอย่างการทำขั้นการรวม

3) ชั้นการเชื่อมโยงเต็มรูป (Fully Connected Layer)

หลังจากการประกอบกันของชั้นคอนโวลูชันและชั้นการรวมจำนวนหนึ่งแล้วจะเรียกส่วนนี้ว่า “ส่วนดึงคุณลักษณะ” (Feature Extraction) และในขั้นสุดท้ายของโครงข่ายประสาทคอนโวลูชันจะเป็นส่วนที่ไว้สำหรับการจำแนกประเภทและเป็นการเชื่อมโยงเต็มรูปแบบ นั่นคือ ในขั้นนี้จะประกอบด้วยชั้นย่อย ๆ ที่มีเพอร์เซปตรอนอยู่จำนวนหนึ่งชั้นกับโครงสร้างที่ได้กำหนดไว้ โดยที่เพอร์เซปตรอนแต่ละตัวจะมีเส้นเชื่อมกับเพอร์เซปตรอนทุกตัวในชั้นก่อนหน้าและเพอร์เซปตรอนทุกตัวในชั้นถัดไปดังภาพที่ 2 การคำนวณปรับค่าน้ำหนักจะใช้หลักการป้อนไปข้างหน้าและการแพร่กระจายย้อนกลับ (Feed-forward and Back Propagation) ภาพที่ 6 แสดงตัวอย่างโครงสร้างเต็มรูปแบบของโครงข่ายประสาทคอนโวลูชัน



ภาพที่ 6 ตัวอย่างโครงสร้างเต็มรูปแบบของโครงข่ายประสาทคอนโวลูชัน [13]

2.1.4 โครงข่ายแคปซูล (Capsule Network)

โครงสร้างของแคปซูลประกอบด้วย 2 ส่วน คือ 1) ส่วนเข้ารหัส (Encoder) และ 2) ส่วนถอดรหัส (Decoder) ส่วนเข้ารหัสจะประกอบด้วยชั้นคอนโวลูชัน ชั้นไพรมารีแคปส์ (PrimaryCaps Layer) และชั้นดิจิตแคปส์ (DigitCaps Layer) ส่วนถอดรหัสจะประกอบด้วยชั้นการเชื่อมโยงเต็มรูปแบบต่อกัน 3 ชั้น

1) ส่วนเข้ารหัส

ส่วนเข้ารหัสจะรับข้อมูลรูปภาพลายมือข้อมูลจาก MNIST ที่มีขนาดรูปภาพ 28×28 แล้วจะทำการเข้ารหัสไปสู่เวกเตอร์ขนาด 16×10 มิติ ดังภาพที่ 7

ชั้นที่ 1. ชั้นคอนโวลูชัน

อินพุต (Input): 28×28 (ตัวอย่างจากเปเปอร์)

เอาต์พุต (Output): $20 \times 20 \times 256$ เท็นเซอร์ (Tensor)

ชั้นคอนโวลูชันจะทำหน้าที่ตรวจสอบหาคุณลักษณะ (Feature) จากภาพที่ 7 จะใช้ตัวกรอง (filter) จำนวน 256 ตัวกรองและมีขนาด $9 \times 9 \times 1$ ใช้ ReLU activation function

ชั้นที่ 2. ชั้นไพรมารีแคปส์ (PrimaryCaps Layer)

อินพุต (Input): $20 \times 20 \times 256$ เท็นเซอร์

เอาต์พุต (Output): $6 \times 6 \times 8 \times 32$ เท็นเซอร์

จากตัวอย่างภาพที่ 7 จะใช้ไพรมารีแคปซูลจำนวน 32 แคปซูล ทำหน้าที่นำคุณลักษณะที่ได้จากชั้นคอนโวลูชันไปสร้างคุณลักษณะใหม่ที่เกิดจากการรวมคุณลักษณะจากชั้นคอนโวลูชัน

ชั้นที่ 3. ชั้นดิจิตแคปส์ (DigitCaps Layer)


อินพุต (Input): $6 \times 6 \times 8 \times 32$ เท็นเซอร์

เอาต์พุต (Output): เมทริกซ์ขนาด 16×10


จากภาพที่ 7 จะมีดิจิตแคปส์จำนวน 10 แคปซูล ทำหน้าที่รวมคุณลักษณะที่ได้จากชั้นไพรมารีแคปส์มาเพื่อสร้างแคปซูลที่รวมคุณลักษณะจำนวนมากไว้ในแต่ละดิจิตแคปซูลและจะนำไปคำนวณเพื่อการจำแนกประเภท โดยใช้ Margin loss function

2) ส่วนถอดรหัส

ส่วนถอดรหัสจะประกอบด้วยชั้นการเชื่อมโยงเต็มรูปแบบ 3 ชั้น ซึ่ง 2 ชั้นแรกจะใช้ ReLU activation function ชั้นสุดท้ายจะใช้ Sigmoid activation function ดังภาพที่ 8 ทำหน้าที่สร้างรูปภาพกลับขึ้นมา โดยนำข้อมูลที่ได้มาจากชั้นดิจิตแคปส์



ภาพที่ 7 โครงสร้างส่วนเข้ารหัสของแคปซูล [7]

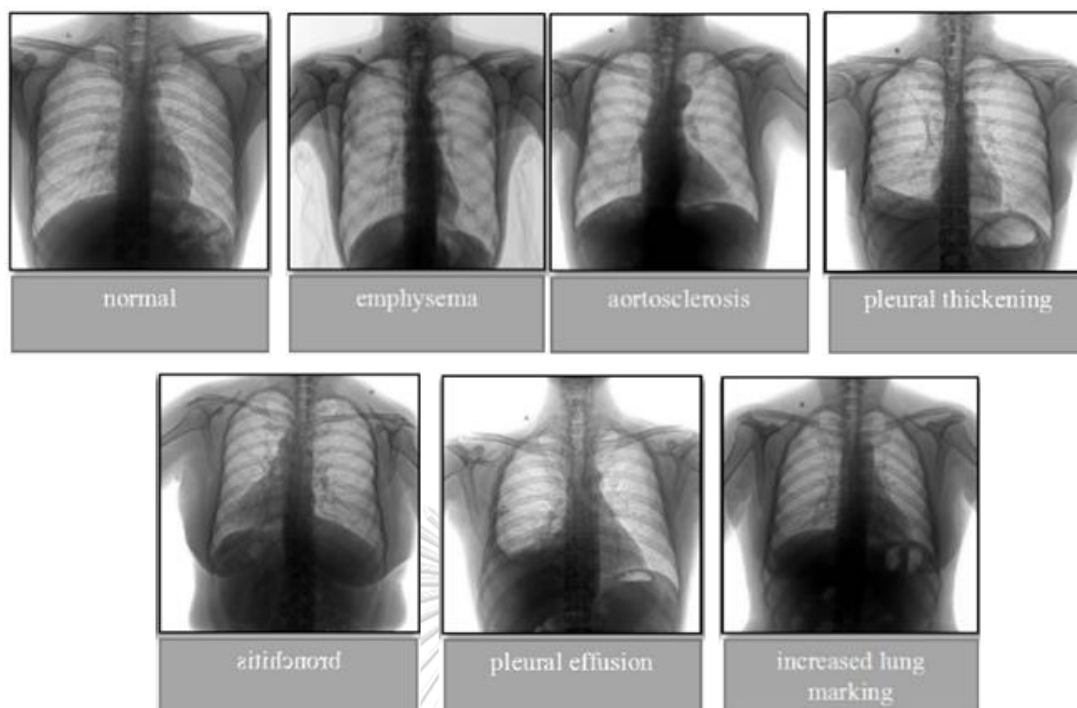


ภาพที่ 8 โครงสร้างส่วนถอดรหัสของแคปซูล [7]

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 Learning to Read Chest X-Ray Images from 16000+ Examples Using CNN [14]

งานวิจัยนี้นำเสนอการนำภาพเอกซเรย์ทรวงอกมาทำนายภาวะเส้นเลือดในปอดเพิ่มขึ้น (Increased lung mrking) ภาวะเส้นเลือดใหญ่แข็งตัว (Aortosclerosis) หลอดลมอักเสบ (Bronchitis) ถุงลมโป่งพอง (Emphysema) ภาวะมีน้ำในโพรงเยื่อหุ้มปอด (Pleural effusion) เยื่อหุ้มปอดหนาตัวผิดปกติ (Pleural thickening) ดังภาพที่ 9 โดยใช้โครงสร้าง CNN 2 แบบคือ วีจีจี-16 และ ResNet-101 พบว่า แบบจำลองผลลัพธ์โครงสร้าง ResNet-101 ให้ค่าความแม่นยำเฉลี่ยในการทำนายโรคแต่ละชนิดสูงกว่าโครงสร้างแบบวีจีจี-16




ภาพที่ 9 ตัวอย่างภาพเอกซเรย์ทรวงอกที่เป็นโรคต่าง ๆ [14]

2.2.2 A novel approach for tuberculosis screening based on deep convolutional neural networks [15]

งานวิจัยนี้เสนอการใช้แบบจำลองโครงข่ายประสาทคอนโวลูชันเพื่อตรวจหาวัณโรคปอดจากภาพเอกซเรย์ทรวงอก โครงสร้าง CNN ที่ใช้คือ อเล็กซ์เน็ต ซึ่งได้ประยุกต์ใช้เทคนิคพรีเทรน (Pre-trained) ที่โครงสร้างชั้นบน (Upper Layer) ร่วมกับการใช้เทคนิคการปรับแต่ง (Fine Tuning) โดยใช้ชุดข้อมูล (Datasets) จากฐาน Montgomery และ Shenzhen การประเมินผลแบบจำลองใช้ค่าพื้นที่ใต้เส้นโค้ง (Area Under Curve, AUC)

2.2.3 Improving Tuberculosis Diagnostics using Deep Learning and Mobile Health Technologies among Resource-poor and Marginalized Communities [16]

งานวิจัยนี้เสนอการใช้แบบจำลองโครงข่ายประสาทคอนโวลูชันเพื่อจำแนกประเภทภาพเอกซเรย์ทรวงอกบนโทรศัพท์มือถือ โครงสร้าง CNN ที่ใช้คือ GoogleNet [17] ชุดข้อมูลที่ใช้ในการสร้างแบบจำลองได้จาก Dr. Peinado สมาชิกทีมวิจัยในเปรู ชุดข้อมูลถูกแบ่งออกเป็น 2 ประเภท คือ 1) ปกติ (Normal) 453 รูป และ 2) ผิดปกติเป็นวัณโรค (Abnormal) 4248 รูป ตัวอย่างภาพเอกซเรย์ทรวงอกที่ใช้ในงานวิจัยนี้ดังภาพที่ 10 ชุดข้อมูลทั้งหมดมี 4701 รูป แบ่งเป็นข้อมูลสอน 4/5 ของจำนวนรูปทั้งหมด และข้อมูลทดสอบ 1/5 ของจำนวนรูปทั้งหมด แบบจำลองได้ประยุกต์ใช้เทคนิค pre-trained ซึ่งผลลัพธ์ของแบบจำลองวัดด้วยค่าความเที่ยง (Precision) ซึ่งมีค่าสูงสุดเป็น 89.6% รายละเอียดผลลัพธ์ของค่าความเที่ยง ดังแสดงในตารางที่ 1




ภาพที่ 10 ชุดข้อมูลภาพเอกซเรย์ทรวงอก [16]

ตารางที่ 1 ค่าเฉลี่ยความถูกต้องของแบบจำลอง [16]

# of Iterations	10,000	30,000	50,000	80,000	100,000
Average Precisions	82.8%	88.6%	89.0%	89.5%	89.6%

2.2.4 Deep-learning: A Potential Method for Tuberculosis Detection using Chest Radiography [18]

งานวิจัยนี้เสนอการปรับแต่งโครงข่ายประสาทคอนโวลูชันโดยประยุกต์จากโครงสร้าง LeNet และ อเล็กซ์เน็ต โครงสร้างที่ได้จากงานวิจัยนี้จะมีโครงสร้างที่ไม่ซับซ้อน สามารถทำให้ตัวแบบจำลองของโครงสร้างนี้ต้องการเวลาและจำนวนพารามิเตอร์ที่ใช้ในการเรียนรู้ลดลง ชุดข้อมูลที่ใช้ในการสร้างแบบจำลองจะได้จากฐานข้อมูลของ Montgomery และ Shenzhen โครงสร้าง CNN ที่เสนอจะมีโครงสร้างดังภาพที่ 11 โครงสร้างจะประกอบด้วย 19 layers แบ่งเป็น 7 Convolutional layers (Conv Layer), 7 ReLu layers, 3 Fully-Connected layer (FC Layer) และ 2 ชั้นดรอปเอาต์ (Dropouts Layer) โดยที่ชั้น conv จะทำหน้าที่ดึงคุณลักษณะที่สำคัญ (Feature) ตัวกรอง (Filter) จะมีขนาด 5x5 และใช้ pooling layer เพื่อลดจำนวนพารามิเตอร์ที่ใช้คำนวณลง ชั้น FC ทำหน้าที่ในการจำแนกประเภทภาพพร้อมกับการใช้ dropout layer เพื่อลดปัญหาการเรียนรู้ที่มากเกินไป (Overfitting) งานวิจัยนี้จะเปรียบเทียบความแตกต่างระหว่างตัวทำให้เหมาะสมที่สุด (Optimizer) ที่ใช้ในโครงสร้าง CNN นี้ ประกอบด้วย optimizer 3 ตัวคือ 1) Adam optimizer 2) momentum optimizer 3) stochastic gradient descent optimizer (SGD Optimizer) จากผลการทดลองพบว่า Adam optimizer ให้ค่าความแม่นยำโดยรวม (Overall Accuracy) สูงสุดคือ 94.73% และค่า Validation accuracy เป็น 82.09% ตามตารางที่ 2



ภาพที่ 11 โครงสร้าง CNN ที่เสนอใน [18]

ตารางที่ 2 ค่าความแม่นยำของ optimizer แต่ละตัว [18]

	Adam	Momentum	SGD
Overall Accuracy	94.73%	80.95%	67.34%
Validation Accuracy	82.09%	79.10%	80.60%
Loss	0.4013	0.4699	0.6332

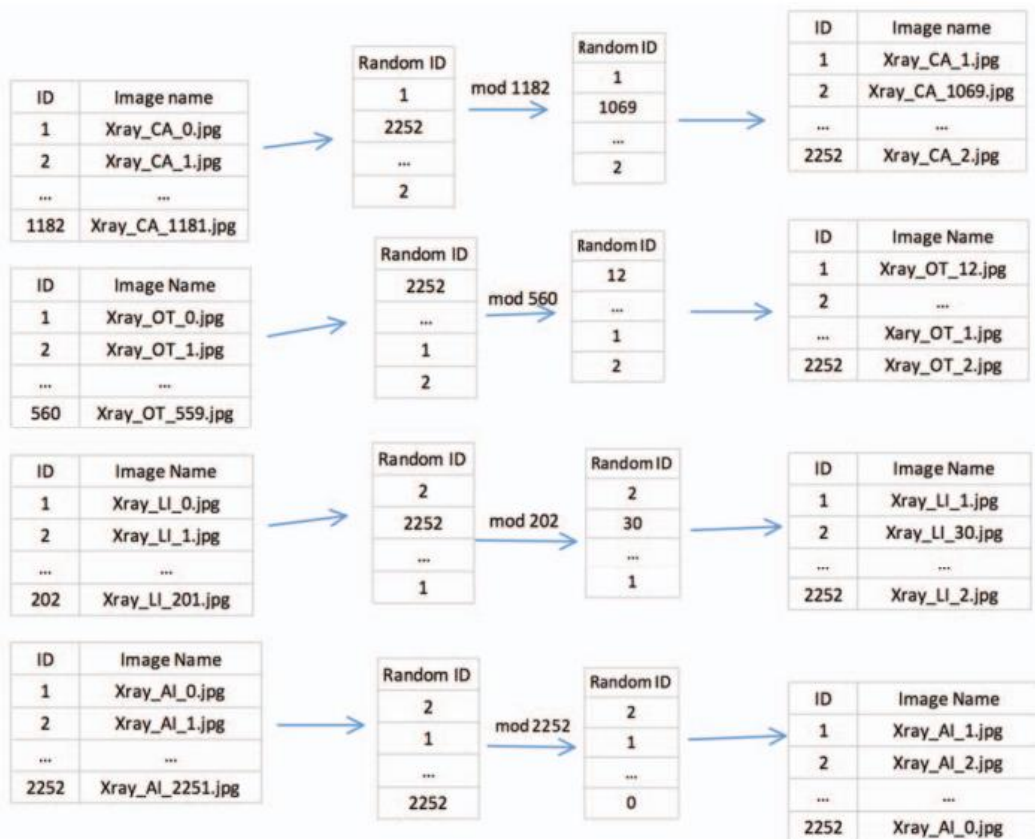
2.2.5 TX-CNN: DETECTING TUBERCULOSIS IN CHEST X-RAY IMAGES USING CONVOLUTIONAL NEURAL NETWORK [19]

งานวิจัยนี้เสนอการใช้โครงข่ายประสาทคอนโวลูชันด้วยโครงสร้างแบบอเล็กซ์เน็ต และ GoogleNet เพื่อการตรวจหาโรควัณโรคปอดจากภาพเอกซเรย์ทรวงอก ชุดข้อมูลที่ใช้ในการสอนและทดสอบ เป็นชุดข้อมูลจากประเทศเปรู ชุดข้อมูลจะแบ่งออกเป็น 2 ประเภท คือ 1) ปกติ (Normal) 453 รูป 2) เป็นวัณโรค (Abnormal) 4248 รูป รวมชุดข้อมูลทั้งหมดเป็น 4701 รูป ซึ่งจะได้จากฐานข้อมูลที่แตกต่างกันดังตารางที่ 3 เนื่องจากชุดข้อมูลเป็นข้อมูลของที่มีจำนวนข้อมูลในคลาสที่แตกต่างกันมาก (Imbalanced Data) จึงทำให้เกิดข้อเสียในการสร้างแบบจำลอง โดยตัวแบบจำลองจะให้ผลลัพธ์ด้านประสิทธิภาพในการตรวจหาโรคไม่ถูกต้อง จึงได้ประยุกต์ใช้เทคนิค Shuffle Sampling ในการจัดการปัญหาด้านข้อมูลไม่สมดุล (Imbalance Data) ขั้นตอนแรกๆของเทคนิค shuffle sampling จะทำการเลือกฐานข้อมูลที่มีจำนวนข้อมูลมากที่สุดในงานวิจัยนี้คือฐานข้อมูลที่มีจำนวน 2252 รูป แต่ละฐานข้อมูลจะทำการสร้างจำนวนเต็มตั้งแต่ 1-2252 โดยเรียงแบบสุ่ม แล้วทำการคำนวณโดยนำค่าตัวเลขที่สุ่มขึ้นมาหารเอาเศษ (Mod, %) ค่าที่ได้จะเป็นตัวดัชนีสุดท้าย (Final Index) สุดท้ายจะทำการคัดลอกรูปภาพตาม final index ที่สร้างขึ้น ตัวอย่างขั้นตอนของ shuffle sampling ดังภาพที่ 12

ผลการทดลองแสดงให้เห็นว่าเทคนิค shuffle sampling จะช่วยเพิ่มความแม่นยำของตัวแบบจำลอง ทั้งโครงสร้างแบบ อเล็กซ์เน็ต จากค่าความแม่นยำ 53.02% เพิ่มขึ้นเป็น 85.68% และ GoogleNet จากค่าความแม่นยำ 56.11% เพิ่มขึ้นเป็น 91.72%

ตารางที่ 3 คำอธิบายฐานข้อมูลที่ใช้ในงานวิจัย [19]

Category (Name of TB manifestation)	Total Image
Miliary Disease (MI)	25
Cavitation (CA)	1182
Lymphadenopathy (LI)	202
Ghon Focus (GH)	27
Alveolar Infiltrates (AI)	2252
Other (OT)	560



ภาพที่ 12 ขั้นตอนการทำ shuffle sampling เพื่อจัดการข้อมูล imbalanced data [19]


2.2.6 Comparing deep learning models for population screening using chest radiography [20]

งานวิจัยได้เปรียบเทียบแบบจำลองการเรียนรู้เชิงลึกที่ใช้จำแนกผู้ป่วยที่เป็นวัณโรคปอด โดยใช้โครงสร้าง CNN แบบปรับแต่ง (Customized model), อเล็กซ์เน็ต, VGG, Xception และ ResNet เปรียบเทียบด้านความแม่นยำของการจำแนกประเภท ใช้ชุดข้อมูลประกอบด้วย Shenzhen, Montgomery, Kenya, และ India รายละเอียดข้อมูลดังตารางที่ 4

ตารางที่ 4 ชุดข้อมูลของ Shenzhen, Montgomery, Kenya และ India [20]

Origin	# TB positive	# Normal	File type	Bit depth	Resolution
Shenzhen	58	80	PNG	8-bit	4020-4892 x 4020-4892
Montohomery	336	326	PNG	8-bit	948-3001 x 1130-3001
Kenya	238	729	PNG	8-bit	1312-1852 x 1094-1838
India	153	153	JPG	8-bit	1024-2480 x1024-2480

ภาพที่ 13 แสดงโครงสร้างของ Customized model ที่ใช้ในงานวิจัยประกอบด้วย 3 Convolutional layers (Conv Layer), 3 max pooling layer, 1 dropouts layer และ 2 Fully-Connected layer (FC layer) ใช้ softmax function เป็นตัวจำแนกประเภท (Classifier) ร่วมกับ SGD momentum และ L2- regularization optimizer ชั้น conv layer ใช้เทคนิค batch normalization [21] และใช้ Relu layer รวมด้วย



ภาพที่ 13 โครงสร้างของ Customized model [20]

เทคนิค pre-trained ได้นำมาประยุกต์ใช้กับทุกโครงสร้างในงานวิจัย ผลการทดลองของ customized model ดังตารางที่ 5 และผลลัพธ์การเปรียบเทียบความแม่นยำของโครงสร้างอเล็กซ์เน็ต วีจีจี-16 วีจีจี-19 Xception และ ResNet-50 ดังสรุปในตารางที่ 6 พบว่า อเล็กซ์เน็ต มีประสิทธิภาพในการจำแนกวินิจฉัยโรคปอดจากภาพเอกซเรย์ทรวงอกได้ดีในทุกฐานข้อมูล Shenzhen, Montgomery และ India โดยให้ค่าความแม่นยำสูงที่สุด

ตารางที่ 5 ค่าความแม่นยำและ AUC ของ customized model [20]


Datasets	Accuracy	AUC
Shenzhen	0.820	0.894
Montgomery	0.658	0.744
Kenya	0.572	0.642
India	0.824	0.900

ตารางที่ 6 ค่าความแม่นยำแบบจำลอง CNN ที่มีโครงสร้างแบบต่าง ๆ [20]

Datasets	AlexNet	VGG-16	VGG-19	Xception	ResNet-50
Shenzhen	0.842	0.815	0.778	0.731	0.819
Montgomery	0.725	0.708	0.6520	0.600	0.676
Kenya	0.657	0.666	0.679	0.653	0.678
India	0.864	0.748	0.840	0.828	0.812

2.2.7 Chest X-Ray Analysis of Tuberculosis by Deep Learning with Segmentation and Augmentation [22]


งานวิจัยนี้ได้นำเสนอการทำนายวินิจฉัยโรคปอดจากภาพฟิล์มเอกซเรย์ทรวงอกด้วย CNN เนื่องจากจำนวนข้อมูลที่ใช้สร้างมีจำนวนน้อยจึงทำให้เกิดการ overfitting กับข้อมูลสอน (Training Data) จึงใช้เทคนิคการแบ่งส่วนภาพ (Segmentation) โดยจะนำภาพเอกซเรย์ทรวงอกแล้วทำการตัดภาพให้เหลือเฉพาะส่วนที่เป็นปอดที่เป็นบริเวณเกิดรอยโรควินิจฉัยโรคปอดตัวอย่างตามภาพที่ 14 และใช้เทคนิคการเพิ่มจำนวนข้อมูล (Data Augmentation) โดยการหมุนภาพ (Rotation) แต่ละภาพด้วยมุม 90, 180, 270 องศา ทำทั้งหมด 7 ครั้ง (จำนวนภาพเพิ่มขึ้นเป็น 8 เท่าของจำนวนภาพเดิม) ผลการทดลองพบว่าเทคนิค Augmentation จะช่วยป้องกันการเกิดปัญหา overfitting



ภาพที่ 14 ตัวอย่างของภาพเอกซเรย์ทรวงอกที่ตัดบริเวณเฉพาะส่วนที่เป็นปอด [22]

2.2.8 Automated Tuberculosis Classification of Chest Radiographs by Using Convolutional Neural Networks [23]

งานวิจัยเสนอการทำนายวัณโรคปอดจากภาพฟิล์มเอกซเรย์ทรวงอกด้วยโครงสร้าง CNN แบบ ResNet ดังภาพที่ 15 โดยใช้จำนวนภาพในการสร้างแบบจำลอง 1133 รูป แบ่งเป็นไม่เป็นวัณโรค (Normal) 449 รูป และเป็นวัณโรค (TB) 634 รูป ขนาด training dataset 793 รูป validation dataset 170 รูป และ test dataset 170 รูป เนื่องจากชุดข้อมูลที่ใช้ในการสร้างแบบจำลองมีขนาดเล็ก จึงทำ Data augmentation เพื่อเพิ่มจำนวนตัวอย่าง โดยนำ training dataset มาเพิ่มข้อมูลด้วย 6 เทคนิคที่ต่างกันดังนี้ เทคนิคที่ 1-3 จะใช้การหมุนภาพด้วยมุม 90, 180 และ 270 องศา เทคนิคที่ 4-5 จะใช้เทคนิคพลิกภาพ (flip) ตามแกนแนวนอนและแนวตั้ง เทคนิคสุดท้ายใช้ ฮิสโตแกรมอีควอลไลเซชัน (Histogram Equalization) ขนาด training dataset เพิ่มขึ้นเป็น 5551 รูป ผลการทดลองพบว่า การเพิ่มข้อมูลใน training dataset จะช่วยเพิ่มความแม่นยำของแบบจำลอง



ภาพที่ 15 โครงสร้าง ResNet [23]


บทที่ 3

แนวคิดและวิธีวิจัย


งานวิจัยนี้สนใจการสร้างแบบจำลองเพื่อตรวจหาร่องรอยการติดเชื้อไวรัสโคโรปอดด้วยวิธีการเรียนรู้เชิงลึกแบบโครงข่ายแคปซูลเปรียบเทียบกับแบบจำลองโครงข่ายคอนโวลูชันแบบเล็กซ์เน็ต และ วิธีจี-16 จากงานวิจัยที่เกี่ยวข้องพบว่าโครงสร้าง อเล็กซ์เน็ต และ วิธีจี-16 เป็นโครงสร้างที่ดีที่สุดในการทำนายรอยโรคไวรัสโคโรปอดจากภาพรังสีเอกซเรย์ทรวงอก วิธีวิจัยการสร้างแบบจำลองและเตรียมข้อมูลแบ่งออกเป็น 4 ขั้นตอนหลัก: 1) การเตรียมชุดข้อมูล 2) การสร้างแบบจำลองการทำนายไวรัสโคโรปอด 3) การเพิ่มประสิทธิภาพแบบจำลอง และ 4) การทำนายไวรัสโคโรปอดจากภาพเอกซเรย์ทรวงอก

3.1 การเตรียมชุดข้อมูล

จัดเตรียมชุดข้อมูลสอนภาพดิจิทัลเอกซเรย์ทรวงอกจากฐานข้อมูล National Library of Medicine- NLM ตัวอย่างภาพเอกซเรย์ทรวงอกที่ปกติและมีรอยโรคไวรัสโคโรปอดดังภาพที่ 16 เนื่องจากข้อมูลภาพเอกซเรย์ทรวงอกมีขนาดที่หลากหลายและมีขนาดที่ใหญ่เกินไปไม่เหมาะสมเป็นข้อมูลสอนของการสร้างแบบจำลอง CNN จำเป็นต้องทำการย่อขนาดภาพเอกซเรย์เพื่อลดเวลาที่ใช้ในการสร้างแบบจำลอง และแปลงภาพให้อยู่ในรูปเมทริกซ์ขนาด $64 \times 64 \times 1$ ซึ่งเป็นขนาดปกติของชุดข้อมูลสอนเพื่อการเรียนรู้ของ CNN อย่างไรก็ตาม ถึงแม้ว่าภาพเอกซเรย์จะเป็นรูปขาวดำ แต่ข้อมูลที่ป้อนเข้าเป็นแบบ RGB เป็นระบบ 3 สี คือ แดง เขียว และน้ำเงิน แต่ละสีจะแทนด้วยค่าข้อมูลเมทริกซ์ ข้อมูลภาพเอกซเรย์เมื่อแปลงเป็นอาร์เรย์จะมีขนาดภาพเป็น $64 \times 64 \times 3$ ซึ่งเลข 3 แทนค่าสีแดง เขียว และน้ำเงิน จึงต้องปรับภาพให้เป็นขาวดำหรือสเกลสีเทา (Gray Scale) ซึ่งสามารถลดข้อมูลค่าสี 3 ชุดข้อมูลภาพที่มีขนาดเป็น $64 \times 64 \times 3$ ให้เหลือเพียง 1 ชุด มีขนาดเป็น $64 \times 64 \times 1$ ดังภาพที่ 17




ภาพที่ 16 ตัวอย่างภาพที่ปกติ (ซ้าย) และมีรอยโรคไวรัสโคโร (ขวา)




ภาพที่ 17 ตัวอย่างกระบวนการย่อขนาดภาพเอกซเรย์ทรวงอก

3.1.1 การเพิ่มข้อมูลด้วยเทคนิค shuffle sampling

เทคนิค shuffle sampling [19] คือ การเพิ่มข้อมูลจากข้อมูลดั้งเดิม (Original Data) เพื่อป้องกันปัญหา overfitting กับข้อมูลสอน เนื่องจากชุดข้อมูลที่ใช้ในการสร้างแบบจำลองของงานวิจัยนี้มีจำนวนฐานข้อมูลที่แตกต่างกันจากงานวิจัย [19] จึงต้องปรับเทคนิค ซึ่งมีกระบวนการทำ shuffle sampling ดังนี้ 1) แบ่งฐานข้อมูลให้เป็นกลุ่ม ๆ (Category) ให้จำนวนกลุ่มของชุดข้อมูลทั้งหมดมีค่าเป็น c 2) แต่ละ category จะทำการสร้างดัชนี (Index) จำนวนจริงเรียงแบบสุ่มตั้งแต่ 1 ถึง N เลขของแต่ละ category โดยที่ N คือจำนวนข้อมูลของ category ที่มีจำนวนข้อมูลมากที่สุด 3) นำเลขดัชนีที่สร้าง (i , คือเลขดัชนีที่สร้างมาจากข้อ 2) ของแต่ละ category มาทำการหารเอาเศษ (Mod , %) ด้วยค่า N_c โดยที่ค่า N_c คือจำนวนข้อมูลสูงสุดของแต่ละ category เพื่อสร้างดัชนีสำหรับการสร้างรูปภาพต่อไป 4) การทำเพิ่มรูปภาพตามดัชนีของรูปภาพที่ได้จากค่า mod ที่ได้จากข้อ 3) โดยการนำภาพที่มีดัชนีของภาพต้นฉบับของแต่ละ category ไปไว้ที่ชุดข้อมูลใหม่ เทคนิคดังกล่าวสามารถเพิ่มชุดข้อมูลจาก category ที่มีข้อมูลน้อย ๆ ให้เพิ่มขึ้นเท่ากับ category ที่มีข้อมูลมากที่สุด ขั้นตอนวิธี shuffle sampling ดังแสดงในภาพที่ 18 และ ภาพที่ 19 แสดงกระบวนการเพิ่มขนาดชุดข้อมูลด้วยเทคนิค shuffle sampling ที่นำเสนอ




ภาพที่ 18 แผนภาพขั้นตอนวิธี shuffle sampling



ภาพที่ 19 กระบวนการเพิ่มข้อมูลด้วยเทคนิค shuffle sampling

3.1.2 การเพิ่มชุดข้อมูลด้วยเทคนิคหมุนภาพ (Rotation)


เทคนิคการเพิ่มข้อมูลด้วยเทคนิคหมุนภาพเป็นเทคนิคที่มีมานานแล้วเพื่อแก้ปัญหาชุดข้อมูลที่มีจำนวนน้อย ซึ่งการหมุนภาพเอกซ์เรย์ทรวงอกที่ใช้นั้นจะทำการหมุนภาพไปตามมุม 90, 180 และ 270 องศา [22, 23] ตัวอย่างการหมุนภาพดังแสดงในภาพที่ 20 เนื่องจากการหมุนภาพด้วยเทคนิคนี้จะทำให้ภาพที่มุมด้วยมุม 90, 180 และ 270 องศา มีรูปร่างปอดที่แตกต่างจากปอดปกติไปมากเกินซึ่งในความเป็นจริงภาพเอกซ์เรย์ทรวงอกมีมุมที่บิดไปจากมุมต้นฉบับเพียงเล็กน้อยไม่เกิน 90 องศา เทคนิคการเพิ่มภาพเอกซ์เรย์ทรวงอกด้วยวิธีการหมุนภาพด้วยมุมที่สูงนั้น จึงไม่สามารถนำแบบจำลองที่สร้างได้จากชุดข้อมูลไปใช้งานจริงให้มีประสิทธิภาพที่ดีได้ งานวิจัยนี้จึงได้ประยุกต์ใช้เทคนิคการหมุนภาพโดยจะหมุนภาพเพียงเล็กน้อยเท่านั้น เพื่อให้รูปปอดจากภาพเอกซ์เรย์ทรวงอกไม่บิดเบือนจากภาพต้นฉบับมากนัก โดยจะประยุกต์ใช้เทคนิค shuffle sampling ร่วมกับการหมุนภาพ ซึ่งมีขั้นตอนดังนี้ ขั้นแรกจะเพิ่มข้อมูลด้วยเทคนิค shuffle sampling แล้วจะหมุนภาพข้อมูลด้วยมุม -10 ถึง 10 องศา โดยจะสุ่มมุมแต่ละภาพในช่วงนั้น เพื่อให้ภาพมีความหลากหลายไม่ซ้ำซ้อนลดปัญหาที่ใช้เทคนิค shuffle sampling เพียงอย่างเดียว คือ ลดรูปที่ซ้ำกับชุดข้อมูล ภาพที่ 21 แสดงขั้นตอนการหมุนภาพด้วยการสุ่มมุม ภาพที่ 22 แสดงตัวอย่างภาพที่หมุนภาพด้วยมุมที่มีค่าน้อย



ภาพที่ 20 ตัวอย่างภาพเอกซเรย์ทรวงอก ก) ภาพต้นฉบับไม่มีการหมุน ข) ภาพหมุนด้วยมุม 90 องศา ค) ภาพหมุนด้วยมุม 180 องศา ง) ภาพหมุนด้วยมุม 270 องศา



ภาพที่ 21 ขั้นตอนการเพิ่มข้อมูลด้วยเทคนิคการหมุนภาพ



ภาพที่ 22 ตัวอย่างภาพที่หมุนด้วยมุมที่มีค่าน้อย


3.1.3 การเตรียมชุดข้อมูลสำหรับการทดสอบภาพผิดปกติ

บางครั้งการถ่ายภาพเอกซเรย์ทรวงอกจะเกิดความผิดพลาดขึ้นได้ เช่น รูปภาพที่ถ่ายจะมีมุมเอียงไปจากภาพปกติหรือบางครั้งกระดูกสันหลังของผู้ป่วยโค้งตัวอย่างตามภาพที่ 23 จึงทำให้รูปร่างปอดบิดเบี้ยวไปจากภาพปกติ เพื่อที่จะทำการทดลองสร้างแบบจำลองที่สามารถจัดการรูปดังกล่าวได้ให้ดียิ่งมากขึ้นโดยไม่ต้องนำภาพที่ถ่ายเอียงหรือภาพที่กระดูกสันหลังผู้ป่วยโค้งมาสอนตัวแบบจำลอง

เนื่องจากภาพเอกซเรย์ทรวงอกที่บิดเบี้ยวไม่มีในฐานข้อมูลที่ได้นำมาในงานวิจัยนี้ จึงต้องทำการสร้างภาพเอกซเรย์ทรวงอกที่ทดแทนภาพดังกล่าวด้วยวิธีการหมุนภาพ โดยจะทำการหมุนภาพไปทีละมุม -30 ถึง 30 องศาแบบสุ่มจากชุดข้อมูลทดสอบ (Test Dataset) ภาพที่ 24 แสดงภาพเปรียบเทียบระหว่างรูปร่างปอดของภาพที่สร้างขึ้นกับภาพผู้ป่วยที่มีกระดูกสันหลังโค้ง จะเห็นว่ารูปร่างปอดส่วนใหญ่จะมีลักษณะบางส่วนที่ใกล้เคียงกัน ภาพด้านซ้ายคือภาพเอกซเรย์ทรวงอกที่สร้างจากการหมุนภาพ ภาพด้านขวาคือภาพเอกซเรย์ทรวงอกของผู้ป่วยที่มีกระดูกสันหลังผิดปกติ



ภาพที่ 23 ตัวอย่างภาพเอกซเรย์ทรวงอกที่บิดเบี้ยวและภาพเอกซเรย์ทรวงอกของผู้ป่วยที่มีกระดูกสันหลังผิดปกติ



ภาพที่ 24 ตัวอย่างภาพเปรียบเทียบระหว่างรูปร่างปอด

3.2 การสร้างแบบจำลองการทำนายวัณโรคปอด


จากงานวิจัยที่เกี่ยวข้องของโครงสร้าง CNN ที่ดีที่สุดในการทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอกคือ อเล็กซ์เน็ต และ วีจีจี-16 เนื่องจากโครงสร้างพื้นฐานของ อเล็กซ์เน็ต และ วีจีจี-16 ไม่เหมาะกับภาพเอกซเรย์ทรวงอกและได้ประสิทธิภาพไม่ดีเท่าที่ควร จึงนำเสนอการปรับแต่งโครงสร้าง

อเล็กซ์เน็ต และ วีจีจี-16 ที่มีความแตกต่างจากโครงสร้างพื้นฐาน ที่มีการเพิ่มขึ้นหรือลดจำนวนตัวกรอง (Filter) ของชั้นคอนโวลูชัน (Convolution Layer) การเพิ่มหรือลดขนาดของตัวกรองเพื่อให้แบบจำลองสามารถทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอกได้แม่นยำมากขึ้น แต่โครงสร้างอเล็กซ์เน็ต และ วีจีจี-16 ทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอกที่ผิดปกติได้ประสิทธิภาพไม่ดีเท่าที่ควร เพื่อที่จะให้แบบจำลองสามารถทำนายวัณโรคปอดจากภาพผิดปกติได้ดีมากขึ้น จึงเสนอโครงสร้างที่มีความซับซ้อนและมีเทคนิคที่แตกต่างจากโครงสร้างแบบ อเล็กซ์เน็ต และ วีจีจี-16 โดยได้โครงสร้างแบบแคปซูล (Capsule) ที่มีการใช้เทคนิคการนำความสัมพันธ์ของ feature แต่ละตำแหน่งจากชั้นก่อนหน้ามารวมประมวลผลเพื่อให้แบบจำลองสามารถทำนายภาพได้ดียิ่งขึ้น

3.2.1 โครงข่ายประสาทคอนโวลูชันแบบอเล็กซ์เน็ต

การปรับโครงข่ายประสาทคอนโวลูชันโดยยึดโครงสร้างอเล็กซ์เน็ตเป็นพื้นฐานเพื่อให้ได้แบบจำลองที่สามารถจำแนกประเภทรอยโรควัณโรคปอดจากภาพเอกซเรย์ทรวงอกได้ดี จะทำการลดจำนวน filter ที่ใช้ในแต่ละชั้นคอนโวลูชัน และจะลดจำนวนนิวรอนในชั้นการเชื่อมโยงเต็มรูปแบบ (Fully-connected Layer) เพื่อที่จะลดเวลาและจำนวนพารามิเตอร์ที่ใช้คำนวณและลดความซับซ้อนของแบบจำลองเพื่อที่จะให้แบบจำลองมีความเป็นทั่วไป (Generalization) กล่าวคือ การที่แบบจำลองสามารถทำนายข้อมูลใหม่หรือข้อมูลที่ไม่ได้นำมาสอนได้ดี ภาพที่ 25 แสดงโครงสร้างอเล็กซ์เน็ตที่ปรับแต่งแล้ว

โครงสร้างอเล็กซ์เน็ต ประกอบด้วย 5 ชั้นคอนโวลูชัน (Conv Layer) 3 ชั้นเชื่อมโยงเต็มรูปแบบ (FC) และ 2 ชั้นดรอปเอาต์ (Dropout Layer) แต่ละ Conv layer จะประกอบด้วย Relu layers เพื่อลดขนาดมิติที่ใช้คำนวณลง (Dimensionality Reduction) Conv layer จะทำหน้าที่ดึงคุณลักษณะที่โดดเด่นออกมา (Distinct Feature) ชั้น Conv1 มี 96 ตัวกรอง ขนาดตัวกรองที่ใช้คือ 11×11 ชั้น Conv2 มี 256 ตัวกรอง ขนาดตัวกรองที่ใช้คือ 5×5 ชั้น Conv3 มี 512 ตัวกรอง ชั้น Conv4 และ Conv5 มีตัวกรองเท่ากันคือ 1024 ตัวกรอง ขนาดตัวกรองของชั้น Conv3, Conv4 และ Conv5 ที่ใช้คือ 3×3 ชั้น Conv1, Conv2, Conv3 และ Conv5 จะใช้ชั้นการรวมที่มีค่ามากที่สุด (Max Pooling Layer) มีขนาด 2×2 และในชั้น Conv1 จะใช้ค่าสไตรด์ (Stride) เป็น 4 พิกเซล (Pixel) ส่วนชั้นที่เหลือจะใช้ค่าสไตรด์เป็น 1 พิกเซล ฟังก์ชันกระตุ้น (Activation Function) ที่ใช้ในแต่ละชั้นยกเว้นชั้น FC3 คือ Relu function อัตราการเรียนรู้ (Learning Rate) ที่ใช้คือ 0.001 และตัวทำให้เหมาะสมที่สุด (Optimizer) ที่ใช้คือ Adam ในชั้น FC3 จะใช้ฟังก์ชันกระตุ้นเป็น softmax function เพื่อที่จะให้ชั้น FC3 นี้เป็นชั้นที่ไว้ทำนายภาพเอกซเรย์ทรวงอกว่าเป็นวัณโรคปอดหรือปกติ รายละเอียดของโครงสร้างแต่ละชั้นตามตารางที่ 7



ภาพที่ 25 โครงสร้างของอเล็กซ์เน็ตที่ปรับแต่งแล้ว

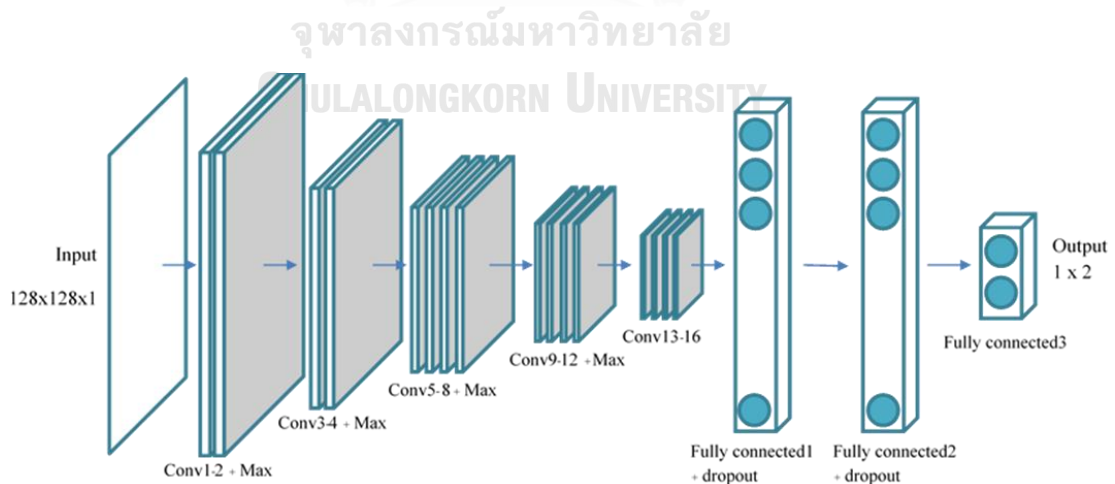
ตารางที่ 7 รายละเอียดโครงสร้างของอเล็กซ์เน็ตที่ปรับแต่งแล้วแต่ละชั้น

Layer	Type	Activation	Input	Output	No. of filters	Filter/pool Size
1	Conv1	ReLu	128 x 128 x 1	32 x 32 x 96	96	11 x 11
2	Maxpooling		32 x 32 x 96	16 x 16 x 96		2 x 2
3	Conv2	ReLu	16 x 16 x 96	16 x 16 x 256	256	5 x 5
4	Maxpooling		16 x 16 x 256	8 x 8 x 256		2 x 2
5	Zero padding		8 x 8 x 256	10 x 10 x 256		
6	Conv3	ReLu	10 x 10 x 256	10 x 10 x 512	512	3 x 3
7	Maxpooling		10 x 10 x 512	5 x 5 x 512		2 x 2
8	Zero padding		5 x 5 x 512	7 x 7 x 512		
9	Conv4	ReLu	7 x 7 x 512	7 x 7 x 1024	1024	3 x 3
10	Zero padding		7 x 7 x 1024	9 x 9 x 1024		
11	Conv5	ReLu	9 x 9 x 1024	9 x 9 x 1024	1024	3 x 3
12	Maxpooling		9 x 9 x 1024	4 x 4 x 1024		2 x 2
13	Flatten		4 x 4 x 1024	1 x 16384		
14	Fully Connected1	ReLu	1 x 16384	1 x 2048		
15	Dropout			Keep Probability = 0.5		
16	Fully Connected2	ReLu	1 x 2048	1 x 2048		
17	Dropout			Keep Probability = 0.5		
18	Fully Connected3	Softmax	1 x 2048	1 x 2		

3.2.2 โครงข่ายประสาทคอนโวลูชันแบบ วีจีจี-16

การปรับโครงข่ายประสาทคอนโวลูชันโดยยึดโครงสร้าง วีจีจี-16 เป็นพื้นฐานเพื่อให้ได้แบบจำลองที่สามารถจำแนกประเภทรอยโรคผิวหนังโรคปอดจากภาพเอกซเรย์ทรวงอกได้ดี จะทำการลดจำนวนตัวกรองที่ใช้ในแต่ละชั้นคอนโวลูชัน และจะลดจำนวนนิวรอนในชั้นการเชื่อมโยงเต็มรูปแบบ (Fully-connected Layer) เพื่อที่จะลดเวลาและจำนวนพารามิเตอร์ที่ใช้คำนวณและลดความซับซ้อนของแบบจำลองเพื่อที่จะให้แบบจำลองมีความเป็นทั่วไปเช่นเดียวกันกับโครงสร้าง อเล็กซ์เน็ต โครงสร้าง วีจีจี-16 ดังภาพที่ 26

โครงสร้าง วีจีจี-16 ประกอบด้วย 16 ชั้นคอนโวลูชัน (Conv Layer) 3 ชั้นเชื่อมโยงเต็มรูปแบบ (FC) และ 2 ชั้นดรอปเอาต์ (Dropout Layer) แต่ละ Conv layer จะประกอบด้วย Relu layers เพื่อลดขนาดมิติที่ใช้คำนวณลง Conv layer จะทำหน้าที่ดึงคุณลักษณะที่โดดเด่นออกมา (Distinct Feature) ชั้น Conv1-2 มี 32 ตัวกรอง ชั้น Conv3-4 มี 64 ตัวกรอง ชั้น Conv5-8 มี 128 ตัวกรอง Conv9-16 มี 256 ตัวกรอง ขนาดตัวกรองที่ใช้ในแต่ละชั้นคือ 3x3 ชั้น Conv2, Conv4, Conv8 และ Conv12 จะใช้ชั้นการรวมที่มีค่ามากที่สุด (Max Pooling Layer) มีขนาด 2x2 และในชั้น Conv2, Conv4, Conv8, Conv15 และ Conv16 จะมีการทำแบบนอร์มอลไลซ์ (Batch Normalize) เพื่อที่จะช่วยเพิ่มความเร็วในการเรียนแบบจำลองให้มากขึ้น[21] ฟังก์ชันกระตุ้น (Activation Function) ที่ใช้ในแต่ละชั้นยกเว้นชั้น FC3 คือ Relu function อัตราการเรียนรู้ (Learning rate) ที่ใช้คือ 0.0001 และตัวทำให้เหมาะสมที่สุด (Optimizer) ที่ใช้คือ Stochastic Gradient Descent (SGD) ในชั้น FC3 จะใช้ฟังก์ชันกระตุ้นเป็น softmax function เพื่อที่จะให้ชั้น FC3 นี้เป็นชั้นที่ไว้ทำนายภาพเอกซเรย์ทรวงอกว่าเป็นวัณโรคปอดหรือปกติ รายละเอียดของโครงสร้างแต่ละชั้น ดังตารางที่ 8



ภาพที่ 26 โครงสร้างของ วีจีจี-16 ที่ปรับแต่งแล้ว

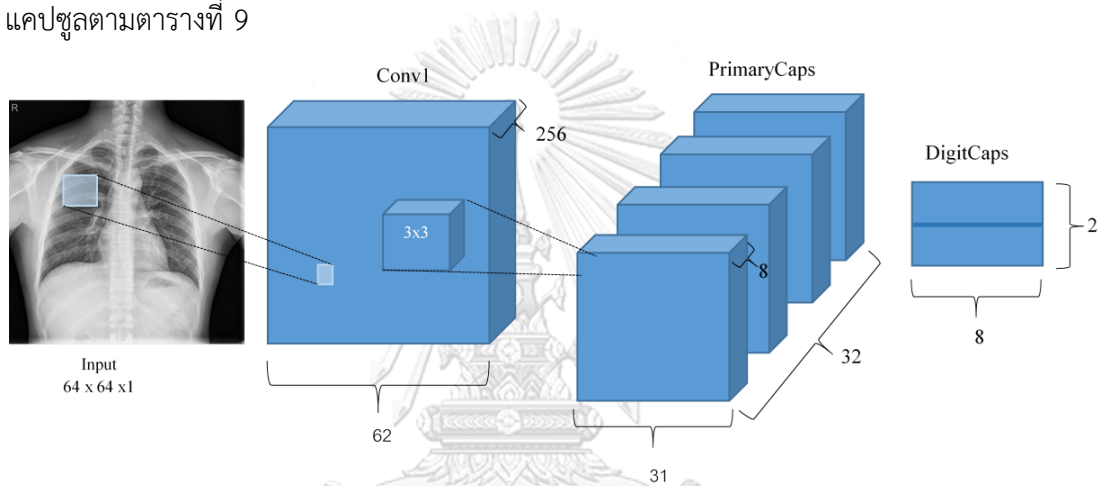
ตารางที่ 8 รายละเอียดของโครงสร้างของ วิจิณี-16 ที่ปรับแต่งแล้วแต่ละชั้น

Layer	Type	Activation	Input	Output	No. of filters	Filter/pool Size
1	Conv1	ReLu	128 x 128 x 1	128 x 128 x 32	32	3 x 3
2	Conv2+batch_norm	ReLu	128 x 128 x 32	128 x 128 x 32	32	3 x 3
3	Maxpooling		128 x 128 x 32	64 x 64 x 32		2 x 2
4	Conv3	ReLu	64 x 64 x 32	64 x 64 x 64	64	3 x 3
5	Conv4+batch_norm	ReLu	64 x 64 x 64	64 x 64 x 64	64	3 x 3
6	Maxpooling		64 x 64 x 64	32 x 32 x 64		2 x 2
7	Conv5	ReLu	32 x 32 x 64	32 x 32 x 128	128	3 x 3
8	Conv6	ReLu	32 x 32 x 128	32 x 32 x 128	128	3 x 3
9	Conv7	ReLu	32 x 32 x 128	32 x 32 x 128	128	3 x 3
10	Conv8+batch_norm	ReLu	32 x 32 x 128	32 x 32 x 128	128	3 x 3
11	Maxpooling		32 x 32 x 128	16 x 16 x 128		2 x 2
12	Conv9	ReLu	16 x 16 x 128	16 x 16 x 256	256	3 x 3
13	Conv10	ReLu	16 x 16 x 256	16 x 16 x 256	256	3 x 3
14	Conv11	ReLu	16 x 16 x 256	16 x 16 x 256	256	3 x 3
15	Conv12	ReLu	16 x 16 x 256	16 x 16 x 256	256	3 x 3
16	Maxpooling		16 x 16 x 256	8 x 8 x 256		2 x 2
17	Conv13	ReLu	8 x 8 x 256	8 x 8 x 256	256	3 x 3
18	Conv14	ReLu	8 x 8 x 256	8 x 8 x 256	256	3 x 3
19	Conv15+batch_norm	ReLu	8 x 8 x 256	8 x 8 x 256	256	3 x 3
20	Conv16+batch_norm	ReLu	8 x 8 x 256	8 x 8 x 256	256	3 x 3
21	Flatten		8 x 8 x 256	1 x 16384		
22	Fully Connected1	ReLu	1 x 16384	1 x 2048		
23	Dropout			Keep Probability = 0.5		
24	Fully Connected2	ReLu	1 x 2048	1 x 2048		
25	Dropout			Keep Probability = 0.5		
26	Fully Connected3	Softmax	1 x 2048	1 x 2		

3.2.3 โครงข่ายโครงข่ายแคปซูล (Capsule Network)

โครงข่ายแคปซูลที่ปรับแต่งแล้วเป็นโครงสร้างที่ต้นไม้อับซ้อนประกอบด้วยชั้นคอนโวลูชัน 2 ชั้น เป็นชั้นคอนโวลูชันแบบปกติและชั้นแคปซูลปฐมภูมิ (Primary Capsules Layer, PrimaryCaps) และ 1 ชั้นเชื่อมโยงเต็มรูปแบบซึ่งได้ปรับแต่งเป็นชั้นดิจิทัลแคปส์ (DigitCaps Layer) ชั้น Conv1 ประกอบด้วย 32 ตัวกรอง ขนาดตัวกรองที่ใช้คือ 3x3 ค่าสไตรด์ (Stride) ที่ใช้คือ 1 ฟังก์ชันกระตุ้นคือ ReLU function ชั้น Conv1 จะทำหน้าที่ดึงคุณลักษณะเด่นออกมาจากภาพแล้วจะส่งผลลัพธ์ไปเป็นอินพุตไปยังชั้น PrimaryCaps ต่อไป โครงข่ายแคปซูลที่ปรับแต่งแล้วแสดงดังภาพที่ 27

ชั้น PrimaryCaps เป็นชั้นแคปซูลที่ประกอบด้วย 32 แคปซูล แต่ละแคปซูลมี 8 มิติ (8D Capsules) ขนาดตัวกรองที่ใช้คือ 3x3 ค่าสไตรด์ที่ใช้คือ 2 ชั้น PrimaryCaps จะใช้ฟังก์ชันกระตุ้นคือ Relu function ขนาดของเอาต์พุตของชั้น PrimaryCaps มีขนาดเป็น 14x14 ซึ่งแต่ละมิติจะคำนวณค่าน้ำหนัก (Weight) ร่วมกัน เอาต์พุตของชั้น PrimaryCaps จะส่งผลลัพธ์ไปเป็นอินพุตของชั้น DigitCaps หรือชั้นสุดท้ายที่ไว้สำหรับจำแนกประเภท ชั้น DigitCaps ประกอบด้วย 2 แคปซูล หรือ 2 คลาส (class) คือ ปกติ หรือ เป็นวัณโรคปอด แต่ละแคปซูลของชั้น DigitCaps จะมี 8 มิติ ซึ่งการจำแนกประเภทของชั้น DigitCaps จะใช้ความยาวของเวกเตอร์ (Vector) เป็นตัวตัดสิน โดยที่เวกเตอร์ใดมีความยาวมากที่สุดจะเป็นการทำนายคลาสนั้น รายละเอียดโครงสร้างของโครงข่ายแคปซูลตามตารางที่ 9



ภาพที่ 27 โครงสร้างโครงข่ายแคปซูลที่ปรับแต่งแล้ว

ตารางที่ 9 รายละเอียดโครงสร้างโครงข่ายแคปซูลที่ปรับแต่งแล้ว

Layer	Type	Activation	Input	Output	No. of filters	Filter/pool Size
1	Conv1	ReLu	64 x 64 x 1	62 x 62 x 256	256	3 x 3
2	PrimaryCaps		62 x 62 x 256	30 x 30 x 8 x 32		3 x 3
3	PrimaryFlatten	Margin loss	30 x 30 x 256	7200 x 32		
4	DigitCaps	Margin loss	7200 x 32	2 x 8		
5	DigitCapsLength		2 x 8	2 x 1		

3.3 การประเมินแบบจำลองทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอก

โดยทั่วไป ตัววัดที่ใช้ในการประเมินแบบจำลองโครงข่ายประสาทเทียมคอนโวลูชันสำหรับการทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอก คือ ค่าความไว (Sensitivity) ความจำเพาะ (Specificity) และความแม่นยำ (Accuracy) การหาค่าความไว ความจำเพาะ และความแม่นยำ แสดงดังสมการ (1), (2) และ (3) ตามลำดับ

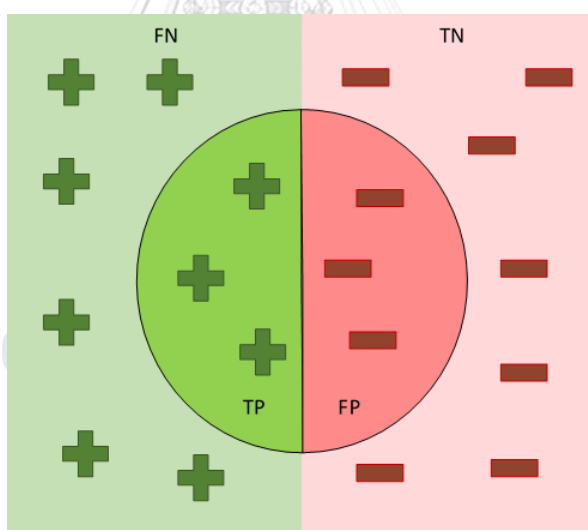
$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (1)$$

$$\text{Specificity} = \frac{TN}{FP + TN} \quad (2)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3)$$

โดย TP คือ จำนวนตัวอย่างบวกที่แบบจำลองทำนายเป็นบวก
 FP คือ จำนวนตัวอย่างลบที่แบบจำลองทำนายเป็นบวก
 TN คือ จำนวนตัวอย่างลบที่แบบจำลองทำนายเป็นลบ
 FN คือ จำนวนตัวอย่างบวกที่แบบจำลองทำนายเป็นลบ

ผลลัพธ์การทำนายด้วยแบบจำลองทั้ง 4 แบบ คือ True Positive, False Positive, True Negative และ False Negative อธิบายดังภาพที่ 28 และตารางคอนฟิวชันเมทริกซ์ (Confusion Matrix) ดังตารางที่ 10



ภาพที่ 28 ภาพจำลองนิยามของ TP, TN, FP และ FN

ตารางที่ 10 รายละเอียดของคอนฟิวชันเมทริกซ์

		ตัวอย่าง	
		บวก	ลบ
ตัวอย่างที่แบบจำลองทำนาย	บวก	TP	FP
	ลบ	FN	TN

บทที่ 4

การทดลองและผลการทดลอง

4.1 ระบบที่ใช้ในการทดลอง

4.1.1 คอมพิวเตอร์ที่ใช้ในการทดลอง

การสร้างแบบจำลองโครงข่ายแคปซูล โครงข่ายประสาทเทียมคอนโวลูชันแบบ อเล็กซ์เน็ต และ วีจีจี-16 พัฒนาบนเครื่องคอมพิวเตอร์ที่มีหน่วยประมวลผลกลางเป็น Intel® Core™ i7-6700K CPU@ 4.00GHz มีหน่วยความจำขนาด 8 GB มีหน่วยประมวลผลกราฟิกคือ NVIDIA GeForce GTX 1080 TI และมีหน่วยความจำกราฟิกขนาด 11 GB บนระบบปฏิบัติการ Windows 10 แบบ 64 bit

การเตรียมชุดข้อมูลก่อนดำเนินการทดลองและสร้างแบบจำลองโครงข่ายแคปซูลและโครงข่ายประสาทเทียมคอนโวลูชันทั้ง 2 แบบ จะใช้หน่วยประมวลผลกลางในการดำเนินการเพียงอย่างเดียว ส่วนการสร้างแบบจำลองและการทดสอบแบบจำลองจะใช้หน่วยประมวลผลกราฟิกมาช่วย เพื่อลดระยะเวลาที่ใช้สร้างแบบจำลอง

4.1.2 การเขียนโปรแกรมและเฟรมเวิร์กที่ใช้ในการทดลอง

การเขียนโปรแกรมเพื่อลดขนาดภาพและการเพิ่มจำนวนรูปภาพด้วยเทคนิค shuffle sampling และการหมุนภาพ พัฒนาโดยใช้ภาษา Python ร่วมกับเฟรมเวิร์ก OpenCV

การเขียนโปรแกรมสำหรับโหลดข้อมูลภาพเป็นแถวลำดับ (Array) ซึ่งแต่ละพิกเซล (Pixel) ของภาพจะเป็นตัวเลขที่บ่งบอกสีในพิกเซลและการแปลงระบบภาพจาก RGB เป็น Gray Scale พัฒนาโดยใช้ภาษา Python ร่วมกับไลบรารี Pillow, Python Imaging Library (PIL)

การเขียนโปรแกรมสำหรับการเตรียมข้อมูลสอน (Training Data) และข้อมูลทดสอบ (Test Data) พัฒนาโดยภาษา Python ร่วมกับการใช้ไลบรารี scikit learn

สำหรับการเขียนโปรแกรมโครงข่ายประสาทเทียมคอนโวลูชันแบบ อเล็กซ์เน็ต และ วีจีจี-16 รวมทั้งโครงข่ายแคปซูลจะใช้ภาษา Python ร่วมกับเฟรมเวิร์ก Tensorflow และ Keras โดยมีการปรับปรุงเพิ่มเติมจากโครงสร้างของแบบจำลองในแบบต่าง ๆ จากต้นฉบับ ซึ่งเปิดเป็นโอเพนซอร์ส (Open Source) โค้ดทั้งหมดถูกพัฒนาด้วยเครื่องมือ Jupyter Notebook ซึ่งเป็นเฟรมเวิร์กของ Python

4.2 ชุดข้อมูลที่ใช้ในการทดลอง

ข้อมูลที่ใช้ในการทดลองเป็นข้อมูลภาพเอกซเรย์ทรวงอกจากฐานข้อมูลสาธารณะ 2 ฐาน คือ Montgomery และ Shenzhen และข้อมูลจากกระทรวงสาธารณสุข 3 ฐานคือ ฐานข้อมูลจังหวัดนครสวรรค์ ฐานข้อมูลจังหวัดพิจิตร และฐานข้อมูลจังหวัดชัยนาทกับจังหวัดอุทัยธานี ข้อมูลภาพ

เอกซเรย์ทรวงอกทั้งหมดที่ใช้มี 1390 ภาพ แบ่งเป็นภาพเอกซเรย์ทรวงอกที่ไม่เป็นวัณโรคปอด 701 ภาพ ภาพเอกซเรย์ทรวงอกที่เป็นวัณโรคปอด 689 ภาพ รายละเอียดข้อมูลแต่ละฐาน ดังตารางที่ 11


ตารางที่ 11 รายละเอียดฐานข้อมูลทั้ง 5 ฐาน

Database	Number of TB	Number of Normal	Resolution
Shenzhen	336	326	948-3001 x 1130-3007
Montgomery	58	80	4020-4892 x 4020-4892
Nakhonsawan	182	135	200 x 243
Phichit	27	105	1008 x 1204
Chai Nat + Uthai Thani	86	55	3072 x 3072

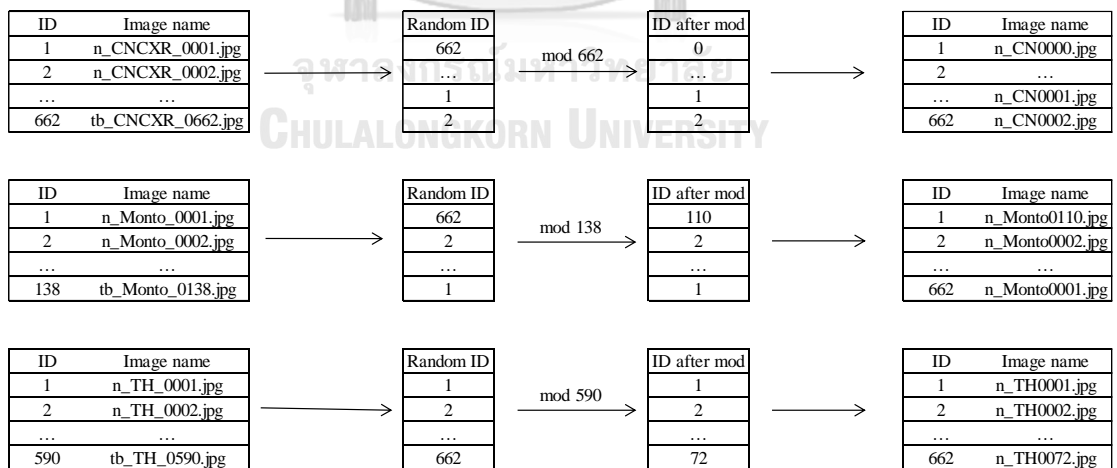
4.2.1 การเพิ่มขนาดชุดข้อมูลด้วยเทคนิค Shuffle sampling

ข้อมูลภาพเอกซเรย์ทรวงอกจากทั้ง 5 ฐานจะถูกเพิ่มจำนวนตัวอย่างเพื่อเพิ่มสมรรถนะของแบบจำลองด้วยเทคนิค Shuffle sampling (หัวข้อ 3.1.1) ในงานวิจัยนี้จะแบ่ง category ออกเป็น 5 category ตามฐานข้อมูลที่แสดงในตารางที่ 11 จากตารางจำนวนข้อมูลมากที่สุดที่จะยึดเป็นฐานในการคำนวณคือฐานข้อมูล Shenzhen ซึ่งมีข้อมูลทั้งหมด 662 ภาพ ผลลัพธ์ที่ได้จากการทำ Shuffle sampling จะเพิ่มข้อมูลที่ใช้ในการสร้างแบบจำลองเป็นจำนวน 3310 ภาพ เป็นภาพเอกซเรย์ทรวงอกที่ไม่เป็นวัณโรคปอด 1803 ภาพ และเป็นภาพเอกซเรย์ทรวงอกที่เป็นวัณโรคปอด 1507 ภาพ ภาพที่ 29 แสดงขั้นตอนวิธีการทำ Shuffle sampling ด้วย 5 category

งานวิจัยได้ทดสอบปัจจัยขนาดชุดข้อมูลที่มีต่อสมรรถนะของแบบจำลอง จึงได้ทำ Shuffle sampling โดยแบ่ง category ให้เหลือเพียงแค่ 3 category ซึ่ง category ที่ 1 และ 2 คือฐานข้อมูลจาก Montgomery และ Shenzhen ตามลำดับ ส่วน category ที่ 3 คือการรวมฐานข้อมูลทั้งหมดในไทย จะได้ category1 มีจำนวน 662 ภาพ category2 มี 138 ภาพ และ category3 มี 590 ภาพ ดูรายละเอียดจำนวนภาพแต่ละ category ได้ในตารางที่ 12 ผลลัพธ์การทำ Shuffle sampling จะเพิ่มข้อมูลที่ใช้ในการสร้างแบบจำลองเป็นจำนวน 1986 ภาพ เป็นภาพเอกซเรย์ทรวงอกที่ไม่เป็นวัณโรคปอด 945 ภาพ และเป็นภาพเอกซเรย์ทรวงอกที่เป็นวัณโรคปอด 1041 ภาพ ภาพที่ 30 แสดงภาพขั้นตอนวิธีการทำ Shuffle sampling ด้วย 3 category



ภาพที่ 29 ภาพขั้นตอนวิธี Shuffle sampling ที่แบ่งข้อมูลเป็น 5 category



ภาพที่ 30 ภาพขั้นตอนวิธี Shuffle sampling ที่แบ่งข้อมูลเป็น 3 category

ตารางที่ 12 รายละเอียดจำนวนภาพที่แบ่งเป็น 3 category

Database	Number of TB	Number of Normal
Category 1	336	326
Category 2	58	80
Category 3	295	295

4.2.2 การเพิ่มชุดข้อมูลด้วยเทคนิคการหมุนภาพ

นอกจากการเพิ่มข้อมูลด้วยเทคนิค Shuffle sampling แล้ว งานวิจัยนี้จะเพิ่มข้อมูลภาพเอกซเรย์ทรวงอกด้วยเทคนิคการหมุนภาพ เพื่อลดปัญหาข้อมูลที่ซ้ำจำนวนมากจากเทคนิค Shuffle sampling และเพื่อให้แบบจำลองมีข้อมูลที่จะสามารถทำนายรอยโรคโควิดโรคปอดจากภาพเอกซเรย์ทรวงอกที่บิดเบี้ยวจากภาพที่เป็นแนวตั้ง เนื่องจากข้อผิดพลาดของคนถ่ายภาพเอกซเรย์ทรวงอก และเพื่อทำนายรอยโรคโควิดโรคปอดจากภาพของคนที่มีกระดูกสันหลังโค้งได้ดียิ่งขึ้น

การเพิ่มข้อมูลภาพด้วยเทคนิคการหมุนจะทำโดยการนำภาพที่เพิ่มขึ้นจากเทคนิค Shuffle sampling ซึ่งมีข้อมูลจำนวน 3310 ภาพ มาทำการหมุนภาพแต่ละภาพด้วยมุมที่สุ่มระหว่าง -10 ถึง 10 องศา หลังการเพิ่มภาพด้วยเทคนิคหมุนภาพจะได้ภาพเอกซเรย์ทรวงอกเพิ่มขึ้นเป็น 6620 ภาพ เป็นภาพเอกซเรย์ทรวงอกที่ไม่เป็นวัณโรคปอด 3606 ภาพ และเป็นภาพเอกซเรย์ทรวงอกที่เป็นวัณโรคปอด 3014 ภาพ ตารางที่ 13 สรุปรายละเอียดจำนวนภาพทั้งหมดที่เพิ่มขึ้นด้วยเทคนิคต่าง ๆ

ตารางที่ 13 สรุปจำนวนภาพทั้งหมดที่เพิ่มขึ้นด้วยเทคนิคต่าง ๆ

Datasets	Total number of CXR
Original	1390
Shuffle sampling (3 category)	1986
Shuffle sampling (5 category)	3310
Affine Transformation (Rotate)	6620

4.2.3 การแบ่งข้อมูล

ในการทดลอง ข้อมูลภาพเอกซเรย์ทรวงอกแต่ละชุดข้อมูลที่มีการเพิ่มข้อมูลและที่ไม่ได้เพิ่มข้อมูล จะถูกแบ่งออกเป็นชุดข้อมูลสำหรับการเรียนรู้ (training dataset) ของตัวแบบจำลอง 60% ของจำนวนข้อมูลทั้งหมดของแต่ละชุดข้อมูล ชุดข้อมูลตรวจสอบความสมเหตุสมผล (validation dataset) ของตัวแบบจำลอง 20% ของจำนวนข้อมูลทั้งหมดของแต่ละชุดข้อมูล และข้อมูลสำหรับการทดสอบ (test dataset) ของตัวแบบจำลอง 20% ของจำนวนข้อมูลทั้งหมดของแต่ละชุดข้อมูล

4.2.4 การเตรียมชุดข้อมูลทดสอบภาพเอกซเรย์ทรวงอกที่ปิดเบี้ยว

เพื่อทำการทดลองโครงข่ายประสาทเทียมคอนโวลูชันแบบ อเล็กซ์เน็ต วิจีจี-16 และโครงข่ายแคปซูล สำหรับการทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอกที่ปิดเบี้ยวจากภาพปกติ จะทำการนำชุดข้อมูลที่ยังไม่ได้ทำการเพิ่มข้อมูล (Original dataset) มาหมุนภาพแต่ละภาพด้วยการสุ่มมุมระหว่าง -30 ถึง 30 องศา ผลลัพธ์ที่ได้จะมีชุดข้อมูลสำหรับการทดสอบภาพเอกซเรย์ทรวงอกที่ปิดเบี้ยวจำนวน 1390 ภาพ

4.3 การดำเนินการทดลอง

ในการทำนายรอยโรควัณโรคปอดจากภาพเอกซเรย์ทรวงอกแบ่งออกเป็นกระบวนการย่อยได้แก่ การนำชุดข้อมูลเข้าและเตรียมชุดข้อมูลซึ่งได้อธิบายขั้นตอนไว้แล้วในบทที่ 4.2 การสอนแบบจำลอง การทดสอบแบบจำลอง และการประเมินสมรรถนะของแบบจำลอง

4.3.1 การสอนแบบจำลอง (Model Training)

การสอนแบบจำลองเป็นขั้นตอนที่จะสร้างแบบจำลองสำหรับการทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอก เนื่องจากงานวิจัยนี้เป็นข้อมูลประเภทภาพ ซึ่งจะมีข้อมูลจำนวนพิกเซลที่ต้องใช้คำนวณจำนวนมาก ซึ่งไม่สามารถสอนแบบจำลองโดยใช้ข้อมูลทั้งหมดแล้วจึงทำการปรับค่าน้ำหนักของนิวรอนเน็ตเวิร์กและตัวกรอง จึงต้องมีการแบ่งข้อมูลเป็นกลุ่มแล้วส่งกลุ่มของข้อมูลนั้นไปประมวลผลและคำนวณหาค่าน้ำหนักฟังก์ชันกระตุ้นและปรับค่าตาม optimizer ที่ใช้ในแต่ละโครงสร้างที่ได้อธิบายไว้แล้วในบทที่ 3.2 ซึ่งโครงข่ายประสาทเทียมคอนโวลูชันแบบ อเล็กซ์เน็ต และ วิจีจี-16 จะใช้ขนาดกลุ่มข้อมูล (Batch Size) เป็น 128 ภาพ ส่วนโครงข่ายแคปซูลจะใช้ Batch Size เป็น 64 เนื่องจากโครงข่ายแคปซูลจะคำนวณความสัมพันธ์ของคุณลักษณะและตำแหน่งจึงมีการคำนวณที่มากกว่าโครงสร้างอื่น และจำนวนกลุ่มที่ใช้ในการคำนวณแต่ละรอบ (Number batches size per epoch) คือ จำนวนภาพทั้งหมดที่นำไปสอนแบบจำลองหารด้วย Batch Size

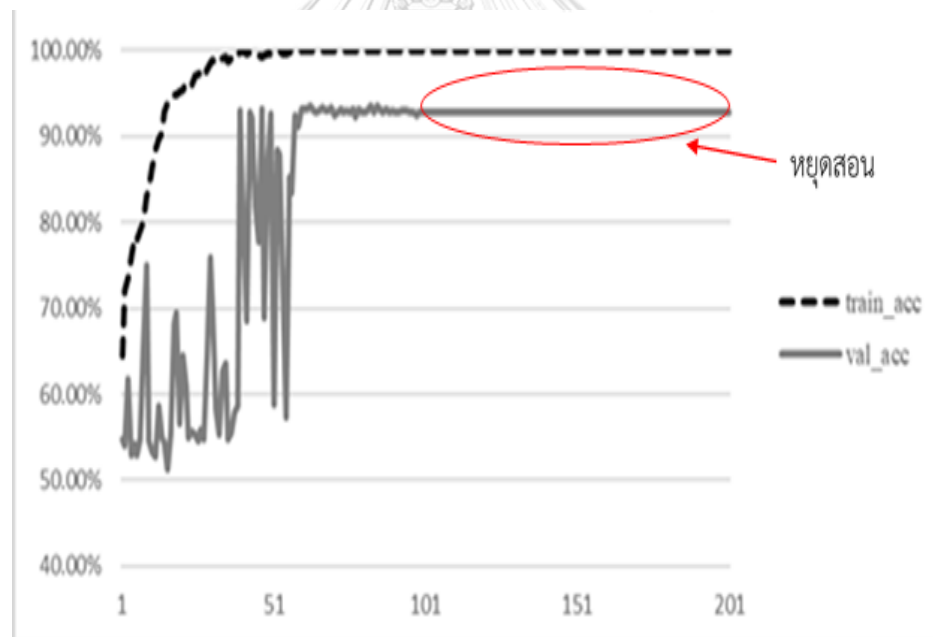
การเลือกใช้แบบจำลอง มีเงื่อนไขในแต่ละรอบการเรียนรู้หรือการสอน (Epoch) จะทำการคำนวณหาค่าความแม่นยำในแต่ละรอบด้วยชุดข้อมูลตรวจสอบความสมเหตุสมผล (Validation Dataset) ในรอบของ epoch นั้นเปรียบเทียบกับค่าที่ดีที่สุดกับรอบที่ผ่านมาทั้งหมด ดังภาพที่ 31 แล้วจะทำการเรียนรู้ไปจนถึงเงื่อนไขในการหยุดการเรียนรู้ของแบบจำลอง เมื่อค่าความแม่นยำมีค่าคงที่หรือเปลี่ยนแปลงน้อยมากจนไม่มีแนวโน้มที่จะเพิ่มขึ้นหรือลดลงตามภาพที่ 32 และเลือกแบบจำลองที่ให้ค่าความแม่นยำสูงที่สุดหลังจากทำการเรียนรู้เสร็จสิ้นแล้ว

```

Epoch 1/300
5248/5296 [=====>.] - ETA: 0s - loss: 0.6311 - acc: 0.6576
Epoch 00001: val_acc improved from -inf to 0.57704, saving model to ./result_alexnet/weights-01.h5
5296/5296 [=====] - 7s 1ms/step - loss: 0.6309 - acc: 0.6584 - val_loss: 0.8574 - val_acc: 0.5770
Epoch 2/300
5248/5296 [=====>.] - ETA: 0s - loss: 0.5399 - acc: 0.7245
Epoch 00002: val_acc did not improve
5296/5296 [=====] - 3s 556us/step - loss: 0.5398 - acc: 0.7243 - val_loss: 1.0565 - val_acc: 0.5514
Epoch 3/300
5248/5296 [=====>.] - ETA: 0s - loss: 0.5093 - acc: 0.7593
Epoch 00003: val_acc improved from 0.57704 to 0.62236, saving model to ./result_alexnet/weights-03.h5
5296/5296 [=====] - 4s 721us/step - loss: 0.5094 - acc: 0.7593 - val_loss: 0.7111 - val_acc: 0.6224
Epoch 4/300
5248/5296 [=====>.] - ETA: 0s - loss: 0.4921 - acc: 0.7715
Epoch 00004: val_acc did not improve
5296/5296 [=====] - 3s 558us/step - loss: 0.4917 - acc: 0.7719 - val_loss: 1.0170 - val_acc: 0.5891
Epoch 5/300
5248/5296 [=====>.] - ETA: 0s - loss: 0.4538 - acc: 0.7931

```

ภาพที่ 31 ตัวอย่างการเลือกใช้แบบจำลองที่ดีที่สุด



ภาพที่ 32 ตัวอย่างการหยุดการเรียนรู้ของแบบจำลอง

4.3.2 การทดสอบแบบจำลอง (Model Testing)

การทดสอบจะใช้แบบจำลองที่มีประสิทธิภาพสูงสุดหรือให้ค่าความแม่นยำสูงสุดหรือมีค่า loss ต่ำที่สุดกับชุดข้อมูลตรวจสอบความสมเหตุสมผล (Validation Dataset) โดยที่ค่า loss ของ อเล็กซ์เน็ต และ วีจีอี-16 ที่ใช้คือ Categorical Cross-entropy ซึ่งคำนวณหาค่ามาจากตัวอย่างที่ทำนายคลาด ผิดพลาด ส่วนโครงข่ายแคปซูลจะใช้ Margin loss

การเลือกใช้แบบจำลองที่ให้ค่าน้ำหนักสำหรับการทำนายล้มโรคปอดจากภาพเอกซเรย์ทรวงอกที่ดีที่สุด จะเลือกวัดจากค่าความแม่นยำของแต่ละรอบการเรียนรู้ ซึ่งเมื่อทำการปรับค่าน้ำหนักทีละ batch จนครบชุดข้อมูลสอนทั้งหมดจากนั้นจะใช้ค่าน้ำหนักของแบบจำลองในการปรับรอบสุดท้ายไปทดสอบกับชุดข้อมูลทวนสอบเพื่อหาค่าความแม่นยำและค่า loss โดยที่ค่าน้ำหนักของแบบจำลองในรอบที่ให้ค่าความแม่นยำสูงสุดหรือค่า loss ต่ำสุด จะเก็บค่าน้ำหนักของแบบจำลองตัวนั้นไว้เพื่อไว้ใช้เทียบกับค่าน้ำหนักในรอบอื่นต่อไป ทำจนรอบการเรียนรู้แต่ละรอบที่ให้ค่าความแม่นยำและค่า loss ที่คงที่หรือเปลี่ยนแปลงน้อยมาก จะหยุดการเรียนรู้แบบจำลองและจะโหลดค่าน้ำหนักที่ดีที่สุดไปทดสอบกับชุดข้อมูลทดสอบ ตัวอย่างการโหลดน้ำหนักตามภาพที่ 33

```
In [18]: # load weight
path_weight = './result_alexnet/weights-61.h5'
model.load_weights(path_weight)
print('loading weight complete')
```

loading weight complete

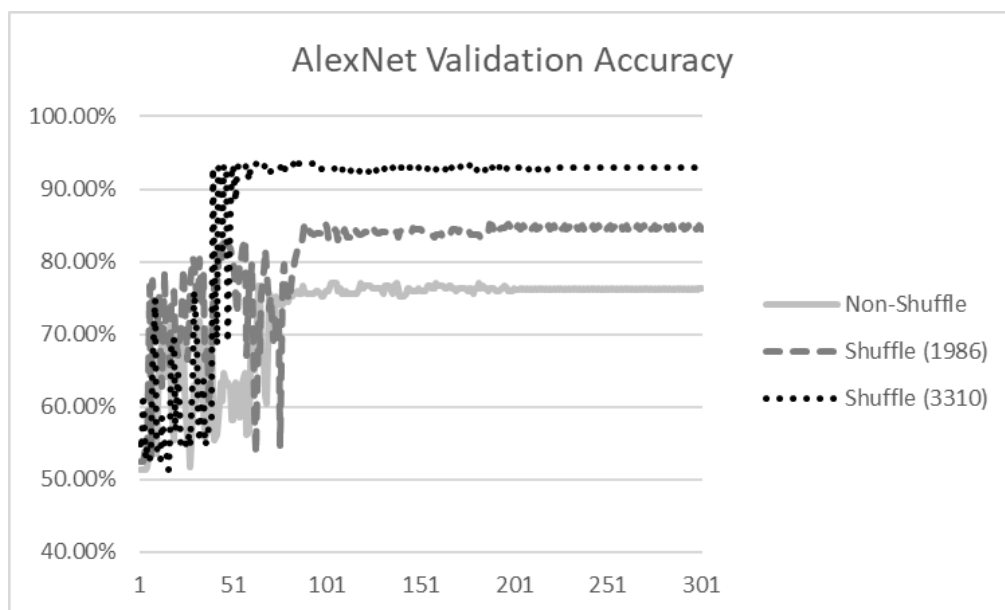
ภาพที่ 33 ตัวอย่างการโหลดน้ำหนักของแบบจำลอง

เมื่อแบบจำลองที่โหลดค่าน้ำหนักที่ดีที่สุดและนำไปทดสอบกับชุดข้อมูลทดสอบแล้ว จะทำการประเมินสมรรถนะของแบบจำลองด้วยตัววัด 3 ค่าคือ ความแม่นยำ ความไว และความจำเพาะ

4.4 ผลการทดลอง

4.4.1 ผลการทดลองของ อเล็กซ์เน็ต

การทดลองนี้ได้ทำการเปรียบเทียบขนาดข้อมูลที่ใช้ในการสร้างแบบจำลอง ซึ่งข้อมูลที่ใช้ในการสร้างแบบจำลองจะแบ่งเป็นข้อมูลที่ไม่มีการเพิ่มจำนวนข้อมูลด้วยเทคนิค shuffle sampling อละข้อมูลที่เพิ่มจำนวนด้วยเทคนิค shuffle sampling ให้มีจำนวน 1986 ภาพ และ 3310 ภาพ โดยจะแบ่งข้อมูลของการเรียนรู้ออกเป็นชุดข้อมูลสอน 60% ชุดข้อมูลทวนสอบ 20% และชุดข้อมูลทดสอบ 20% ของจำนวนข้อมูลทั้งหมดที่ใช้ กราฟการเรียนรู้ของแบบจำลอง อเล็กซ์เน็ต ดังภาพที่ 34 ซึ่งใช้ค่าความแม่นยำที่แต่ละรอบ epoch ที่แบบจำลองไปสร้างจากชุดข้อมูลสอนแล้วนำไปทดสอบค่าความแม่นยำกับชุดข้อมูลทวนสอบ และค่าความแม่นยำ ความไว และความจำเพาะของแบบจำลอง อเล็กซ์เน็ต ที่เรียนรู้ด้วยชุดข้อมูลทั้ง 3 ขนาดจะทำนายกับชุดข้อมูลทดสอบโดยที่ผลลัพธ์แสดงดังตารางที่ 14



ภาพที่ 34 กราฟการเรียนรู้ อเล็กซ์เน็ต

ตารางที่ 14 การประเมินสมรรถนะแบบจำลองอเล็กซ์เน็ตที่ใช้ชุดข้อมูลที่มีจำนวนต่างกัน


	จำนวนชุดข้อมูลที่ใช้		
ตัววัด	1390 ภาพ	1986 ภาพ	3310 ภาพ
ความแม่นยำ	75.18%	83.92%	92.90%
ความไว	73.33%	82.45%	92.51%
ความจำเพาะ	76.92%	85.40%	93.24%

จากตารางที่ 14 พบว่าเมื่อชุดข้อมูลที่นำไปเรียนรู้ให้กับแบบจำลองมีจำนวนมากขึ้น ประสิทธิภาพของแบบจำลองจะสูงขึ้น ซึ่งค่าความแม่นยำของแบบจำลอง อเล็กซ์เน็ต ก็กับการใช้ข้อมูลจำนวน 1390 ภาพจะให้ค่าความแม่นยำ 75.18% ข้อมูลจำนวน 1986 ภาพจะให้ค่าความแม่นยำ 83.92% และข้อมูลจำนวน 3310 ภาพจะให้ค่าความแม่นยำ 92.90%

4.4.2 ผลการทดลองของ วีจีจี-16

การทดลองนี้ จะทำการเปรียบเทียบขนาดข้อมูลที่ใช้ในการสร้างแบบจำลอง ซึ่งข้อมูลที่ใช้ในการสร้างแบบจำลองจะแบ่งเป็นข้อมูลที่ไม่มีการเพิ่มจำนวนข้อมูลด้วยเทคนิค shuffle sampling และข้อมูลที่เพิ่มจำนวนด้วยเทคนิค shuffle sampling ให้มีจำนวน 1986 ภาพ และ 3310 ภาพ โดยจะแบ่งข้อมูลของการเรียนรู้ออกเป็นชุดข้อมูลสอน 60% ชุดข้อมูลทวนสอบ 20% และชุดข้อมูล

ทดสอบ 20% ของจำนวนข้อมูลทั้งหมดที่ใช้ กราฟการเรียนรู้ของแบบจำลอง วิธีจี-16 เป็นดังภาพที่ 35 ซึ่งใช้ค่าความแม่นยำที่แต่ละรอบ epoch ที่แบบจำลองไปสร้างจากชุดข้อมูลสอนแล้วนำไปทดสอบค่าความแม่นยำกับชุดข้อมูลทดสอบ และค่าความแม่นยำ ความไว และความจำเพาะของแบบจำลอง อเล็กซ์เน็ต ที่เรียนรู้ด้วยชุดข้อมูลทั้ง 3 ขนาดจะทำนายกับชุดข้อมูลทดสอบ สรุปผลลัพธ์ดังแสดงในตารางที่ 15 พบว่าเมื่อชุดข้อมูลที่นำไปเรียนรู้ให้กับแบบจำลองมีจำนวนมากขึ้น ประสิทธิภาพของแบบจำลองจะสูงขึ้น ซึ่งค่าความแม่นยำ ของแบบจำลอง วิธีจี-16 กับการใช้ข้อมูลจำนวน 1390 ภาพจะให้ค่าความแม่นยำ 76.26% ข้อมูลจำนวน 1986 ภาพจะให้ค่าความแม่นยำ 81.91% และข้อมูลจำนวน 3310 ภาพจะให้ค่าความแม่นยำ 94.56%



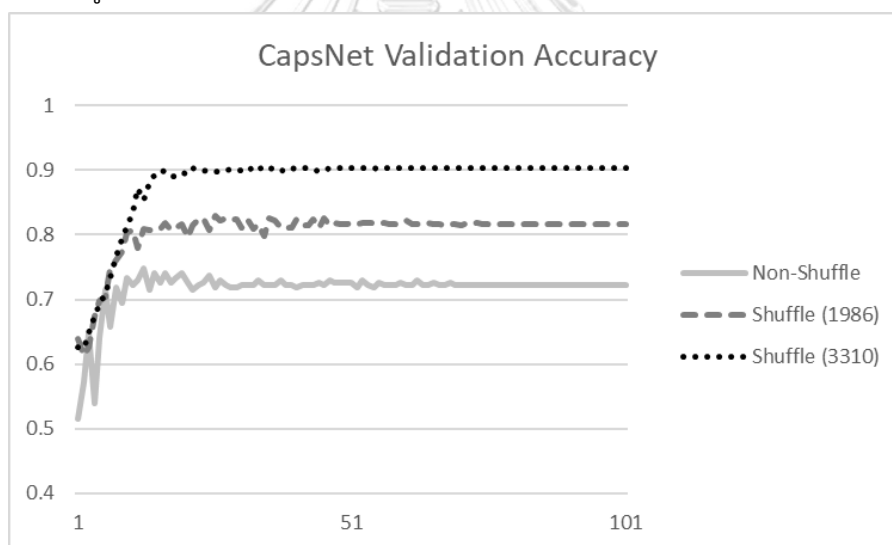
ภาพที่ 35 กราฟการเรียนรู้ วิธีจี-16

ตารางที่ 15 การประเมินสมรรถนะแบบจำลองวิธีจี-16 ที่ใช้ชุดข้อมูลที่มีจำนวนต่างกัน

ตัววัด	จำนวนชุดข้อมูลที่ใช้		
	1390 ภาพ	1986 ภาพ	3310 ภาพ
ความแม่นยำ	76.26%	81.91%	94.56%
ความไว	74.07%	80.42%	92.83%
ความจำเพาะ	78.32%	82.30%	96.06%

4.4.3 ผลการทดลองของโครงข่ายแคปซูล (แคปส์เน็ต)

การทดลองนี้ จะทำการเปรียบเทียบขนาดข้อมูลที่ใช้ในการสร้างแบบจำลอง ซึ่งข้อมูลที่ใช้ในการสร้างแบบจำลองจะแบ่งเป็นข้อมูลที่ไม่มีการเพิ่มจำนวนข้อมูลด้วยเทคนิค shuffle sampling และข้อมูลที่เพิ่มจำนวนด้วยเทคนิค shuffle sampling ให้มีจำนวน 1986 ภาพ และ 3310 ภาพ โดยจะแบ่งข้อมูลของการเรียนรู้ออกเป็นชุดข้อมูลสอน 60% ชุดข้อมูลทวนสอบ 20% และชุดข้อมูลทดสอบ 20% ของจำนวนข้อมูลทั้งหมดที่ใช้ กราฟการเรียนรู้ของแบบจำลอง แคปส์เน็ต เป็นดังภาพที่ 36 ซึ่งใช้ค่าความแม่นยำที่แต่ละรอบ epoch ที่แบบจำลองไปสร้างจากชุดข้อมูลสอนแล้วนำไปทดสอบค่าความแม่นยำกับชุดข้อมูลทวนสอบ และค่าความแม่นยำ ความไว และความจำเพาะของแบบจำลอง แคปส์เน็ต ที่เรียนรู้ด้วยชุดข้อมูลทั้ง 3 ขนาดจะทำนายกับชุดข้อมูลทดสอบ สรุปผลลัพธ์ดังแสดงในตารางที่ 16 พบว่าเมื่อชุดข้อมูลที่น่าไปเรียนรู้ให้กับแบบจำลองมีจำนวนมากขึ้น ประสิทธิภาพของแบบจำลองจะสูงขึ้น ซึ่งค่าความแม่นยำของแบบจำลอง แคปส์เน็ต กับการใช้ข้อมูลจำนวน 1390 ภาพจะให้ค่าความแม่นยำ 73.74% ข้อมูลจำนวน 1986 ภาพจะให้ค่าความแม่นยำ 82.16% และข้อมูลจำนวน 3310 ภาพจะให้ค่าความแม่นยำ 90.33%



ภาพที่ 36 กราฟการเรียนรู้ แคปส์เน็ต

ตารางที่ 16 การประเมินสมรรถนะแบบจำลองแคปส์เน็ตที่ใช้ชุดข้อมูลที่มีจำนวนต่างกัน

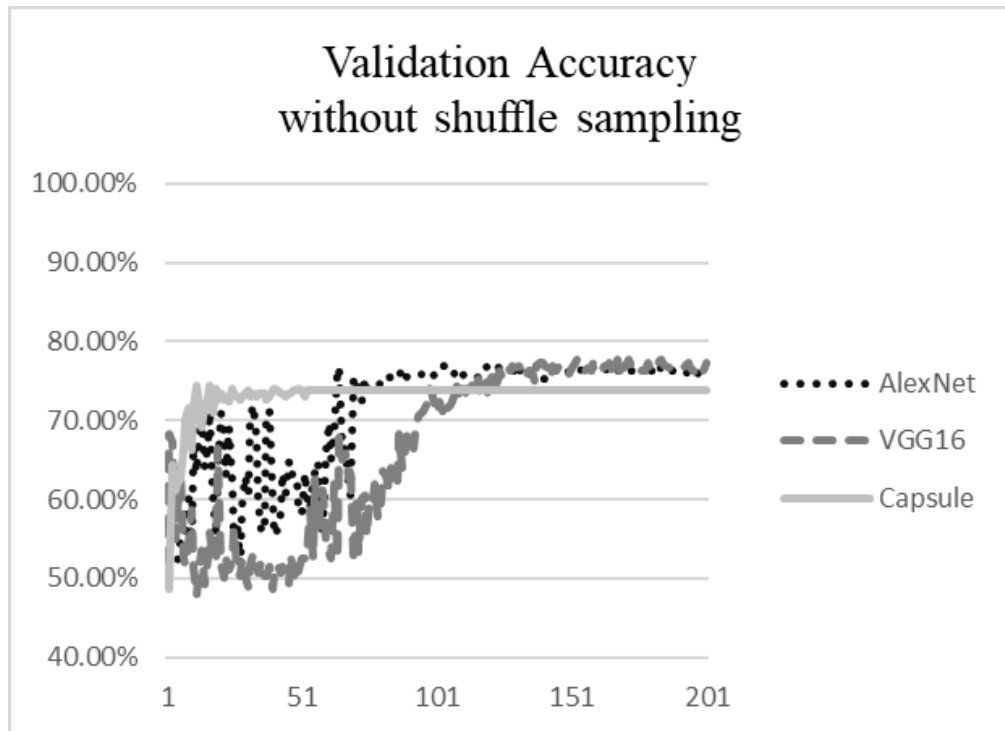
ตัววัด	จำนวนชุดข้อมูลที่ใช้		
	1390 ภาพ	1986 ภาพ	3310 ภาพ
ความแม่นยำ	73.74%	82.16%	90.33%
ความไว	72.59%	79.37%	86.32%
ความจำเพาะ	74.83%	84.69%	93.80%

4.4.4 เปรียบเทียบผลการทดลองทั้ง 3 แบบจำลองกับจำนวนชุดข้อมูลที่แตกต่างกัน


รายละเอียดผลการทดลองทั้ง 3 แบบจำลองแสดงในตารางที่ 17 พบว่าในชุดข้อมูลที่ไม่ได้เพิ่มจำนวนข้อมูลแบบจำลอง วีจีจี-16 จะให้ค่าความแม่นยำ ความไว และความจำเพาะสูงสุดเป็น 76.26%, 74.07% และ 78.32% ตามลำดับ ส่วนชุดข้อมูลที่เพิ่มจำนวนข้อมูลด้วยเทคนิค shuffle sampling ให้มีจำนวนข้อมูลเป็น 1986 ภาพ แบบจำลอง อเล็กซ์เน็ต จะมีประสิทธิภาพสูงสุด ซึ่งค่าความแม่นยำ ความไว และความจำเพาะสูงสุดเป็น 83.92%, 82.45% และ 85.40% ส่วนชุดข้อมูลที่เพิ่มขึ้นด้วยเทคนิค shuffle sampling ให้มีจำนวนข้อมูลเป็น 3310 ภาพ แบบจำลอง วีจีจี-16 จะให้ค่าความแม่นยำ ความไว และความจำเพาะสูงสุดเป็น 94.56%, 92.83% และ 96.06% ตามลำดับ จากผลการทดลองพบว่าทั้ง 3 แบบจำลองเมื่อให้จำนวนชุดข้อมูลที่นำไปเรียนรู้แบบจำลองเพิ่มขึ้นจะส่งผลให้ประสิทธิภาพของแบบจำลองดีขึ้น กล่าวคือค่าความแม่นยำ ความไว และความจำเพาะจะเพิ่มสูงขึ้น ภาพที่ 37 แสดงกราฟการเรียนรู้ของแบบจำลองกับชุดข้อมูลที่ไม่ได้เพิ่มจำนวน ภาพที่ 38 แสดงกราฟการเรียนรู้ของแบบจำลองกับชุดข้อมูลที่เพิ่มจำนวนข้อมูลเป็น 1986 ภาพ ภาพที่ 39 แสดงกราฟการเรียนรู้ของแบบจำลองกับชุดข้อมูลที่เพิ่มจำนวนข้อมูลเป็น 3310 ภาพ

ตารางที่ 17 ประสิทธิภาพของแบบจำลองทั้ง 3 แบบ

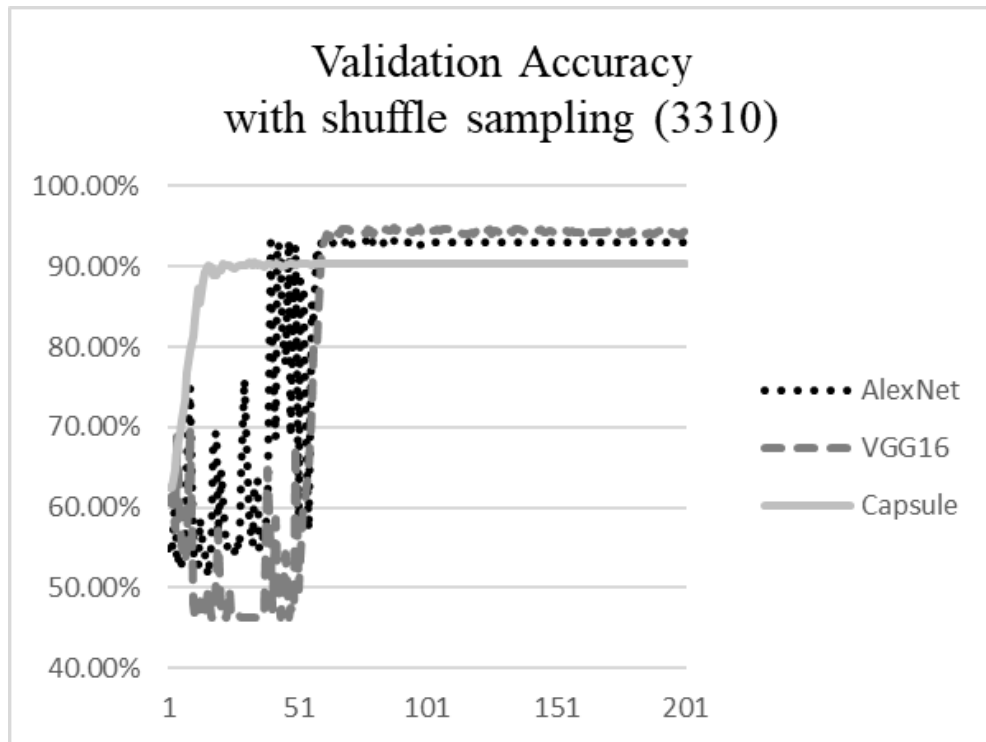
Performance	Non-shuffle sampling			Shuffle sampling (1986)			Shuffle sampling (3310)		
	อเล็กซ์เน็ต	วีจีจี-16	แคปส์เน็ต	อเล็กซ์เน็ต	วีจีจี-16	แคปส์เน็ต	อเล็กซ์เน็ต	วีจีจี-16	แคปส์เน็ต
ความแม่นยำ	75.18%	76.26%	73.74%	83.92%	81.91%	82.16%	92.90%	94.56%	90.33%
ความไว	73.33%	74.07%	72.59%	82.45%	80.42%	79.37%	92.51%	92.83%	86.32%
ความจำเพาะ	76.92%	78.32%	74.83%	85.40%	82.30%	84.69%	93.24%	96.06%	93.80%



ภาพที่ 37 กราฟการเรียนรู้ทั้ง 3 แบบจำลองกับชุดข้อมูลที่ไม่ได้เพิ่มจำนวน



ภาพที่ 38 กราฟการเรียนรู้ทั้ง 3 แบบจำลองกับชุดข้อมูลที่เพิ่มจำนวนข้อมูลเป็น 1986 ภาพ



ภาพที่ 39 กราฟการเรียนรู้ทั้ง 3 แบบจำลองกับชุดข้อมูลที่เพิ่มจำนวนข้อมูลเป็น 3310 ภาพ

4.4.5 ผลการทดลองการทำนายรอยโรคผิวหนังโรคปอดจากภาพที่บิดเบี้ยว

เพื่อทำการทดสอบความสามารถของแบบจำลองทั้ง 3 โครงสร้างกับภาพเอกซเรย์ทรวงอกที่บิดเบี้ยว โดยภาพเอกซเรย์ทรวงอกที่บิดเบี้ยวจะสร้างขึ้นมาจากภาพเอกซเรย์ทรวงอกต้นฉบับ ตัวอย่างภาพเอกซเรย์ทรวงอกที่บิดเบี้ยวดังภาพที่ 40 ซึ่งสร้างด้วยวิธีการตามหัวข้อ 3.1.3 การทดสอบนี้จะใช้ชุดข้อมูลทดสอบอยู่ 2 แบบคือ 1. ชุดข้อมูลภาพเอกซเรย์ทรวงอกที่หมุนภาพมุมระหว่าง -10 ถึง 10 องศา 2. ชุดข้อมูลภาพเอกซเรย์ทรวงอกที่หมุนภาพมุมระหว่าง -30 ถึง 30 องศา โดยที่ชุดข้อมูลสอนที่นำไปเรียนรู้จะใช้ชุดข้อมูลภาพเอกซเรย์ทรวงอกที่ไม่บิดเบี้ยวที่ทำการเพิ่มข้อมูลด้วยเทคนิค shuffle sampling 3310 ภาพ แบ่งเป็นชุดข้อมูลสอน 2648 ภาพ (80%) และชุดข้อมูลทดสอบ 662 ภาพ (20%) ส่วนชุดข้อมูลทดสอบจะสร้างจากภาพเอกซเรย์ทรวงอกต้นฉบับที่มี 1390 ภาพ แต่ละภาพจะบิดมุมด้วยมุมที่สุ่ม ซึ่งจากการทดลองกับภาพเอกซเรย์ทรวงอกที่ไม่บิดเบี้ยวจะให้ประสิทธิภาพสูงสุด แล้วจะเปรียบเทียบประสิทธิภาพของแบบจำลองกับแบบจำลองที่ใช้ชุดข้อมูลสอนที่ทำการเพิ่มข้อมูลด้วยเทคนิค shuffle sampling ร่วมกับเทคนิคการหมุนภาพด้วยมุมระหว่าง -10 ถึง 10 องศา วิธีการทำตามบทที่ 4.2.2



ภาพที่ 40 ตัวอย่างชุดข้อมูลทดสอบภาพเอกซเรย์ทรวงอก

ผลการทดลองการทดสอบความสามารถในการทำนายวินิจฉัยโรคปอดจากภาพเอกซเรย์ทรวงอกที่บิดเบี้ยว โดยสร้างแบบจำลองทั้ง 3 โครงสร้างกับชุดข้อมูลที่เพิ่มจำนวนด้วยเทคนิค shuffle sampling ให้มีจำนวนข้อมูลเป็น 3310 ภาพ เป็นดังตารางที่ 18 พบว่า วิจีจี-16 มีประสิทธิภาพที่บิดเบี้ยวทั้งมุม -10 ถึง 10 องศา และ -30 ถึง 30 องศา ซึ่งมีค่าความแม่นยำเป็น 58.50% และ 53.17% ตามลำดับ ส่วน อเล็กซ์เน็ต ให้ค่าความแม่นยำจากการทำนายวินิจฉัยโรคปอดจากภาพที่บิดเบี้ยวด้วยมุม -10 ถึง 10 องศา และ -30 ถึง 30 องศา ซึ่งมีค่าความแม่นยำเป็น 60.33% และ 54.83% ตามลำดับ แคปส์เน็ต จะมีประสิทธิภาพในการทำนายภาพที่บิดเบี้ยวได้ดีที่สุดเมื่อเทียบกับ อเล็กซ์เน็ต และ วิจีจี-16 ซึ่งให้ค่าความแม่นยำเป็น 68.50% กับภาพที่บิดด้วยมุม -10 ถึง 10 องศาและ 63.71% ภาพที่บิดด้วยมุม -30 ถึง 30 องศา

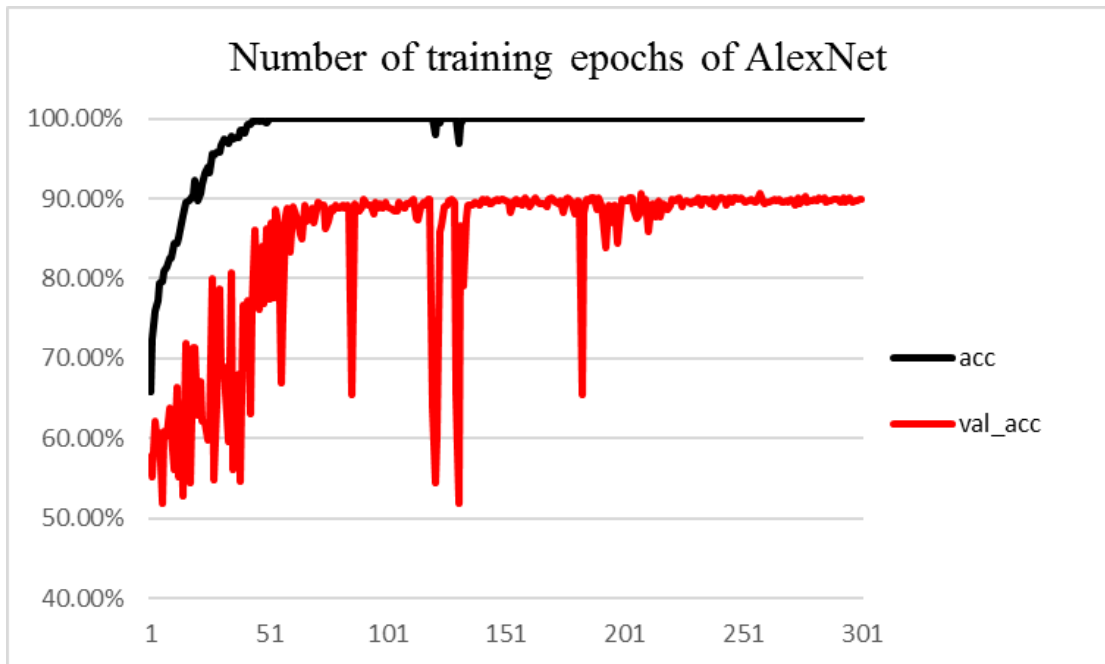
ตารางที่ 18 ผลการทดลองแบบจำลองที่สร้างจากข้อมูลที่ไม่ได้เพิ่มข้อมูลด้วยการหมุนภาพ

	ข้อมูลทดสอบที่บิดมุม -10 ถึง 10 องศา			ข้อมูลทดสอบที่บิดมุม -30 ถึง 30 องศา		
	อเล็กซ์เน็ต	วิจีจี-16	แคปส์เน็ต	อเล็กซ์เน็ต	วิจีจี-16	แคปส์เน็ต
ความแม่นยำ	60.33%	58.50%	68.50%	54.83%	53.17%	63.71%
ความไว	25.00%	20.00%	72.00%	10.00%	9.67%	31.33%
ความจำเพาะ	95.67%	96.67%	65.00%	99.67%	96.67%	95.00%


แบบจำลองทั้ง 3 โครงสร้างที่สร้างด้วยชุดข้อมูลสอนที่เพิ่มข้อมูลด้วยเทคนิค shuffle sampling ยังให้ประสิทธิภาพของผลลัพธ์ไม่ดี งานวิจัยนี้จึงทดลองเพิ่มเติมโดยใส่ข้อมูลที่เพิ่มขึ้นด้วยเทคนิคการหมุนเพิ่มเติมเข้าไป รายละเอียดเทคนิคการเพิ่มข้อมูลดูได้ในบทที่ 3.1.2 โดยชุดข้อมูลที่เพิ่มขึ้นจะใช้มุมที่หมุนภาพระหว่าง -10 ถึง 10 องศา แต่ละภาพจะถูกหมุนแบบสุ่มซึ่งชุดข้อมูล

ทั้งหมดที่ใช้จะมีทั้งหมด 6620 ภาพ แบ่งออกเป็นชุดข้อมูลสอน 5296 ภาพ (80%) ชุดข้อมูลทวนสอบ 1324 ภาพ (20%) ส่วนชุดข้อมูลทดสอบจะสร้างจากภาพเอกซเรย์ทรวงอกต้นฉบับที่มี 1390 ภาพ แต่ละภาพจะบิดมุมด้วยมุมที่สุ่มซึ่งจะเป็นชุดข้อมูลสอนชุดเดียวกันกับชุดข้อมูลที่น่าไปทดสอบกับแบบจำลองที่สร้างด้วยเทคนิคการเพิ่มข้อมูลด้วย shuffle sampling เพียงอย่างเดียว


ผลการทดลองการทดสอบความสามารถในการทำนายวัณโรคปอดจากภาพเอกซเรย์ทรวงอกที่บิดเบี้ยวโดยสร้างแบบจำลองทั้ง 3 โครงสร้างกับชุดข้อมูลที่เพิ่มจำนวนด้วยเทคนิค shuffle sampling และเทคนิคการหมุนภาพให้มีจำนวนข้อมูลเป็น 6620 ภาพ ภาพที่ 41 แสดงกราฟการเรียนรู้ในแต่ละรอบของแบบจำลองของ อเล็กซ์เน็ต ภาพที่ 42 แสดงกราฟการเรียนรู้ในแต่ละรอบของแบบจำลองของ วีจีจี-16 ภาพที่ 43 แสดงกราฟการเรียนรู้ในแต่ละรอบของแบบจำลองของ แคปส์เน็ต พบว่ารอบ epoch ที่ใช้ในการเรียนรู้แบบจำลอง แคปส์เน็ต จะใช้รอบ epoch น้อยที่สุด ส่วน อเล็กซ์เน็ต จะใช้รอบ epoch มากที่สุด ประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้างเป็นดังตารางที่ 19 พบว่า อเล็กซ์เน็ต เมื่อทดสอบกับชุดข้อมูลภาพที่บิดเบี้ยวทั้งมุม -10 ถึง 10 องศา และ -30 ถึง 30 องศา มีค่าความแม่นยำเป็น 90.63% และ 70.09% ตามลำดับ ส่วน วีจีจี-16 เมื่อทดสอบกับชุดข้อมูลภาพที่บิดเบี้ยวทั้งมุม -10 ถึง 10 องศา และ -30 ถึง 30 องศา มีค่าความแม่นยำเป็น 90.79% และ 74.17% ตามลำดับ แคปส์เน็ต เมื่อทดสอบกับชุดข้อมูลภาพที่บิดเบี้ยวทั้งมุม -10 ถึง 10 องศา และ -30 ถึง 30 องศา มีค่าความแม่นยำเป็น 86.86% และ 80.06% ตามลำดับ อเล็กซ์เน็ต และ วีจีจี-16 เมื่อทดสอบกับภาพที่บิดด้วยมุมระหว่าง -10 ถึง 10 องศา พบว่าจะค่าความแม่นยำที่สูงกว่า แคปส์เน็ต และทั้ง อเล็กซ์เน็ต และ วีจีจี-16 จะให้ประสิทธิภาพของแบบจำลองที่ไม่แตกต่างกันอย่างมีนัยสำคัญ ส่วน แคปส์เน็ต จะมีประสิทธิภาพในการทำนายรอยโรควัณโรคปอดจากภาพที่บิดด้วยมุมระหว่าง -30 ถึง 30 องศา ดีกว่าแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16



ภาพที่ 41 กราฟการเรียนรู้ของแบบจำลอง อเล็กซ์เน็ต ด้วยชุดข้อมูลสอนที่เพิ่มด้วยเทคนิคการหมุน



ภาพที่ 42 กราฟการเรียนรู้ของแบบจำลอง วีจีจี-16 ด้วยชุดข้อมูลสอนที่เพิ่มด้วยเทคนิคการหมุน



ภาพที่ 43 กราฟการเรียนรู้ของแบบจำลอง แคปส์เน็ต ด้วยชุดข้อมูลสอนที่เพิ่มด้วยเทคนิคการหมุน

ตารางที่ 19 ผลการทดลองแบบจำลองที่สร้างจากข้อมูลที่เพิ่มข้อมูลด้วยการหมุนภาพ

	ข้อมูลทดสอบที่บิดมุม -10 ถึง 10 องศา			ข้อมูลทดสอบที่บิดมุม -30 ถึง 30 องศา		
	อเล็กซ์เน็ต	วีจีจี-16	แคปส์เน็ต	อเล็กซ์เน็ต	วีจีจี-16	แคปส์เน็ต
ความแม่นยำ	90.63%	90.79%	86.86%	70.09%	74.17%	80.06%
ความไว	89.07%	88.74%	85.43%	68.21%	65.56%	92.72%
ความจำเพาะ	91.94%	92.50%	88.06%	71.67%	81.39%	69.44%

4.5 วิเคราะห์ผลการทดลอง

จากผลการทดลองในบทที่ 4.4.1-4.4.4 วิธีการเพิ่มข้อมูลด้วยเทคนิค shuffle sampling ที่นำเสนอส่งผลให้ประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้างดีขึ้น ในชุดข้อมูลที่เพิ่มขึ้นด้วยเทคนิค shuffle sampling ที่เพิ่มจำนวนเป็น 3310 ภาพ พบว่า วีจีจี-16 มีประสิทธิภาพที่ดีที่สุดกล่าวคือ วีจีจี-16 เนื่องจากโครงสร้าง วีจีจี-16 มีความสามารถในการเรียนรู้การจดจำรูปภาพที่เข้ากับชุดข้อมูลสอนได้ดีกว่าโครงสร้างแบบ อเล็กซ์เน็ต และ แคปส์เน็ต แต่เมื่อนำแบบจำลองที่สร้างขึ้นด้วยเทคนิค shuffle sampling ทั้ง 3 แบบจำลองไปทดสอบกับข้อมูลทดสอบที่บิดเบี้ยวพบว่า แคปส์เน็ต ให้ประสิทธิภาพในการทำนายได้ดีกว่า อเล็กซ์เน็ต และ วีจีจี-16 ซึ่งจากผลการทดลองกับภาพที่บิดเบี้ยวมุม -30 ถึง 30 องศา แบบจำลองทั้ง อเล็กซ์เน็ต และ วีจีจี-16 จะทำนายภาพเอกซเรย์ทรงอกให้เป็นคลาสปกติเกือบทั้งหมด หมายความว่าแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 ถ้าชุดข้อมูลทดสอบไม่มี

ข้อมูลที่มีลักษณะเหมือนกับชุดข้อมูลสอนจะไม่สามารถทำนายรูปภาพนั้นได้เลย แต่ แคปส์เน็ต ยังคงความสามารถในการทำนายได้ดีกว่าต่อให้ไม่มีชุดข้อมูลตัวนั้นก็ตาม เพราะ แคปส์เน็ต จะใช้วิธีการหาคุณลักษณะโดยที่ไม่มีการทิ้งความสัมพันธ์กับคุณลักษณะอื่น และเนื่องจาก แคปส์เน็ต ยังแปลงข้อมูลให้อยู่ในรูปแบบเวกเตอร์ จึงสามารถทำนายข้อมูลที่มีการบิดมุมได้เล็กน้อยอีกด้วย โดยที่ทั้ง อเล็กซ์เน็ต และ วีจีจี-16 ไม่สามารถทำได้จึงส่งผลให้ประสิทธิภาพการทำนายให้ผลลัพธ์ที่แย่

จากผลการทดลองในบทที่ 4.4.5 เพื่อแก้ปัญหาแบบจำลองไม่สามารถจำแนกประเภทชุดข้อมูลที่เป็นภาพบิดเบี้ยว จึงใช้วิธีการเพิ่มชุดข้อมูลด้วยการหมุนภาพร่วมกับเทคนิค shuffle sampling เพื่อเพิ่มประสิทธิภาพแบบจำลองกับภาพบิดเบี้ยว จากตารางที่ 19 พบว่าเมื่อแบบจำลองที่ได้เพิ่มชุดข้อมูลด้วยรูปภาพที่บิดมุมระหว่าง -10 ถึง 10 องศา แล้วนำไปทดสอบกับชุดข้อมูลที่บิดมุมระหว่าง -10 ถึง 10 องศา ประสิทธิภาพของแบบจำลองทั้ง 3 แบบเพิ่มขึ้นเมื่อเทียบกับการสร้างแบบจำลองด้วยข้อมูลที่ไม่ได้เพิ่มใช้เทคนิคเพิ่มข้อมูลด้วยการหมุนภาพ แต่เมื่อทดสอบกับชุดข้อมูลทดสอบด้วยภาพบิดมุมระหว่าง -30 ถึง 30 องศา พบว่าประสิทธิภาพของแบบจำลองทั้ง 3 แบบลดลง โดยเฉพาะแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 ที่แบบจำลองมีประสิทธิภาพลดลงมากเมื่อเทียบกับ แคปส์เน็ต ที่ลดลงเพียงเล็กน้อยเท่านั้น จึงเป็นการยืนยันได้ว่าโครงสร้าง อเล็กซ์เน็ต และ วีจีจี-16 มีความสามารถในการจดจำรูปภาพที่ต้องมีลักษณะเหมือนกับภาพที่นำไปเรียนรู้ให้กับตัวแบบจำลองเท่านั้น เมื่อมีข้อมูลที่ไม่ได้นำไปเรียนรู้จะไม่สามารถทำนายให้ถูกต้องได้ แต่ แคปส์เน็ต มีความสามารถในการทำนายภาพที่บิดเบี้ยวได้ดีกว่า แต่ แคปส์เน็ต จะจดจำรูปภาพที่มีลักษณะที่เหมือนกับภาพต้นฉบับได้ไม่ดีเท่ากับแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 หมายความว่าแบบจำลอง แคปส์เน็ต เหมาะกับชุดข้อมูลที่มีจำนวนน้อยและมีรายละเอียดของภาพที่แตกต่างกันมาก ส่วนแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 เหมาะกับชุดข้อมูลที่มีจำนวนมาก ๆ จึงจะให้ประสิทธิภาพของแบบจำลองที่ดี โดยที่ชุดข้อมูลนั้นต้องครอบคลุมลักษณะสำคัญต่าง ๆ ของภาพให้ครบทุกรูปแบบ หรือก็คือแบบจำลอง แคปส์เน็ต มีความเป็นเจนเนอรัลไลเซชัน (Generalization) มากกว่า อเล็กซ์เน็ต และ วีจีจี-16

จากภาพที่ 41, ภาพที่ 42 และ ภาพที่ 43 พบว่าแบบจำลอง แคปส์เน็ต มีความสามารถในการเรียนรู้โดยใช้รอบในการเรียนรู้ (epoch) น้อยกว่าแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 และตัวกราฟการเรียนรู้ค่อนข้างที่จะนิ่งมากกว่าไม่มีการแกว่งของค่า Validation Accuracy แบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 จะมีการปรับน้ำหนักโดยขึ้นกับข้อมูลที่นำไปเรียนรู้ ถ้าข้อมูลที่นำไปเรียนรู้ไม่มีลักษณะที่เหมือนกับชุดข้อมูลสอน จะเกิดการทำนายที่ผิดพลาดให้ค่า Validation Accuracy ขึ้น ๆ ลง ๆ ตามค่าน้ำหนักที่ปรับ แต่เมื่อดูกราฟเส้น Training Accuracy ซึ่งก็คือการทำนายแบบจำลองด้วยชุดข้อมูลสอนพบว่าเส้นกราฟจะมีลักษณะที่เพิ่มขึ้นแบบค่อนข้างนิ่ง เนื่องจากชุดข้อมูลสอนที่นำไปเรียนรู้ตัวแบบจำลองจะปรับน้ำหนักตามชุดข้อมูลสอน กราฟที่ได้จึงค่า Training Accuracy ที่เพิ่มขึ้น ในทางกลับกันแบบจำลอง แคปส์เน็ต ไม่ว่าจะป็นเส้นกราฟของ Training Accuracy หรือ

Validation Accuracy จะมีเส้นลักษณะที่เพิ่มขึ้นแบบค่อนข้างที่นิ่งทั้งคู่จะไม่มีค่าที่ขึ้น ๆ ลง มากนั้น ไม่เหมือนกับ อเล็กซ์เน็ต และ วีจีจี-16 ซึ่งหมายความว่า แคปส์เน็ต แบบจำลองที่สามารถทำนาย ข้อมูลรูปภาพที่มีลักษณะที่แตกต่างจากชุดข้อมูลภาพที่นำไปเรียนรู้ได้ดีกว่าแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 เพราะ แคปส์เน็ต จะไม่มีชั้น Pooling ที่ใช้ใน อเล็กซ์เน็ต และ วีจีจี-16 โดยที่หน้าที่ ของชั้น Pooling จะทำหน้าที่ลดพารามิเตอร์ที่ใช้ในการคำนวณแต่มีข้อเสียก็คือชั้น Pooling จะทำให้ คุณลักษณะของภาพสูญเสียความสัมพันธ์กับคุณลักษณะอื่น ๆ และสูญเสียตำแหน่งของคุณลักษณะ ในภาพนั้น แต่ แคปส์เน็ต ได้ปรับเปลี่ยนไม่ใช่ชั้น Pooling แต่ใช้เทคนิคเก็บคุณลักษณะและคำนวณ ร่วมกับคุณลักษณะอื่นในรูปแบบ Capsule จึงทำให้ แคปส์เน็ต สามารถคงความสัมพันธ์ของ คุณลักษณะและตำแหน่งได้



บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปการวิจัย

วิทยานิพนธ์นี้ได้เสนอโครงข่ายแคปซูลที่ได้มีการปรับโครงสร้างให้เหมาะสมกับชุดข้อมูลการทำนายรอยโรคผิวหนังโรคปอดจากภาพเอกซเรย์ทรวงอก โดยได้ดำเนินการตามขอบเขตดังนี้

1. ทำการทำนายรอยโรคผิวหนังโรคปอดจากภาพเอกซเรย์ทรวงอกด้วยโครงข่ายคอนโวลูชันที่มีโครงสร้างแบบ อเล็กซ์เน็ต, วีจีจี-16 และ แคปส์เน็ต
2. เปรียบเทียบสมรรถนะของโครงข่ายแคปซูลเมื่อมีการปรับโครงสร้างแล้วกับโครงสร้างแบบ อเล็กซ์เน็ต และ วีจีจี-16
3. เปรียบเทียบเทคนิคการเพิ่มข้อมูลเพื่อเพิ่มสมรรถนะให้กับแบบจำลอง ได้แก่
 - การเพิ่มข้อมูลด้วยเทคนิค shuffle sampling
 - การเพิ่มข้อมูลด้วยเทคนิคการหมุนภาพ
4. เปรียบเทียบสมรรถนะของโครงข่ายแคปซูลและโครงสร้างแบบ อเล็กซ์เน็ต และ วีจีจี-16 กับข้อมูลภาพเอกซเรย์ทรวงอกที่บิดเบี้ยว

ซึ่งเทคนิคการเพิ่มข้อมูลด้วยเทคนิค shuffle sampling ส่งผลให้ประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้างดีขึ้นเมื่อเทียบกับการที่ให้แบบจำลองเรียนรู้โดยชุดข้อมูลเดิม และเทคนิคการเพิ่มข้อมูลด้วยการหมุนภาพ ส่งผลให้แบบจำลองทั้ง 3 โครงสร้างสามารถทำนายรอยโรคผิวหนังโรคปอดจากภาพที่บิดเบี้ยวได้ดีขึ้น

สำหรับการทดลอง ผู้วิจัยได้แบ่งวิธีการทดลองโดยแบ่งออกเป็น 2 แบบ ได้แก่ การสร้างแบบจำลองด้วยชุดข้อมูลที่เพิ่มขึ้นด้วยเทคนิค shuffle sampling และการสร้างแบบจำลองด้วยชุดข้อมูลที่เพิ่มขึ้นด้วยเทคนิคการหมุนภาพ ซึ่งแบบจำลองทั้ง 3 โครงสร้างได้ทำการปรับเปลี่ยนตัวกรองขนาดตัวกรองและพารามิเตอร์อื่น ๆ เพื่อให้ได้ผลการทดลองที่มีประสิทธิภาพมากที่สุดในชุดข้อมูลที่นำไปเรียนรู้

การผลการทดลองการเปรียบเทียบเทคนิคการเพิ่มข้อมูลด้วยเทคนิค shuffle sampling พบว่า แบบจำลอง วีจีจี-16 มีประสิทธิภาพในการทำนายรอยโรคผิวหนังโรคปอดจากภาพเอกซเรย์ทรวงอกได้ดีกว่าโครงสร้าง อเล็กซ์เน็ต และ แคปส์เน็ต ซึ่ง แคปส์เน็ต มีประสิทธิภาพต่ำที่สุด แต่เมื่อนำแบบจำลองที่สร้างจากชุดข้อมูล shuffle sampling ไปทดสอบกับชุดข้อมูลทดสอบที่เป็นภาพบิดเบี้ยว ผลการทดลองแสดงให้เห็นว่าทั้ง วีจีจี-16 และ อเล็กซ์เน็ต ที่มีประสิทธิภาพเมื่อทำนายกับภาพปกติกลับมีประสิทธิภาพที่แย่กว่า แคปส์เน็ต แต่ทั้งนี้แบบจำลองทั้ง 3 โครงสร้างก็ให้ค่าความแม่นยำที่ไม่ถึง 70% ทั้ง 3 โครงสร้าง จึงต้องใช้วิธีการเพิ่มชุดข้อมูลด้วยเทคนิคการหมุนภาพเข้าไปในชุด

ข้อมูลสอนเพิ่มเติม ผลการทดลองพบว่าทั้ง 3 โครงสร้างเมื่อสร้างแบบจำลองด้วยชุดข้อมูลที่เพิ่มขึ้น ด้วยเทคนิคการหมุนภาพระหว่างมุม -10 ถึง 10 องศา แล้วนำไปทดสอบกับชุดข้อมูลทดสอบที่ภาพบิดมุม -10 องศา ถึง 10 องศา ประสิทธิภาพของแบบจำลองทั้ง 3 โครงสร้างสูงขึ้นและสูงเกินกว่า 85% โดยที่ วีจีจี-16 มีประสิทธิภาพที่ดีกว่า อเล็กซ์เน็ต และ แคปส์เน็ต เมื่อนำแบบจำลองไปทดสอบกับชุดข้อมูลทดสอบที่ภาพบิดมุม -30 องศา ถึง 30 องศา ผลการทดลองแสดงให้เห็นประสิทธิภาพของแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 มีประสิทธิภาพลดลงอย่างมาก เมื่อเทียบกับ แคปส์เน็ต ที่ลดลงเพียงเล็กน้อย กล่าวคือ อเล็กซ์เน็ต และ วีจีจี-16 เหมาะกับชุดข้อมูลที่มีจำนวนข้อมูลมากและข้อมูลที่ครอบคลุมลักษณะสำคัญในชุดข้อมูลสอนให้หลากหลายรูปแบบ เพราะสามารถจดจำลักษณะของข้อมูลได้ดี ส่วน แคปส์เน็ต เป็นแบบจำลองที่สามารถทำนายข้อมูลรูปภาพที่มีลักษณะที่แตกต่างจากชุดข้อมูลภาพที่นำไปเรียนรู้ได้ดีกว่าแบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16

ประโยชน์ที่ได้จากการใช้แบบจำลองในการทำนายโรคปอดจากภาพเอกซเรย์ทรวงอก จะช่วยให้แพทย์ลดระยะวินิจฉัยในการตรวจหาโรคปอดจากภาพเอกซเรย์ทรวงอกได้ และสามารถช่วยให้แพทย์ลดข้อผิดพลาดในการวินิจฉัยได้ สามารถการเลือกใช้โครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสมกับชุดข้อมูลภาพเอกซเรย์ได้ ซึ่งถ้าชุดข้อมูลภาพเอกซเรย์ทรวงอกมีจำนวนมากและมีภาพเอกซเรย์ทรวงอกที่บิดเบือนน้อยก็เลือกใช้แบบจำลอง อเล็กซ์เน็ต และ วีจีจี-16 ที่สามารถจดจำลักษณะรูปภาพได้ดี ส่วนถ้าผู้ป่วยเป็นโรคกระดูกสันหลังคดหรือภาพเอกซเรย์ทรวงอกที่ได้ถ่ายมานั้นมีรูปร่างที่บิดเบือนเล็กน้อยจะเลือกใช้แบบจำลองแคปส์เน็ต เพื่อที่จะสามารถทำนายโรคปอดได้อย่างมีประสิทธิภาพ ครอบคลุมการทำนายโรคปอดจากภาพดิจิทัลเอกซเรย์ทรวงอกที่ผิดรูปได้ดีกว่าแบบจำลองเปรียบเทียบ

5.2 ข้อเสนอแนะ

งานวิจัยนี้ ได้ปรับปรุงโครงสร้างของโครงข่ายประสาทเทียมคอนโวลูชันและปรับพารามิเตอร์ต่าง ๆ ของตัวกรอง ขนาดตัวกรอง จำนวนชั้นคอนโวลูชัน จำนวนชั้นการเชื่อมโยงเต็มรูปแบบและจำนวนนิวรอลที่เลียนแบบมาจากโครงสร้างเดิม การปรับเปลี่ยนโครงสร้างและการนำเทคนิคแต่ละแบบของแต่ละโครงสร้างมาใช้ร่วมกันจะสามารถช่วยให้แบบจำลองมีประสิทธิภาพที่ดีขึ้นเมื่อใช้กับภาพเอกซเรย์ทรวงอก

ข้อมูลที่นำมาใช้ในการทดลองนี้ เป็นข้อมูลที่มีขนาดเล็ก ซึ่งในการทำนายรูปภาพโดยใช้โครงสร้างโครงข่ายประสาทเทียมคอนโวลูชันนั้นต้องใช้ข้อมูลที่มีขนาดใหญ่มาก โดยอ้างอิงจากงานวิจัยที่เคยมีมาก่อน โดยชุดข้อมูลที่เป็นรูปภาพอื่นที่ไม่ใช่ภาพเอกซเรย์ทรวงอก จะใช้ชุดข้อมูลรูปภาพประมาณ 10,000 ภาพต่อคลาส การทดสอบกับชุดข้อมูลที่มีขนาดใหญ่จะช่วยให้ยืนยันผลการทดลองให้มีความชัดเจนยิ่งขึ้นได้ หรือการใช้เทคนิคการเพิ่มจำนวนข้อมูลเทคนิคอื่น ๆ ที่จะสามารถ

จำลองภาพเอกซเรย์ทรวงอกที่มีลักษณะอื่น ๆ ที่ใกล้เคียงกับภาพเอกซเรย์ทรวงอกที่ถ่ายจริงก็จะช่วยให้ผลการทดลองนี้มีความชัดเจนมากยิ่งขึ้นเมื่อนำไปใช้จริง

การใช้เทคนิคอื่น ๆ มาร่วมกับการใช้โครงข่ายประสาทเทียมคอนโวลูชันเพียงอย่างเดียว เช่น เทคนิคตัดภาพเฉพาะบริเวณส่วนที่เป็นรูปร่างปอด หรือการนำข้อความอาการเบื้องต้นของผู้ป่วย มาร่วมวินิจฉัยจะช่วยให้แบบจำลองสามารถทำนายรอยโรคฉับโรคปอดจากภาพเอกซเรย์ทรวงอกได้ดียิ่งขึ้น



บรรณานุกรม

- [1] "World Health Organization. Global tuberculosis report 2016," 2016.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," presented at the Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1, Lake Tahoe, Nevada, 2012.
- [3] K. Simonyan and A. Zisserman, *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 2014.
- [4] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. B. Wojna, *Rethinking the Inception Architecture for Computer Vision*. 2016.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770-778.
- [6] F. Chollet, *Xception: Deep Learning with Depthwise Separable Convolutions*. 2017, pp. 1800-1807.
- [7] S. Sabour, N. Frosst, and G. E Hinton, *Dynamic Routing Between Capsules*. 2017.
- [8] T. Tonpho, A. Leelasantitham, and S. Kiattisin, "Investigation of chest x-ray images based on medical knowledge and balanced histograms," in *2010 International Symposium on Intelligent Signal Processing and Communication Systems*, 2010, pp. 1-4.
- [9] K. Shridhar. (2017). *A Beginners Guide to Deep Learning*. Available: <https://medium.com/@shridhar743/a-beginners-guide-to-deep-learning-5ee814cf7706>
- [10] F.-F. Li, J. Johnson, and S. Yeung. *CS231n Convolutional Neural Networks for Visual Recognition*. Available: <http://cs231n.github.io/neural-networks-1/>
- [11] A. Deshpande. (2016). *A Beginner's Guide To Understanding Convolutional Neural Networks*. Available: <https://adeshpande3.github.io/A-Beginner%27s-Guide-To-Understanding-Convolutional-Neural-Networks/>
- [12] I. Goodfellow. (2016). *Convolutional Networks Lecture slides for Chapter 9 of*

- Deep Learning*. Available: http://www.deeplearningbook.org/slides/09_conv.pdf
- [13] (2017). *A toy convolutional neural network for image classification with Keras*. Available: https://www.kernix.com/blog/a-toy-convolutional-neural-network-for-image-classification-with-keras_p14
- [14] Y. Dong, Y. Pan, J. Zhang, and W. Xu, "Learning to Read Chest X-Ray Images from 16000+ Examples Using CNN," in *2017 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, 2017, pp. 51-57.
- [15] S. Hwang, H.-E. Kim, J. Jeong, and H.-J. Kim, "A novel approach for tuberculosis screening based on deep convolutional neural networks," in *SPIE Medical Imaging*, 2016, vol. 9785, p. 8: SPIE.
- [16] Y. Cao *et al.*, "Improving Tuberculosis Diagnostics Using Deep Learning and Mobile Health Technologies among Resource-Poor and Marginalized Communities," in *2016 IEEE First International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, 2016, pp. 274-281.
- [17] C. Szegedy *et al.*, "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1-9.
- [18] R. Hooda, S. Sofat, S. Kaur, A. Mittal, and F. Meriaudeau, "Deep-learning: A potential method for tuberculosis detection using chest radiography," in *2017 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*, 2017, pp. 497-502.
- [19] C. Liu *et al.*, "TX-CNN: Detecting tuberculosis in chest X-ray images using convolutional neural network," in *2017 IEEE International Conference on Image Processing (ICIP)*, 2017, pp. 2314-2318.
- [20] S. Rajaraman, S. Antani, S. Candemir, Z. Xue, M. Kohli, and G. Thoma, *Comparing deep learning models for population screening using chest radiography*. 2018.
- [21] S. Ioffe and C. Szegedy, *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift*. 2015.
- [22] S. Stirenko *et al.*, *Chest X-Ray Analysis of Tuberculosis by Deep Learning with Segmentation and Augmentation*. 2018.
- [23] H. Rahul and M. Ajay, "Automated Tuberculosis Classification of Chest

Radiographs by Using Convolutional Neural Networks," *International Journal of Engineering Technology Science and Research*, vol. 5, no. 3, pp. 310-317, 2018.



ประวัติผู้เขียน

ชื่อ-สกุล	ตะวันส่องแสง การย์กวินพงศ์
วัน เดือน ปี เกิด	16 พฤษภาคม 2536
สถานที่เกิด	ศรีสะเกษ
วุฒิการศึกษา	วิศวกรรมศาสตรบัณฑิต (วศ. บ.)
ที่อยู่ปัจจุบัน	119/248 หมู่ 1 หมู่บ้าน Perfect Place 2 ถ. รัตนวิเบศร์ ต.ไทรมา อ. เมือง จ. นนทบุรี 11000
ผลงานตีพิมพ์	<ol style="list-style-type: none">1. T. Karnkwinpong and Y. Limpiyakorn, "Classification of Pulmonary Tuberculosis Lesion with Convolutional Neural Networks", 11th International Conference on Computer and Electrical Engineering (ICCEE 2018), October 12-14, 2018, Tokyo, Japan.2. T. Karnkwinpong and Y. Limpiyakorn, "Chest X-Ray Analysis of Tuberculosis by Convolutional Neural Networks with Affine Transforms", 2nd International Conference on Computer Science and Artificial Intelligence (CSAI 2018), December 8-10, 2018, Shenzhen University, Shenzhen, China.
รางวัลที่ได้รับ	-