

การเปรียบเทียบสถาปัตยกรรมโครงข่ายประสาทคอนโวลูชัน 3 มิติ โดยการจำแนก  
โรคหลอดเลือดสมองจากภาพการฉายรังสีเอกซเรย์สมอง



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต  
สาขาวิชาสถิติ ภาควิชาสถิติ  
คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2565  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

A COMPARISON OF 3D CONVOLUTION NEURAL NETWORKS FOR BRAIN STROKE  
CLASSIFICATION WITH CT SCAN IMAGES



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Science in Statistics  
Department of Statistics  
FACULTY OF COMMERCE AND ACCOUNTANCY  
Chulalongkorn University  
Academic Year 2022  
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การเปรียบเทียบสถาปัตยกรรมโครงการขยายประสาท คอนโวลูชัน 3 มิติ โดยการจำแนกโรคหลอดเลือดสมอง จากภาพการฉายรังสีเอกซเรย์สมอง
โดย	นายชานนท์ วรโชติสีบตระกูล
สาขาวิชา	สถิติ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.อักรินทร์ ไพบูลย์พานิช

---

คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้  
เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

----- คณะบดีคณะพาณิชยศาสตร์และ  
การบัญชี  
(ศาสตราจารย์ ดร.วิเลิศ ภูริวัชร)

คณะกรรมการสอบวิทยานิพนธ์

----- ประธานกรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร.ภริพันธ์ รุจิขจร)

----- อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(ผู้ช่วยศาสตราจารย์ ดร.อักรินทร์ ไพบูลย์พานิช)

----- กรรมการ  
(อาจารย์ ดร.สาวิตรี บุญพัชรนนท์)

----- กรรมการภายนอกมหาวิทยาลัย  
(ผู้ช่วยศาสตราจารย์ ดร.สุเมธดา เกษมวิลาศ)

ชานนท์ วรโชติสีบตระกูล : การเปรียบเทียบสถาปัตยกรรมโครงข่ายประสาทคอนโวลูชัน 3 มิติ  
 โดยการจำแนกโรคหลอดเลือดสมองจากภาพการฉายรังสีเอกซเรย์สมอง. ( A COMPARISON OF  
 3D CONVOLUTION NEURAL NETWORKS FOR BRAIN STROKE CLASSIFICATION WITH CT  
 SCAN IMAGES) อ.ที่ปรึกษาหลัก : ผศ. ดร.อักรินทร์ ไพบูลย์พานิช

แบบจำลองโครงข่ายคอนโวลูชัน หรือ ซีเอ็นเอ็น (Convolutional Neural Networks หรือ CNN) ได้รับการนำมาใช้กันอย่างแพร่หลายในการจำแนกภาพ โดยเฉพาะในทางการแพทย์ ซึ่งปกติการจำแนกภาพทางการแพทย์นิยมใช้โครงข่ายคอนโวลูชัน 2 มิติ แต่เนื่องจากข้อมูลภาพบางประเภท เช่น ภาพการฉายรังสีเอกซเรย์สมองมีลักษณะมองภาพ 3 มิติ ให้เป็นภาพ 2 มิติ ดังนั้นในงานวิจัยนี้จึงมีแนวคิดในการใช้โครงข่ายคอนโวลูชัน 3 มิติมาใช้ในการจำแนกภาพเพื่อนำเอาจุดเด่นจากความสามารถในการดึงคุณลักษณะความสัมพันธ์ในชั้นความลึกที่เพิ่มเข้ามาซึ่งมีความแตกต่างจากรูปแบบ 2 มิติ เพื่อเพิ่มประสิทธิภาพให้แบบจำลองสามารถดึงคุณลักษณะสำคัญของภาพให้มีความหลากหลายมากขึ้น งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพโครงข่ายคอนโวลูชัน 3 มิติ ร่วมกับแบบจำลองที่ถูกฝึกมาเรียบร้อยแล้ว (pre-trained model) 4 แบบจำลอง ประกอบไปด้วย อเล็กซ์เน็ต (Alexnet) วีจีจี-16 (Vgg-16) กูเกิลเน็ต (Googlenet) และเรสเน็ต (Resnet) เพื่อจำแนกข้อมูลภาพผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยที่มีสุขภาพปกติ จากภาพฉายรังสีเอกซเรย์สมอง (CT-Scan) จากฐานข้อมูลเว็บไซต์ Kaggle ชุดข้อมูลประกอบด้วยภาพผู้ป่วยที่เป็นโรคหลอดเลือดสมอง 950 ภาพ จาก 40 คน และภาพผู้ป่วยสุขภาพปกติ 1551 ภาพ จาก 82 คน ซึ่งงานวิจัยนี้มีการปรับรายละเอียดโดยการนำจุดเด่นของแต่ละแบบจำลองมาใช้ และเพิ่มชั้นความลึกที่เป็นจุดเด่นของการค้นหาคุณลักษณะสำคัญของรูปแบบ 3 มิติ ร่วมกับการประมวลผลภาพล่วงหน้า (Image Preprocessing) และการทำการเพิ่มจำนวนข้อมูล (Data augmentation) เพื่อเพิ่มประสิทธิภาพของแบบจำลอง จากนั้นเพื่อไม่ให้เกิดการทดลองโน้มเอียงต่อแต่ละแบบจำลอง มีการนำเทคนิค K-Fold Cross validation (K=5) มาเพื่อแก้ปัญหาในงานวิจัยชิ้นนี้ ในส่วนของการวัดประสิทธิภาพผลการทดลองใช้ Confusion matrix เป็นเครื่องมือในการประเมินประสิทธิภาพของแบบจำลอง ซึ่งพบว่าสมรรถนะแบบจำลองโครงข่ายคอนโวลูชันกูเกิลเน็ต 3 มิติ ให้ผลลัพธ์ที่ดีที่สุด โดยผลการทดสอบการจำแนกภาพผู้ป่วยที่เป็นโรคหลอดเลือดสมองจากภาพฉายรังสีเอกซเรย์ให้ค่าความแม่นยำ ความเที่ยงตรง ค่าความครบถ้วน และ F1-Score ที่ 92.00% 94.01% 83.96% และ 88.70% ตามลำดับ ซึ่งงานวิจัยนี้เห็นได้ว่าการนำโครงข่ายคอนโวลูชันรูปแบบ 3 มิติ มาใช้ร่วมกับการจำแนกภาพที่นำเสนอมีความหวังที่สามารถนำไปพัฒนาต่อไปในอนาคต

สาขาวิชา สถิติ  
 ปีการศึกษา 2565

ลายมือชื่อนิสิต .....  
 ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6380073826 : MAJOR STATISTICS

KEYWORD: 3D convolutional neural networks, Brain Ct-Scan images

Chanon Worachotsueptrakun : A COMPARISON OF 3D CONVOLUTION NEURAL NETWORKS FOR BRAIN STROKE CLASSIFICATION WITH CT SCAN IMAGES . Advisor: Asst. Prof. AKARIN PHAIBULPANICH, Ph.D.

Convolutional Neural Network (CNN) has been widely applied for image classification especially in the medical industry. Normally, the image classification technique used in the industry is 2D convolution neural networks. However, some image data, including brain X-rays, required converting 3D images to 2D images. Therefore, the aims of this research will apply 3D-CNN as a classification method to apply its in-depth correlational characteristics features to differentiate the processing from 2D-CNN. This approach enhances the efficiency of the model in capturing diverse and important features of the images. This research presents 3D convolution neural networks with 4 pre-trained models: Alexnet, VGG-16, Googlenet and Resnet to classify the image data of patients who have had a stroke and patients who haven't had a stroke from CT-Scan images from the website: Kaggle. For the dataset, there were 950 images of 40 stroke patients and 1551 images of 82 normal individuals. This research has been fine-tuned by using the strengths of each model and adds a distinctive layer of depth to find key features of the 3D model, along with image preprocessing and data augmentation to increase model efficiency. This research also applied K-Fold cross validation techniques to resolve the bias in each model. Finally, the confusion matrix was used to evaluate the performance of the models. Googlenet 3D was found to produce the best results, with accuracy, precision, recall and F1-scores at 92.00%, 94.01, 83.96% and 88.70% respectively. This research shows that the use of a 3D convolution network with an image classification approach should be further developed to benefit research in the future.

Field of Study: Statistics

Student's Signature .....

Academic Year: 2022

Advisor's Signature .....

## กิตติกรรมประกาศ

ด้วยความกรุณาอย่างดียิ่งจาก ผู้ช่วยศาสตราจารย์ ดร.อัครินทร์ ไพบุลย์พานิช อาจารย์ที่ปรึกษาวิทยานิพนธ์ผู้ที่ให้ความรู้และให้คำแนะนำ คำปรึกษา ความรู้และข้อคิดเห็น รวมถึงการตรวจแก้ไขข้อบกพร่องมาโดยตลอด วิทยานิพนธ์เล่มนี้จึงมีความสมบูรณ์ยิ่งขึ้น ผู้วิจัยขอกราบขอบพระคุณด้วยความเคารพอย่างสูงไว้ ณ ที่นี้

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. ภูริพันธุ์ รุจิขจร ประธานกรรมการสอบวิทยานิพนธ์ และผู้ช่วยศาสตราจารย์ ดร. สุมณฑา เกษมวิลาศ กรรมการสอบวิทยานิพนธ์ที่กรุณาเสียสละเวลาอันมีค่าในการตรวจสอบ และให้คำแนะนำ ที่เป็นประโยชน์ในการทำวิทยานิพนธ์ในครั้งนี้ ขอขอบพระคุณคณาจารย์ภาควิชาสถิติ ทุกท่านที่ให้ความรู้อันมีคุณค่า

ขอขอบพระคุณบิดามารดา เพื่อนๆ พี่ๆ น้องๆ ขอบคุณที่คอยเป็นห่วงเป็นใยถามไถ่เสมอมา ตั้งแต่เข้ารับการศึกษาจนกระทั่งวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วง รวมถึงขอบคุณตัวเองที่ไม่ยอมแพ้ ท้อถอยและย่อท้อ กระจ่างหวังว่า วิทยานิพนธ์ฉบับนี้จะเป็นประโยชน์ต่อผู้ที่สนใจต่อไปในภายภาคหน้า

ชานนท์ วรโชติสีบตระกูล


## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....ค	ค
บทคัดย่อภาษาอังกฤษ.....ง	ง
กิตติกรรมประกาศ.....จ	จ
สารบัญ.....ฉ	ฉ
สารบัญตาราง.....ฌ	ฌ
สารบัญรูปภาพ.....ญ	ญ
บทที่ 1 บทนำ..... 1	1
1.1. ที่มาและความสำคัญของปัญหา..... 1	1
1.2. วัตถุประสงค์การวิจัย..... 4	4
1.3. ขอบเขตของการวิจัย..... 4	4
1.4. วิธีการดำเนินการวิจัย..... 4	4
1.5. ประโยชน์ที่คาดว่าจะได้รับ..... 5	5
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง..... 6	6
2.1 ทฤษฎีและกรอบแนวคิดที่เกี่ยวข้อง..... 6	6
2.1.1 โครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network)..... 6	6
2.1.2 Convolutional Neural Networks (CNN) หรือ โครงข่ายประสาทคอนโวลูชัน..... 6	6
2.1.3 โครงข่ายประสาทแบบคอนโวลูชันแบบวีจีจี 16 (VGG-16)..... 7	7
2.1.4 โครงข่ายประสาทแบบคอนโวลูชันอเล็กเน็ต (AlexNet)..... 8	8
2.1.5 โครงข่ายประสาทแบบคอนโวลูชัน GoogleNet..... 8	8
2.1.6 โครงข่ายประสาทแบบคอนโวลูชันเรสเน็ต (Residual Network หรือ ResNet)..... 9	9
2.1.7 ตารางการประเมินผลลัพธ์การทำนาย (Confusion Matrix) (20)..... 9	9

2.1.8	ตัววัดประสิทธิภาพ .....	10
2.1.9	Relu Activation Function.....	11
2.1.10	Regularization (24).....	11
2.1.11	การประมวลผลภาพล่วงหน้า (Image preprocessing) (27).....	12
2.1.12	ฟังก์ชัน Softmax.....	13
2.1.13	K-Fold Cross Validation (24).....	13
2.2	เอกสารและงานวิจัยที่เกี่ยวข้อง .....	14
บทที่ 3 แนวคิดและวิธีการวิจัย.....		22
3.1	การเตรียมชุดข้อมูล.....	23
3.2	การสร้างแบบจำลองการทำนายโรคหลอดเลือดสมอง .....	24
3.3	การเปรียบเทียบประสิทธิภาพของแบบจำลอง.....	24
3.4	การวัดประสิทธิภาพแบบจำลองจากผลการทำนาย .....	24
3.5	การเตรียมชุดข้อมูลที่ใช้ในการทดสอบแบบจำลอง.....	25
3.6	การดำเนินการสร้างแบบจำลอง.....	28
3.6.1	แบบจำลองโครงข่ายประสาทคอนโวลูชันเล็กซ์เน็ต (Alexnet) .....	29
3.6.2	แบบจำลองโครงข่ายประสาทคอนโวลูชันวีจีจี 16 (VGG-16).....	30
3.6.3	แบบจำลองโครงข่ายประสาทคอนโวลูชันกูเกิลเน็ต (Googlenet).....	32
3.6.4	แบบจำลองโครงข่ายประสาทคอนโวลูชันเรสเน็ต (Resnet) .....	33
3.6.5	K-Fold Cross Validation (K=5) .....	34
3.7	การเปรียบเทียบประสิทธิภาพ และประเมินแบบจำลองผลการทำนายโรคหลอดเลือดสมอง จากภาพการฉายรังสีเอกซเรย์.....	35
บทที่ 4 การทดลองและผลการทดลอง.....		36
4.1	สภาพแวดล้อมที่ใช้ในการทดลอง.....	36
4.1.1	การเขียนโปรแกรมและเฟรมเวิร์คที่ใช้ในการทดลอง.....	36



4.1.2 ชุดข้อมูลที่ใช้ในการทดลอง และเทคนิคการเพิ่มขนาดของชุดข้อมูล.....	36
4.2 การดำเนินการทดลอง.....	36
4.2.2 การสอนแบบจำลอง (Model Training).....	39
4.2.2 ผลการทดสอบแบบจำลอง .....	40
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	45
5.1 สรุปผลการวิจัย .....	45
5.2 ข้อเสนอแนะ .....	47
บรรณานุกรม .....	49
ประวัติผู้เขียน.....	53



## สารบัญตาราง

หน้า

ตารางที่ 1 ในการฝึกสอนและทดสอบแบบจำลอง จะแบ่งข้อมูลออกเป็น ข้อมูลสอน ข้อมูลตรวจสอบ และข้อมูลทดสอบ.....	24
ตารางที่ 2 การวัดประสิทธิภาพของแบบจำลองทั้ง 4 รูปแบบ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet.....	40
ตารางที่ 3 ประสิทธิภาพการฝึกสอนของแบบจำลองทั้ง 4 รูปแบบ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet.....	41



## สารบัญรูปภาพ

	หน้า
รูปที่ 1 ภาพการทำ CT Scan สมองของคนหนึ่งคน.....	1
รูปที่ 2 ภาพการนำโครงข่ายคอนโวลูชันประยุกต์ใช้ในการแบ่งส่วนรอยโรค (7).....	3
รูปที่ 3 โครงสร้างโครงข่ายประสาทคอนโวลูชัน (14).....	7
รูปที่ 4 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ VGG-16 (14) .....	7
รูปที่ 5 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ AlexNet (16) .....	8
รูปที่ 6 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ GoogleNet (17) .....	9
รูปที่ 7 Residual block (19).....	9
รูปที่ 8 เทคนิคการ Dropout Regularization ซ้าย : รูป neural network 2 hidden layers ขวา: รูปที่มีทำการ Dropout ข้อมูลบางส่วนออกไปจากชุดข้อมูลในขณะที่เทรนโมเดล (25).....	12
รูปที่ 9 โครงสร้าง K-Fold Cross Validation (K=5) (28).....	14
รูปที่ 10 ตัวอย่างการแบ่งส่วนรอยโรคหลอดเลือดสมองโดยการใช้ Image Preprocessing จัดการ พื้นที่ส่วนกระดูกในสมองออก (8).....	15
รูปที่ 11 ภาพตัวอย่างวิธีการ Grad-CAM (28) .....	15
รูปที่ 12 ตัวอย่างการตรวจจ็บรอยโรคหลอดเลือดสมองตีบ [30].....	16
รูปที่ 13 รูปตัวอย่างก้อนเนื้อปอดจากผล CT-Scan (31).....	17
รูปที่ 14 ตัวอย่างข้อมูลภาพผู้ป่วยปกติ, ผู้ป่วยที่เป็นโรคโควิด 19 และผู้ป่วยโรคปอดบวม (25).....	18
รูปที่ 15 ตัวอย่างการผลการทดลองแบ่งส่วนรอยโรคสมองในแต่ละแบบจำลอง (32).....	19
รูปที่ 16 ตัวอย่างผลการตรวจจ็บรอยโรคของ ภาพ MRI ของสมองในแต่ละแบบจำลอง (10).....	20
รูปที่ 17 โมเดลพิวชันการตัดสินใจตาม Deep CNN (33).....	21
รูปที่ 18 ภาพประกอบการตัดสินใจแบบพิวชัน (33).....	21
รูปที่ 19 ขั้นตอนแนวคิดและวิธีการวิจัยเพื่อเปรียบเทียบโครงข่ายประสาทคอนโวลูชัน สำหรับการ จำแนกรโรคหลอดเลือดสมอง .....	22

รูปที่ 20 ตัวอย่างชุดข้อมูลภาพการฉายรังสีเอกซเรย์ทั้ง 2 ประเภท ที่ใช้ในการฝึกฝนแบบจำลอง ....	23
รูปที่ 21 ตัวอย่างการอัปโหลดข้อมูล .....	25
รูปที่ 22 ตัวอย่างการทำการประมวลผลภาพล่วงหน้ากับชุดข้อมูล .....	26
รูปที่ 23 ตัวอย่างการประมวลผลภาพล่วงหน้าเพื่อกำหนดชั้นความลึกของข้อมูล .....	27
รูปที่ 24 ตัวอย่างการนำภาพฉายรังสีเอกซเรย์คนเป็นโรคหลอดเลือดสมอง มาประกอบกันเป็นภาพ 3 มิติ ขนาด 128x128x40.....	27
รูปที่ 25 ตัวอย่างการเพิ่มจำนวนข้อมูล (Data Augmentation) สำหรับชุดข้อมูลที่ใช้ในการทดสอบ .....	28
รูปที่ 26 รายละเอียดโครงสร้างของแบบจำลองอเล็กซ์เน็ต 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง.....	30
รูปที่ 27 รายละเอียดโครงสร้างของแบบจำลองวีจีจีแบบ 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง .....	31
รูปที่ 28 รายละเอียดโครงสร้างของแบบจำลองกูเกิลเน็ตแบบ 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง.....	32
รูปที่ 29 รายละเอียดโครงสร้างของแบบจำลองเรสเน็ตแบบ 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง.....	33
รูปที่ 30 การแบ่งข้อมูลแบบ K-Fold Cross Validation (25) .....	34
รูปที่ 31 ตัวอย่างตารางคอนฟิวชันเมทริกซ์ (Confusion Matrix) (34) .....	35
รูปที่ 32 รูปตัวอย่างภาพฉายรังสีเอกซเรย์ของคนเป็นโรคหลอดเลือดสมองต่อหนึ่งคน .....	37
รูปที่ 33 ตัวอย่างการทำ Histogram equalization .....	37
รูปที่ 34 ตัวอย่างภาพการหาค่าสูงสุดของภาพถ่ายรังสีเอกซเรย์ของแต่ละคน.....	38
รูปที่ 35 ตัวอย่างรูปภาพหลังการใช้เทคนิค Data Augmentation รูปแบบ .....	39
รูปที่ 36 ตัวอย่างรูปภาพหลังการใช้เทคนิค Data Augmentation ในรูปแบบการ Rotate.....	39
รูปที่ 37 ตัวอย่างปัญหาความไม่เสถียรของการทดสอบแบบจำลอง 3D Resnet .....	41
รูปที่ 38 กราฟแท่งแสดงการเปรียบเทียบ Precision, Recall, F1-score, และ Accuracy .....	42

รูปที่ 39 กราฟแท่งแสดงการเปรียบเทียบ TP, TN, FP, และ FN .....	42
รูปที่ 40 ตัวอย่างรูปของคนเป็นโรคหลอดเลือดสมองที่แบบจำลองทำนายผิด.....	43
รูปที่ 41 ตัวอย่างรูปของคนไม่เป็นโรคหลอดเลือดสมองที่แบบจำลองทำนายผิด.....	44



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY


# บทที่ 1

## บทนำ

### 1.1. ที่มาและความสำคัญของปัญหา

ในแต่ละปีจะมีผู้เสียชีวิตจากโรคหลอดเลือดสมองประมาณ 14 ล้านคนจากทั่วโลก และผู้รอดชีวิตกว่า 50 ล้านคนจะมีชีวิตอยู่ด้วยความทุพพลภาพถาวร จากข้อมูลขององค์การอนามัยโลก (1) โรคหลอดเลือดสมองเป็นสาเหตุการตายอันดับ 2 ของผู้ที่มีอายุมากกว่า 60 ปี และเป็นสาเหตุอันดับ 5 ในผู้ที่มีอายุระหว่าง 15-59 ปี อีกทั้งโรคหลอดเลือดสมองยังเป็นสาเหตุหลักของความทุพพลภาพในระยะยาว ส่งผลต่อการดำรงชีวิตด้วยความทุพพลภาพ 116 ล้านปีในปี (2) การเลือกวิธีการวินิจฉัยโรคนั้น ขึ้นอยู่กับแต่ละกรณี เช่น อาการของผู้ป่วย หรือเวลาที่เริ่มมีอาการ เป็นต้น ทั้งนี้ความล่าช้าใดๆ ในการรักษาพยาบาลส่งผลต่อการเพิ่มความเสียหายของผลกระทบที่รุนแรงและเสียชีวิต

ขั้นตอนในการวินิจฉัยโรคหลอดเลือดสมองสามารถทำได้หลากหลายวิธี หนึ่งในนั้นคือการทำ CT Scan ที่สามารถทำงานได้ซับซ้อนกว่าการเอกซเรย์แบบธรรมดา จะมีการแสดงภาพเป็น 3 มิติ และซอຍภาพออกเป็นแผ่นบางๆ ในภาพลักษณะตัดขวางได้หลายสิบแผ่น ช่วยให้แพทย์วิเคราะห์ความผิดปกติของอวัยวะนั้นๆ ได้อย่างละเอียด




รูปที่ 1 ภาพการทำ CT Scan สมองของคนหนึ่งคน

สำหรับการจำแนกโรคของผู้ป่วยที่เป็นโรคหลอดเลือดสมองมีการนำเทคนิคการประมวลผลด้วยภาพมาช่วยในการวินิจฉัยโรคของผู้ป่วย หนึ่งในเทคนิคที่นิยมใช้กันคือใช้โครงข่ายคอนโวลูชัน (Convolutional Neural Networks) ซึ่งเป็นเทคนิคที่นิยมใช้สำหรับการจำแนกภาพทางการแพทย์ (3) โดยมีการคิดค้นครั้งแรกในปี 1980 โดย Yann LeCun (4) การทำงานของโครงข่ายคอนโวลูชันมีด้วยกัน 3 รูปแบบ คือ 1 มิติ, 2 มิติ และ 3 มิติ โดยรูปแบบนำมาใช้ในการจำแนกภาพทั่วไปคือรูปแบบ 2 มิติ ในส่วนของรูปแบบ 3 มิติ จะใช้ในส่วนของการจำแนกภาพเคลื่อนไหว, ภาพถ่ายวิดีโอ, รูปภาพที่มีรูปแบบ 3 มิติ และอื่น ๆ

แบบจำลองด้วยโครงข่ายประสาทคอนโวลูชันรูปแบบ 3 มิติ (5) มีความสามารถในการคัดเลือกคุณลักษณะของข้อมูลได้อย่างมีประสิทธิภาพ เนื่องจากรูปแบบ 3 มิติ มีการประมวลผลหรือหน่วยความจำที่สูงมาก รวมถึงมีการค้นหาความสัมพันธ์แบบ 3 มิติ คือ ความสูง ความกว้าง และความลึก ซึ่งมีประสิทธิภาพในการทำนายที่ดีกว่า รูปแบบ 2 มิติ ที่แยกรูปแบบเพียง 2 มิติ เท่านั้นคือ ความสูง และความกว้าง ตัวอย่างเช่น การสแกนแบบ 2 มิติ สามารถแยกความแตกต่างระหว่าง วงกลม และทรงกลมได้ แต่หากเป็นการสแกนแบบ 3 มิติจะสามารถจำแนกวัตถุที่เป็นทั้งวงกลม ทรงกลม และทรงกระบอกได้

ในงานวิจัยที่เกี่ยวกับโครงข่ายประสาทคอนโวลูชันที่นำมาใช้เพื่อจำแนกโรคทางการแพทย์ Bhanumathi (6) มีการนำแบบจำลองโครงข่ายคอนโวลูชันที่ถูกฝึกมาเรียบร้อยแล้ว (Pre-trained Model) อาทิเช่น อเล็กซ์เน็ต , วีจีจี-16 และกูเกิลเน็ต มาใช้ในการจำแนกคนเป็นโรคเนื้องอกในสมองจากผลสแกน MRI ซึ่งได้ผลลัพธ์ของแบบจำลองที่มีประสิทธิภาพ อย่างไรก็ตาม การนำเทคนิคโครงข่ายคอนโวลูชันแบบ 3 มิติ มาใช้ในการจำแนกโรคเกี่ยวกับภาพสมองยังมีจำนวนที่น้อย โดยงานวิจัยที่เกี่ยวกับสมองจำนวนมากจะนิยมใช้การแบ่งส่วนภาพ หรือการแบ่งส่วนรอยโรคเข้ามาเพื่อช่วยในการประกอบการตัดสินใจ (7) โดยใช้ในการแยกเนื้อเยื่อสมองส่วนที่เสียหาย และมีสุขภาพปกติ หลังจากนั้นจะนำมาตัดสินใจเลือก และรักษาต่อไป ซึ่งวิธีนี้สามารถช่วยในการคาดการณ์พื้นที่และช่วยแพทย์ในการลดจำนวนเวลาการวินิจฉัยโรคจากผู้ป่วยที่มีจำนวนมาก ซึ่งสามารถช่วยในการประกอบการตัดสินใจในการเลือกดูแลผู้ป่วยฉุกเฉินก่อนเป็นอันดับแรก (8)



รูปที่ 2 ภาพการนำโครงข่ายคอนโวลูชันประยุกต์ใช้ในการแบ่งส่วนรอยโรค (7)

ในงานวิจัยนี้ต้องการที่จะลดขั้นตอนการวินิจฉัยทางการแพทย์ โดยจะใช้เทคนิคการจำแนกภาพที่ต่างจากเทคนิคการแบ่งส่วนภาพ โดยการจำแนกภาพสามารถแสดงผลลัพธ์ของการทดลองได้ โดยที่ไม่ต้องมีการนำมาประกอบการเลือกตัดสินใจรักษาหลังการทดลองต่างจากเทคนิคการแบ่งส่วนรอยโรค (9) โดยงานวิจัยจำนวนมากที่เกี่ยวกับสมองจะมีการใช้เทคนิคการแบ่งส่วนรอยโรค หรือ การคาดการณ์พื้นที่เป็นส่วนใหญ่ ซึ่งงานวิจัยชิ้นนี้ต่างออกไป และต้องการให้ลดขั้นตอนในการวินิจฉัยโรค และได้ผลลัพธ์ที่มีประสิทธิภาพดีกว่า ผู้วิจัยมีความสนใจที่จะศึกษาการจำแนกภาพ โดยการนำชุดข้อมูลของผู้ป่วยที่เป็นโรคหลอดเลือดสมองจากภาพการฉายรังสีเอกซเรย์ (CT Scan) โดยเทคนิคการสร้างแบบจำลองโครงข่ายประสาทคอนโวลูชันรูปแบบ 3 มิติ โดยประยุกต์ใช้กับแบบจำลองที่เป็นที่นิยมในการนำมาใช้จำแนกภาพทางการแพทย์ (10, 11) ประกอบด้วย อเล็กซ์เน็ต (Alexnet), วีจีจี-16 (VGG-16), กูเกิลเน็ต (Googlenet) และเรสเน็ต (Resnet) โดยจะมีการใช้เทคนิคการประมวลผลภาพล่วงหน้า เพื่อช่วยในการเพิ่มประสิทธิภาพของการทำโครงข่ายคอนโวลูชัน 3 มิติ ซึ่งงานวิจัยชิ้นนี้ มีการนำเทคนิค K-Fold Cross Validation เข้ามาใช้เพื่อแก้ปัญหาคอคติ (Bias) ในแต่ละแบบจำลอง โดยจะมีการใช้ Confusion Matrix เป็นเครื่องมือสำคัญในการประเมิน ผลลัพธ์ของการทำนายจากแบบจำลองที่สร้างขึ้น เพื่อนำผลจากการประเมินมาวิเคราะห์การเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลองเพื่อให้ได้แบบจำลองที่เหมาะสมกับชุดข้อมูลภาพการฉายรังสีเอกซเรย์ของคนเป็นโรคหลอดเลือดสมองมากที่สุด



## 1.2 วัตถุประสงค์การวิจัย

เพื่อเปรียบเทียบประสิทธิภาพในการทำนายของแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติ โดยนำผลลัพธ์ที่ได้จากการใช้แบบจำลองการเรียนรู้โครงข่ายคอนโวลูชัน 4 แบบ ได้แก่ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet โดยการเปรียบเทียบผ่านตัวชี้วัด ได้แก่ ตารางการประเมินผลลัพธ์การทำนาย (Confusion Matrix), ความแม่นยำ (accuracy), ความเที่ยงตรง (Precision), ความครบถ้วน (Recall) และค่า F1-Score

## 1.3 ขอบเขตของการวิจัย

1. แหล่งที่มาของข้อมูลภาพการฉายรังสีสมองของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยสุขภาพปกติ จากฐานข้อมูลเว็บไซต์ Kaggle ชุดข้อมูล : <https://www.kaggle.com/afridirahman/brain-stroke-ct-image-dataset> สำหรับชุดข้อมูลประกอบด้วยภาพผู้ป่วยที่เป็นโรคหลอดเลือดสมอง 950 ภาพ (40 คน) และผู้ป่วยสุขภาพปกติ 1551 ภาพ (82 คน) โดยมีขนาดของภาพที่ 650 x 650

2. Pre-trained models ประกอบด้วย อเล็กซ์เน็ต, วีจีจี-16, กูเกิลเน็ต และเรสเน็ต

3. การเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยค่า Confusion Matrix, accuracy, Recall, Precision และ F1-Score

## 1.4 วิธีการดำเนินการวิจัย

1. ศึกษาและทำความเข้าใจทฤษฎีและงานวิจัยที่เกี่ยวข้อง
2. ศึกษาเครื่องมือสำหรับการสร้างแบบจำลองการเรียนรู้โครงข่ายคอนโวลูชัน 3 มิติ
3. รวบรวมภาพการฉายรังสีของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยที่สุขภาพปกติ
4. สร้างแบบจำลอง ทดสอบ และปรับแต่งเพิ่มความแม่นยำ
5. วิเคราะห์และประเมินผลการวิจัย
6. สรุปผลการวิจัยและข้อเสนอแนะ
7. ตีพิมพ์ผลงานทางวิชาการ
8. จัดทำวิทยานิพนธ์

### 1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถเปรียบเทียบประสิทธิภาพของโครงข่ายคอนโวลูชันต่างๆที่ประยุกต์เข้ากับโครงข่ายคอนโวลูชัน 3 มิติ เพื่อให้แบบจำลองสามารถทำนายผู้ป่วยที่เป็นโรคหลอดเลือดสมองและผู้ป่วยสุขภาพปกติได้
2. ได้แบบจำลองทำนายผู้ป่วยเป็นโรคหลอดเลือดในสมองจากภาพการฉายรังสี ซึ่งสามารถตรวจวินิจฉัยโรคหลอดเลือดในสมองได้อย่างอัตโนมัติ



## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### 2.1 ทฤษฎีและกรอบแนวคิดที่เกี่ยวข้อง

##### 2.1.1 โครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network)

ความรู้ด้านโครงข่ายประสาทเทียม (12) ได้รับการวิจัยและพัฒนาจนเกิดเป็นเทคนิคการเรียนรู้เชิงลึกขึ้น โดยการใช้โครงข่ายประสาทเทียมมีชั้นซ่อน (Hidden Layer) จำนวนหลายชั้น เพื่อเรียนรู้ และสร้างตัวแทนข้อมูลขึ้นมา จากเดิมที่ต้องผ่านกระบวนการสกัดคุณลักษณะของข้อมูล (Feature Extraction) โดยมนุษย์ สำหรับการเรียนรู้เชิงลึก ตัวแทนข้อมูลจะเกิดจากการเรียนรู้ภายในโครงข่ายประสาทเทียม สำหรับงานวิจัยนี้เป็นการจำแนกโรคหลอดเลือดสมอง โดยโครงข่ายจะถูกออกแบบให้เรียนรู้ตัวแทนข้อมูลตามลำดับ

##### 2.1.2 Convolutional Neural Networks (CNN) หรือ โครงข่ายประสาทคอนโวลูชัน

Convolutional Neural Networks (13) เป็นการใช้ประโยชน์จากความสัมพันธ์เชิงพื้นที่ โดยบังคับใช้รูปแบบการเชื่อมต่อภายในระหว่างเซลล์ประสาทของเลเยอร์ที่อยู่ติดกัน โดยวิธีการทำงานของ CNN ที่ใช้ในการจัดประเภทรูปภาพจะดำเนินการค้นหาคุณลักษณะของรูปภาพ เช่น ขอบและส่วนโค้งต่างๆ และจากนั้นจะสร้างภาพที่เป็นนามธรรมมากขึ้นผ่านชุดเลเยอร์ที่บิดเบี้ยว CNN ทั่วไปประกอบด้วยเลเยอร์ที่แตกต่างกันอย่างน้อย 4 ชั้น ได้แก่ Convolutional layer, Pooling/Subsampling layer, Fully connected layer และ Output layer

##### Convolutional Layer


เป็นชั้นที่ทำการหาคุณลักษณะจากกลุ่มของข้อมูลอินพุตที่อยู่ใกล้ๆ กันโดยใช้วิธีการคูณเมทริกซ์ (Dot matrix) กับตัวกรอง (Filter) หรือบางครั้งเรียกว่า เคอร์เนล (Kernel) โดยที่น้ำหนักของตัวกรองจะใช้ร่วมกันในทุก ๆ การทำคอนโวลูชันของข้อมูลอินพุต โดยเมื่อคูณเสร็จจะได้ผลลัพธ์ขั้นเอาต์พุตเกิดขึ้นใหม่ ซึ่งจำนวนของเอาต์พุตที่เกิดขึ้นจะขึ้นกับจำนวนของตัวกรอง

##### Pooling/Subsampling layer

เป็นชั้นที่เป็นการรวมการกระตุ้นของเซลล์ประสาทที่ชั้นหนึ่งเป็นเซลล์ประสาทเดียวในชั้นถัดไป เปรียบเสมือนขั้นการรวมทำหน้าที่ลดขนาดของข้อมูล (Dimensionality Reduction) เพื่อให้เหลือเพียงข้อมูลที่สำคัญเท่านั้น สามารถใช้วิธีการรวมสองวิธีที่ ได้แก่ 1.Max pooling และ 2.Average pooling โดยที่ Max pooling จะใช้ค่าสูงสุดจากแต่ละคลัสเตอร์ของเซลล์ประสาทที่เลเยอร์ก่อนหน้า แต่ Average pooling จะเฉลี่ยค่าจากแต่ละกลุ่มของเซลล์ประสาทที่เลเยอร์ก่อนหน้า

### Fully connected layer and Output layer


Fully connected layer เซลล์ประสาททุกเซลล์เชื่อมต่อกับเซลล์ประสาททั้งหมดในชั้นอื่นๆ และสุดท้ายเซลล์ประสาทของ Output layer จะทำหน้าที่ในการทำนายแบบจำลอง ดังรูปที่ 3



รูปที่ 3 โครงสร้างโครงข่ายประสาทคอนโวลูชัน (14)

### 2.1.3 โครงข่ายประสาทแบบคอนโวลูชันแบบวีจีจี 16 (VGG-16)


โครงสร้างแบบ VGG-16 (15) เป็นสถาปัตยกรรมของ Convolution Neural Network (CNN) ชนะการแข่งขัน ILSVR (ImageNet) ในปี 2014 ถือได้ว่าเป็นหนึ่งในสถาปัตยกรรมที่มีสมรรถภาพของแบบจำลองในการจำแนกประเภทที่นิยมจนถึงปัจจุบัน โดยจุดเด่นของ VGG-16 คือการแทนที่ hyperparameter จำนวนมาก เน้นที่การออกแบบ เลเยอร์ conv2D 3x3 pixels, 1 stride และการใช้ same padding และ max pooling 2x2 pixels, 2 stride แบบเดียวกันตลอดทั้งโครงสร้าง ดังนั้นกล่าวโดยสรุปคือ VGG-16 จะมีขนาดเคอร์เนลสม่ำเสมอทั่วทั้งเลเยอร์



รูปที่ 4 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ VGG-16 (14)

### 2.1.4 โครงข่ายประสาทแบบคอนโวลูชันเล็กเน็ต (AlexNet)


โครงสร้าง AlexNet (16) ประกอบไปด้วยชั้นคอนโวลูชันจำนวน 5 ชั้น และชั้นเชื่อมต่อแบบสมบูรณ์ (Fully connected layer) จำนวน 3 ชั้น โดยผลลัพธ์ของชั้นเชื่อมต่อแบบสมบูรณ์ ถูกกำหนดให้มีจำนวน 100 โหนด และในชั้นสุดท้ายของชั้นเชื่อมต่อแบบสมบูรณ์ ใช้วิธี Softmax เพื่อคำนวณหาผลลัพธ์ โดยจะมีลักษณะดังรูปที่ 5



รูปที่ 5 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ AlexNet (16)

### 2.1.5 โครงข่ายประสาทแบบคอนโวลูชัน GoogleNet


โครงสร้างแบบ GoogleNet (17) มีโครงสร้างในลักษณะ Inception เพื่อให้ CNN มีความลึกและความกว้าง โดยไม่ส่งผลให้การประมวลผลช้าลง ในแต่ละ Inception จะประกอบไปด้วยการคำนวณคอนโวลูชันโดยใช้เคอร์เนล ขนาด 1x1, 3x3 และ 5x5 เป็นการประมวลผลแบบขนาน ซึ่งส่งผลให้มิติของข้อมูลลดลง (Dimension Reduction) โดยโครงสร้างจะประกอบไปด้วย Inception 9 ชั้น จากจำนวนทั้งสิ้น 22 ชั้น และใช้ฟังก์ชัน ReLu เพื่อเป็นฟังก์ชันกระตุ้น และชั้นเชื่อมต่อแบบสมบูรณ์กำหนดให้มีจำนวน 1024 โหนด ก่อนจะส่งต่อไปยังชั้นแสดงผล ดังแสดงในรูปที่ 6



รูปที่ 6 โครงสร้างโครงข่ายประสาทคอนโวลูชันแบบ GoogleNet (17)

### 2.1.6 โครงข่ายประสาทแบบคอนโวลูชันเรสเน็ต (Residual Network หรือ ResNet)

ResNet หรือ Deep Residual Network (18) เป็นสถาปัตยกรรมของ Convolution Neural Network (CNN) ชนะการแข่งขัน ILSVR (ImageNet) ในปี 2015 เป็นโครงข่ายที่มีความลึกค่อนข้างมาก ด้วยการใส่เทคนิคทางลัด (Skip หรือ Shortcut connections) ดังรูปประกอบที่ 7 ซึ่งเสมือนทำให้ Layers มีความลึกขึ้น เพื่อแก้ปัญหาเรื่อง Vanishing gradient



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY  
รูปที่ 7 Residual block (19)

งานวิจัยนี้ใช้โครงข่ายประสาทเทียมที่เรียกว่า ResNet-50 คือแบบจำลองที่มีชั้นของ Layer 50 ชั้น ซึ่งสถาปัตยกรรมประกอบด้วย 4 Block โดยในแต่ละ Block จะมี Convolutional Layer ประกอบด้วย 3, 4, 6 และ 3 ตามลำดับ  $((3+4+6+3) \times 3 = 48$  ชั้น) และรวม Convolutional Layer ชั้นที่ติดกับข้อมูลที่นำเข้า และชั้นข้อมูลที่ทำนายออกจะได้ผลรวมเป็น 50 ชั้น

### 2.1.7 ตารางการประเมินผลลัพธ์การทำนาย (Confusion Matrix) (20)

ตารางแสดงความสัมพันธ์ระหว่างค่าพยากรณ์ และค่าจริง เป็นการเปรียบเทียบระหว่างค่าพยากรณ์กับค่าจริงโดยแบ่งออกเป็น 4 กลุ่ม ได้แก่ True-positive ( TP ), True-negative ( TN), False-positive ( FP ) และ False-negative ( FN ) เพื่อประเมินประสิทธิภาพของโมเดล

- True positive (TP) คือ จำนวนเหตุการณ์ที่สนใจมีผลเป็นบวก และมีผลจากการพยากรณ์เป็นบวก

- False positive (FP) คือ จำนวนเหตุการณ์ที่สนใจมีผลเป็นลบ แต่มีผลจากการพยากรณ์เป็นบวก

- False negative (FN) คือ จำนวนเหตุการณ์ที่สนใจมีผลเป็นบวก และมีผลจากการพยากรณ์เป็นลบ

- True negative (TN) คือ จำนวนเหตุการณ์ที่สนใจมีผลเป็นลบ และมีผลจากการพยากรณ์เป็นลบ

		ค่าสังเกต	
		Positive	Negative
ค่าพยากรณ์	Positive	True positive (TP)	False positive (FP)
	Negative	False negative (FN)	True negative (TN)

### 2.1.8 ตัววัดประสิทธิภาพ

Zhang H (21) และ Jungyoon Kim (22) มีการนำค่าความแม่นยำ (Accuracy), ค่าความครบถ้วน (Recall), ค่าความถูกต้อง (Precision) มาใช้ในงานวิจัยเพื่อประเมินประสิทธิภาพ ดังนั้นงานวิจัยนี้เป็นการศึกษาตัวแบบการจำแนกข้อมูลจากภาพการฉายรังสีเอกซเรย์ โดยใช้เทคนิคการเรียนรู้เชิงลึก การวัดประสิทธิภาพตัวแบบจะใช้ตัววัดประสิทธิภาพ ดังนี้

ค่าความแม่นยำ (Accuracy) คือ การวัดความถูกต้องของการพยากรณ์โดยพิจารณาทุกกลุ่ม

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

ค่าความครบถ้วน (Recall) คือ การวัดความถูกต้องของการพยากรณ์โดยพิจารณาแยกทีละกลุ่ม

$$Recall = \frac{TP}{TP+FN}$$

ค่าความถูกต้อง (Precision) คือ การวัดความแม่นยำของข้อมูลโดยพิจารณาแยกทีละกลุ่ม

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

F1-Score คือค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall เป็น single metric ที่วัดความสามารถของโมเดล

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall}$$

### 2.1.9 Relu Activation Function

มีการใช้ Relu Function ในงานวิจัยต่างๆมากมาย (23) เนื่องจากเป็นฟังก์ชันเป็นที่นิยมในการทำโมเดล Deep Learning ReLu ทำงานได้ดีกว่าฟังก์ชันอื่นๆ ในสถานการณ์ส่วนใหญ่ (23) เป็นฟังก์ชันเส้นตรงที่ถูกปรับแก้ Rectified ไม่ได้เป็นรูปตัว S โดยถ้า Input เป็นบวก Slope จะเท่ากับ 1 ตลอดกาล ทำให้ Gradient ไม่หาย ทำให้ไม่เกิด Vanishing Gradient ส่งผลให้เราสามารถเทรนโมเดลได้เร็วมากขึ้น

$$Relu f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$$

โดยที่ขอบเขตความสามารถในการแปลงอินพุตได้ดังนี้

$$f(x) = \max(0, x)$$


### 2.1.10 Regularization (24)

เกิดจาก เมื่อโมเดลถูกเทรนแล้วพิตกับข้อมูลชุด Train set ได้ดี แต่เมื่อนำไปพยากรณ์ไม่แม่นยำเมื่อนำไปใช้กับ Test set โดย Regularization เป็นเทคนิคที่ใช้เพื่อลดปัญหา Variance ของโมเดล โดยการจำกัดความสำคัญของ Feature ให้มีผลต่อการเกิดผลลัพธ์ (output) น้อยลง โดยการไม่ตัด Feature นั้นๆทิ้ง โดยวิธีการแก้ปัญหานั้นมีหลากหลายวิธี ดังนี้

#### Dropout Regularization (25)

โครงข่ายประสาทลึกที่มีพารามิเตอร์จำนวนมาก จะส่งผลต่อระบบการเรียนรู้ของเครื่องที่ทรงพลังมาก อย่างไรก็ตาม ปัญหา Overfitting นับว่าเป็นปัญหาร้ายแรง รวมไปถึงปัญหาการใช้งานที่ล่าช้าในเครือข่ายดังกล่าวซึ่งทำให้ยากต่อการจัดการกับปัญหา Overfitting ดังนั้น Dropout เป็นเทคนิคในการแก้ไขปัญหานี้ โดยมีรูปแบบที่เรียบง่ายคือ การสุ่มเอาข้อมูลบางส่วนออกไปพร้อมกับการเชื่อมต่อประสาทเทียม ระหว่างกำลังเทรนโมเดล การทำแบบนี้เพื่อไม่ให้ข้อมูลปรับตัวร่วมกันมากเกินไป





รูปที่ 8 เทคนิคการ Dropout Regularization ซ้าย : รูป neural network 2 hidden layers

ขวา: รูปที่มีทำการ Dropout ข้อมูลบางส่วนออกไปจากชุดข้อมูลในขณะที่เทรนโมเดล (25)

### Data Augmentation

วิธีการเสริมข้อมูล หรือ Data Augmentation (26) คือการเพิ่มตัวอย่างของข้อมูลภาพ กล่าวคือการทำเหมือนช่วยให้รูปภาพมีความหลายหลายมากยิ่งขึ้น ทั้งจากการหมุนรูปภาพ (rotations), การซูมเข้าและรูปภาพ, การเปลี่ยนสีของภาพ และอื่นๆ เพื่อใช้จัดการกับชุดข้อมูลที่มีปัญหาเรื่องของจำนวนที่น้อยเกินไป ซึ่งวิธีนี้จะช่วยลดปัญหา Overfitting ที่ช่วยในการปรับปรุงประสิทธิภาพของโมเดลให้ดีขึ้น

### Batch Normalization

Batch Normalization (26) เป็นเทคนิคที่ใช้ระหว่างการฝึกโมเดล เพื่อปรับค่าข้อมูลให้มีขนาดเหมาะสม ไม่เล็ก ไม่ใหญ่เกินไป เมื่อเทียบจากค่าเฉลี่ย (Mean) และค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) ของทุก Activation ใน Layer ของทั้ง Batch นั้น Batch Normalization เป็นวิธีการ Regularization แบบหนึ่งที่มีประสิทธิภาพสูง โดยเทคนิคนี้จะช่วยให้ข้อมูลมีการกระจายตัวเหมือนกัน ไม่มีตัวหนึ่งตัวใดมีอิทธิพลมากกว่ากัน ทั้งยังเป็นการเพิ่มความเร็วในการฝึกโมเดล และผลลัพธ์ที่ดีขึ้นโดยรวม

#### 2.1.11 การประมวลผลภาพล่วงหน้า (Image preprocessing) (27)

คือ การนำภาพมาประมวลผลหรือคิดคำนวณด้วยคอมพิวเตอร์ เพื่อให้ได้ข้อมูลที่เราต้องการ ทั้งในเชิงคุณภาพและปริมาณ โดยเป็นวิธีที่ทำเพื่อขจัดความผิดปกติของรูปภาพบางอย่าง เพื่อให้การจำแนกประเภทมีความแม่นยำมากขึ้น มีการปรับรูปภาพเพื่อให้มองเห็นพื้นที่ที่ต้องการได้ดียิ่งขึ้น

รวมไปถึงการปรับค่าสูงสุดและต่ำสุดของพิกเซลภาพเพื่อควบคุมขีดของภาพ โดยวิธีการประมวลผลล่วงหน้าแบ่งออกได้หลากหลายวิธีดังนี้

1. Image acquisition คือ การนำภาพเข้าระบบโดยอาจจะมีการประมวลผลก่อน (preprocessing)
2. Image enhancement คือ การปรับปรุงภาพให้ดีขึ้น โดยทำให้รายละเอียดของภาพมีความชัดเจนขึ้น และทำให้คุณลักษณะที่สำคัญเด่นชัดขึ้น
3. Image-restoration คือ การทำให้ภาพที่มีความเสื่อมโทรมกลับคืนสู่สภาพเดิม หรือได้รับการปรับปรุงใหม่
4. Color image processing คือ การประมวลผลภาพสีโดยการใช้รูปแบบของสี ในการแยกคุณลักษณะที่สำคัญของภาพด้วยสีของภาพที่เราสนใจ
5. Image Compression คือการบีบอัดข้อมูลภาพเพื่อให้ภาพมีขนาดที่เล็กลง
6. Morphological image processing คือ การประมวลผลด้านโครงสร้าง ซึ่งจะเกี่ยวข้องกับการแยกส่วนประกอบของภาพเพื่อใช้ในการแสดงรูปร่าง
7. Segmentation คือ การแบ่งส่วนต่างของภาพเพื่อหาจุดสำคัญของภาพ
8. Recognition คือ การรู้จำรูปแบบ เช่น การจดจำใบหน้า หรือลายนิ้วมือ


#### 2.1.12 ฟังก์ชัน Softmax

ฟังก์ชัน Softmax หรือฟังก์ชันเลขชี้กำลัง เป็นลักษณะทั่วไปของฟังก์ชันโลจิสติก (logistic function) มักจะใช้ในเลเยอร์สุดท้ายของโครงข่ายประสาทเทียมในปัญหาการจำแนกประเภท โดยฟังก์ชัน Softmax ถูกใช้เป็นอินพุตเวกเตอร์  $Z$  ของ  $K$  จำนวนจริง และทำให้เป็นค่าตัวเลขในรูปแบบการแจกแจงความน่าจะเป็น โดยสมการฟังก์ชัน Softmax ถูกกำหนดโดยสมการดังนี้

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad \text{for } i = 1, \dots, K \text{ และ } Z = (z_1, \dots, z_K) \in R^K$$

#### 2.1.13 K-Fold Cross Validation (24)

K-Fold Cross Validation เป็นเทคนิคที่ใช้กันอย่างแพร่หลายในการวัดประสิทธิภาพ และเพื่อลดความอคติ (Bias) ของข้อมูล สำหรับแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) โดยทั่วไปแล้วจำนวน  $K$  ที่มากขึ้นแสดงถึงความอคติที่ลดลงของแบบจำลองการเรียนรู้ของเครื่องด้วยชุดข้อมูลจะถูกแบ่งออกเป็น  $K$  ส่วน โดยในแต่ละส่วนจะถูกนำมาสุ่มเพื่อที่จะให้ชุดข้อมูลกระจายอย่างละเท่า ๆ กัน คือ ชุดข้อมูลสำหรับการทดสอบ 1 ส่วน และชุดข้อมูลสำหรับการฝึกสอนจำนวน  $K-1$  ส่วน จากนั้นชุดข้อมูลจะถูกนำไปฝึกสอน และทดสอบในแบบจำลองเป็นจำนวน  $K$  รอบ ดังแสดงในรูปที่ 9




รูปที่ 9 โครงสร้าง K-Fold Cross Validation (K=5) (28)

## 2.2 เอกสารและงานวิจัยที่เกี่ยวข้อง

จากการศึกษาค้นคว้างานวิจัยที่เกี่ยวข้องกับการจำแนกประเภทโดยใช้การเรียนรู้เชิงลึกด้วยโครงข่ายประสาทคอนโวลูชันในหัวข้อต่างๆ พบว่า มีการใช้เทคนิคในการสร้างแบบจำลองที่หลากหลาย การปรับค่าพารามิเตอร์ของแบบจำลองที่แตกต่างกัน และการใช้ตัวชี้วัดประสิทธิภาพของแบบจำลอง


### 2.2.1 งานวิจัยที่เกี่ยวข้องกับการนำโครงข่ายคอนโวลูชันประยุกต์กับข้อมูลทางการแพทย์

A.V. Dobshik (8) นำเสนอการใช้โครงข่ายคอนโวลูชัน 3 มิติ ประยุกต์ร่วมกับแบบจำลองยูเน็ต (U-net) เพื่อการแบ่งส่วนรอยโรคหลอดเลือดสมอง จากภาพฉายรังสีเอกซเรย์ (CT-Scan) จำนวน 81 คน โดยใช้เทคนิค Image Preprocessing เพื่อช่วยเพิ่มประสิทธิภาพในการแบ่งส่วนของแบบจำลอง โดยทำการตัดพื้นที่ส่วนกระดูกออก ซึ่งทำให้แบบจำลองเรียนรู้ชุดข้อมูลในส่วนของเนื้อสมองเพียงอย่างเดียว และมีการวัดประสิทธิภาพของแบบจำลองโดยใช้เทคนิค K-fold Cross validation โดยผลลัพธ์ของแบบจำลองได้ค่า sensitivity ที่  $0.699 \pm 0.039$ , specificity ที่  $0.9965 \pm 0.0016$  และ precision ที่  $0.619 \pm 0.036$  โดยการใช้เทคนิค Image Preprocessing ในงานวิจัยนี้ช่วยเพิ่มประสิทธิภาพในการแบ่งส่วนรอยโรคของแบบจำลองได้ดียิ่งขึ้น



รูปที่ 10 ตัวอย่างการแบ่งส่วนรอยโรคหลอดเลือดสมองโดยการใช้ Image Preprocessing จัดการพื้นที่ส่วนกระดูกในสมองออก (8)


AMV Dadário (29) เสนอโครงข่ายประสาทคอนโวลูชัน 3 มิติ โดยใช้ ResNet-50 เป็นแกนหลัก ในการจำแนก 3 คลาส ได้แก่ ผู้ป่วยที่เป็นโรคโควิด-19, ผู้ป่วยที่เป็นโรคปอดบวม และผู้ป่วยปกติ มีจัดการกับชุดข้อมูลโดยใช้เทคนิคการประมวลผลภาพล่วงหน้า (Image Preprocessing) และแยกบริเวณพื้นที่ที่น่าสนใจโดยการประยุกต์ใช้แบบจำลอง U-Net อีกทั้งมีการนำเทคนิค Grad-CAM หรือ Gradient-weighted Class Activation Map เป็นเทคนิคในการ Visualization ของการเรียนรู้เชิงลึก ประเภท CNN เพื่อตรวจสอบว่าตัวแบบจำแนกประเภทของภาพจากองค์ประกอบส่วนใดของภาพ งานวิจัยชิ้นนี้มีการประเมินประสิทธิภาพของโมเดลโดย Sensitivity, Specificity, พื้นที่ใต้เส้นโค้ง (AUC), การทดสอบ ANOVA และการทดสอบ  $\chi^2$  เพื่อเปรียบเทียบความแตกต่างระหว่างกลุ่ม



รูปที่ 11 ภาพตัวอย่างวิธีการ Grad-CAM (28)


Olli Oman (30) นำเสนอการตรวจจับรอยโรคหลอดเลือดสมองตีบ โดยใช้ชุดข้อมูลภาพการฉายรังสีเอกซเรย์ (CT-Scan Images) ของผู้ป่วย 60 รายที่สงสัยว่าเป็นโรคหลอดเลือดสมองตีบในการฝึกสอนแบบจำลองโดยเลือกใช้โครงข่ายคอนโวลูชัน 3 มิติ ในการตรวจจับรอยโรคหลอดเลือด

สมองตีบ และระบุได้ว่ามีส่วนของเนื้อสมองตาย ผลการทดลองแบบจำลอง Sensitivity ที่ 0.93, Specificity ที่ 0.82, AUC ที่ 0.93 และ Dice ที่ 0.61




รูปที่ 12 ตัวอย่างการตรวจจบบรอยโรคหลอดเลือดสมองตีบ [30]

Wangxia Zuo (31) เสนอวิธีการจำแนกผู้ที่เป็นก้อนเนื้อปอด (Lung nodule) จากฐานข้อมูล LUNA 16 โดยมีข้อมูลผู้ที่เป็นโรคก้อนเนื้อปอดจำนวน 551,065 คน โดยการใช้โครงข่ายคอนโวลูชัน 2 มิติ เปรียบเทียบกับ 3 มิติ งานวิจัยชิ้นนี้สร้างแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติ โดยการโหด weight ในแต่ละส่วนของแบบจำลอง 2 มิติ เพื่อเพิ่มประสิทธิภาพการจับหมวดหมู่ของกลุ่มตัวอย่าง โดยการประยุกต์แบบจำลอง 3 มิติ จะทำให้เกิดพารามิเตอร์จำนวนมาก งานวิจัยชิ้นนี้จึงการเพิ่มเลเยอร์ BatchNorm ให้กับแบบจำลอง 3 มิติ เพื่อให้พารามิเตอร์เป็นปกติ และการทดลองแสดงให้เห็นว่ากระบวนการนี้มีประโยชน์และช่วยเพิ่มประสิทธิภาพได้ดียิ่งขึ้น โดยการวัดประสิทธิภาพผลการทดลองมีการเปรียบเทียบแบบจำลองโครงข่ายคอนโวลูชัน 2 มิติ เทียบกับแบบจำลอง 3 มิติ โดยนำค่า accuracy, precision, Sensitivity, Specificity ในการวัดประสิทธิภาพแบบจำลอง 2 มิติ ได้ค่า 90.11%, 89.96%, 87.1%, 92.43% ตามลำดับ และแบบจำลอง 3 มิติ ได้ค่า 97.94%, 95.32%, 90.59%, 99.05% ตามลำดับ ผลลัพธ์ชี้ให้เห็นว่าการประยุกต์ใช้โครงข่ายคอนโวลูชัน 3 มิติช่วยเพิ่มประสิทธิภาพในการจำแนกประเภทของก้อนปอดได้ดียิ่งขึ้น เมื่อเทียบกับแบบจำลอง 2 มิติจากค่าตัวชี้วัด




รูปที่ 13 รูปตัวอย่างก้อนเนื้อปอดจากผล CT-Scan (31)

Narendra Kumar Mishra (25) งานวิจัยนี้ได้นำเสนอการเทคนิคการเรียนรู้เชิงลึกโดยโครงข่ายประสาทคอนโวลูชัน โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน (Tranfered learning) โดยที่เลือกใช้แบบจำลอง VGG-16 และ ResNet-50 เป็นพื้นฐานเพื่อจำแนกประเภทของภาพการฉายรังสีเอกซเรย์ (CT-Scan Images) จากผู้ที่เป็นที่โรคโควิด-19 (COVID-19), โรคปอดบวม (Pneumonia) และสุขภาพปกติ (Normal) โดยข้อมูลจำแนกเป็นภาพผู้ป่วยโรคโควิด-19 จำนวน 400 ภาพ ผู้ป่วยปกติจำนวน 400 ภาพ และผู้ป่วยโรคปอดบวมจำนวน 250 ภาพ โดยมีการนำเทคนิค Data Augmentation และ Fine-tuning มาใช้เพื่อปรับปรุง และเพิ่มประสิทธิภาพให้กับโมเดล VGG-16 และ ResNet-50 โดยมี การทดสอบประสิทธิภาพของแบบจำลองโดยการใช้เทคนิค 5-fold cross-validation โดยโมเดลที่เสนอได้ทำการแบ่งข้อมูลได้เป็น 2 กรณี คือ การจำแนกประเภทไบนารี (binary classification) (COVID เทียบกับ Normal) และการจำแนกประเภทหลายคลาส (multiclass classification) (โรคโควิด-19 เทียบกับ สุขภาพปกติ เทียบกับ โรคปอดบวม ผลสรุปได้ว่า โมเดล VGG16 และ ResNet50 มีความแม่นยำในการจำแนกประเภทไบนารีโดยเฉลี่ยมากกว่า 99% และสามารถจำแนกประเภทหลายคลาสโดยมีความแม่นยำที่ 86.74% และ 88.52% ตามลำดับ โดยงานวิจัยได้กล่าวถึงปัญหาของโมเดลเพิ่มเติมว่าเกิดจากผลกระทบของโรคโควิด-19 และโรคปอดบวมที่มีความคล้ายคลึงกัน



รูปที่ 14 ตัวอย่างข้อมูลภาพผู้ป่วยปกติ, ผู้ป่วยที่เป็นโรคโควิด 19 และผู้ป่วยโรคปอดบวม (25)


Kehan Qi (32) นำเสนอโครงข่ายประสาทคอนโวลูชัน X-Net เพื่อช่วยในการแบ่งส่วนรอยโรคของสมองจากภาพ MRI ซึ่งงานวิจัยมีการเปรียบเทียบประสิทธิภาพแบบจำลอง X-Net กับแบบจำลอง 6 แบบได้แก่ ResUNet, Deeplab v3+, 2D Dense-UNet, PSPNet, SegNetc และ U-Net โดยแบบจำลอง X-Net มีการใช้ Adam เพื่อเป็นการเพิ่มประสิทธิภาพของโมเดล และใช้เทคนิคการลดอัตราการเรียนรู้ (Learning Rate) โดยอัตโนมัติ กล่าวคืออัตราการเรียนรู้จะลดลงตามปัจจัยที่คงที่ โดยที่ใช้ตัวชี้วัดประสิทธิภาพอย่าง Dice score , Intersection over Union (IoU), Precision และ Recall เพื่อวัดประสิทธิภาพของแบบจำลอง งานวิจัยชิ้นนี้เมื่อเปรียบเทียบผลลัพธ์ของแบบจำลอง X-Net กับทั้ง 6 แบบจำลอง ได้ผลลัพธ์ว่าแบบจำลอง X-Net สามารถแบ่งรอยโรคสมองได้ดี และยังมีพารามิเตอร์ที่ฝึกได้จำนวนน้อยกว่าอย่างมีนัยสำคัญ อีกทั้งยังสามารถดึงคุณสมบัติของข้อมูลได้อย่างมีประสิทธิภาพด้วยพารามิเตอร์ (Parameters) ที่ฝึกได้น้อยลง ซึ่งแสดงให้เห็นว่าโมเดล X-Net สามารถบรรลุประสิทธิภาพที่ดีกว่าโมเดลที่มีอยู่ โดยกล่าวเพิ่มเติมว่า แบบจำลอง 2Dense UNet ก็นับว่ามีความน่าสนใจ เนื่องจากมีค่าของ Recall ที่สูงกว่า X-Net



รูปที่ 15 ตัวอย่างการผลการทดลองแบ่งส่วนรอยโรคสมองในแต่ละแบบจำลอง (32)

Liwei Tan (10) เสนอการตรวจจับเพื่อวิเคราะห์รอยโรคหลอดเลือดสมอง จากภาพคลื่นแม่เหล็กไฟฟ้า (MRI) ผ่านการเรียนรู้เชิงลึก ซึ่งมีจำนวนภาพผู้ป่วยที่เป็นโรคหลอดเลือดสมองจำนวน 5,688 ภาพ โดยการนำเทคนิคการตรวจจับวัตถุการเรียนรู้เชิงลึก (Object detection) โดยเลือกใช้เทคนิค Faster R-CNN ประยุกต์ใช้กับแบบจำลอง VGG-16 และ ResNet-101 เพื่อนำมาสกัดคุณสมบัติ (Feature) ของรูปภาพ โดยบทวิจัยนี้ทำการเปรียบเทียบแบบจำลองทั้ง 2 แบบจำลองที่มีการประยุกต์ใช้ร่วมกับ Faster R-CNN ได้แก่ Faster R-CNN VGG-16 , Faster R-CNN Resnet-101 ร่วมกับเครือข่ายการตรวจจับวัตถุการเรียนรู้เชิงลึกอีก 2 ประเภท ได้แก่ YOLOV3 และ SSD งานวิจัยนี้ได้ผลลัพธ์ว่า Faster R-CNN VGG-16, Faster R-CNN ResNet-101 และเครือข่าย YOLOV3 ได้ผลลัพธ์จากการวัดค่าความแม่นยำในการตรวจจับมีความใกล้เคียงกันที่ค่า 76.04%, 76.5% และ 74.9% ตามลำดับ ในขณะที่ SSD มีความสามารถในการเรียนรู้ที่ดีที่สุดและสามารถปรับให้เข้ากับรอยโรคต่างๆจนได้ผลลัพธ์ที่ดีที่สุดที่ค่า 89.77%

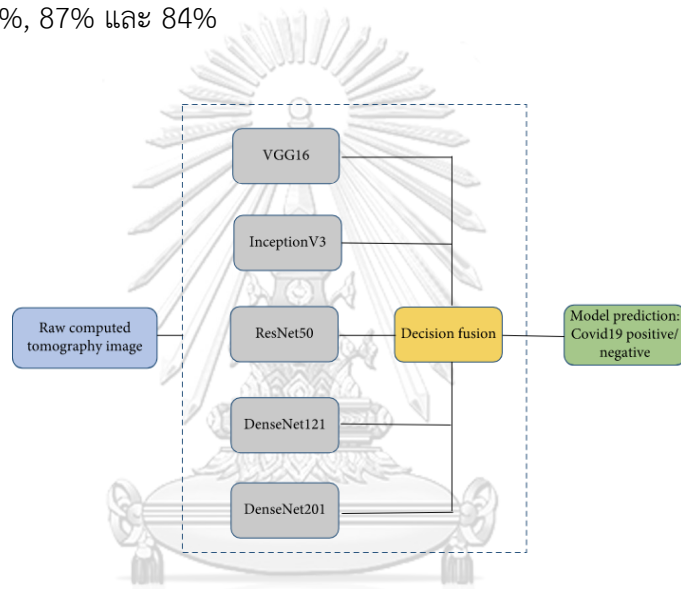




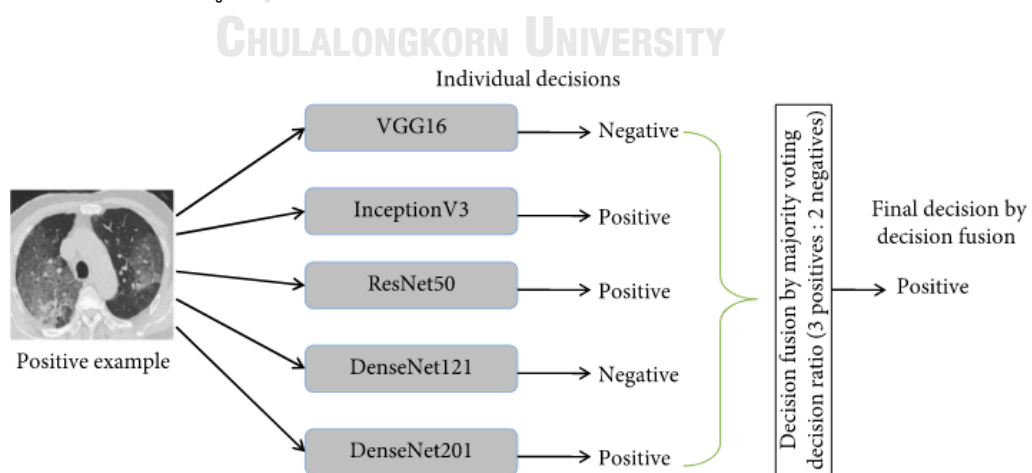
รูปที่ 16 ตัวอย่างผลการตรวจจับรอยโรคของ ภาพ MRI ของสมองในแต่ละแบบจำลอง (10)

Anjali Gautam (11) เสนอการจำแนกโรคหลอดเลือดสมองจากภาพการฉายรังสีเอกซเรย์ (CT-Scan Images) โดยการใช้โครงข่ายประสาทคอนโวลูชัน โดยมีการแบ่งข้อมูลออกเป็น 2 ชุด ชุดแรกประกอบด้วยโรคหลอดเลือดสมองตีบ (ischemic stroke) และโรคเลือดออกในสมอง (brain hemorrhagic) และชุดที่สองประกอบไปด้วย โรคหลอดเลือดสมอง, โรคเลือดออกในสมอง และภาพการฉายรังสีเอกซเรย์ของผู้ป่วยปกติ โดยงานวิจัยนี้มีข้อมูลภาพจำนวน 900 ภาพ โดยแบ่งได้เป็นจำนวน 300 ภาพในแต่ละประเภทโรค งานวิจัยมีการนำเสนอแนวทาง CNN-13 ชั้นที่ผู้วิจัยเสนอ โดยนำมาเปรียบเทียบกับแบบจำลอง AlexNet และ ResNet-50 ซึ่งมีการนำเทคนิคการรวมภาพ (image fusion) ร่วมกับการใช้เทคนิคประมวลผลภาพล่วงหน้า (Image Preprocessing) เพื่อปรับปรุงคุณภาพ และขจัดความไม่คมชัดของภาพบางอย่างจากภาพ CT-Scan การวัดประสิทธิภาพของแบบจำลองมีการใช้เทคนิค K-Fold Cross Validation (K=10) โดยผลการทดลองในงานวิจัยนี้มีเลือกใช้ตัวชี้วัดจากค่า Accuracy โดยแนวทาง CNN-13 ชั้น ที่ผู้วิจัยเสนอมีค่าเท่ากับ 98.77% ในขณะที่ AlexNet และ ResNet-50 ได้ค่าที่ 95.33% และ 98.50% ตามลำดับ ซึ่งผู้วิจัยมีการวัดประสิทธิภาพของการนำเทคนิคการประมวลผลภาพล่วงหน้ามาใช้ร่วมกับแบบจำลอง พบว่าหากไม่มีการใช้เทคนิคประมวลผลภาพล่วงหน้า ค่า Accuracy ของแบบจำลองจะลดลงอยู่ที่ 98.52%

Pinki Roy (33) เสนอการจำแนกรูปภาพของผู้ป่วยโควิด 19 จากภาพถ่ายรังสีเอกซเรย์ (CT-Scan Images) โดยใช้โครงข่ายประสาทคอนโวลูชัน 5 แบบจำลองได้แก่ VGG16, InceptionV3, ResNet-50, DenseNet-121 และ DenseNet-201 เพื่อคัดแยกผู้ป่วยที่เป็นโรคโควิด 19 และผู้ป่วยปกติผ่านภาพถ่ายรังสีทรวงอก โดยใช้ภาพ 757 ภาพ งานวิจัยมีการเสนอแนวทางการตัดสินใจแบบพิวซัน ซึ่งนำผลลัพธ์จากวิธีการต่างๆ เพื่อสร้างการทำนายขั้นสุดท้ายผ่านวิธีการลงคะแนนเสียงข้างมาก (majority voting approach) ซึ่งสามารถปรับปรุงประสิทธิภาพโดยรวมของแบบจำลองพื้นฐานได้ โดยความแม่นยำของแบบจำลองพิวซันให้ค่าความแม่นยำมากที่สุดที่ 88% ในขณะที่ VGG16, InceptionV3, ResNet-50, DenseNet-121 และ DenseNet-201 มีค่าความแม่นยำที่ 83%, 80%, 81%, 87% และ 84%



รูปที่ 17 โมเดลพิวซันการตัดสินใจตาม Deep CNN (33)

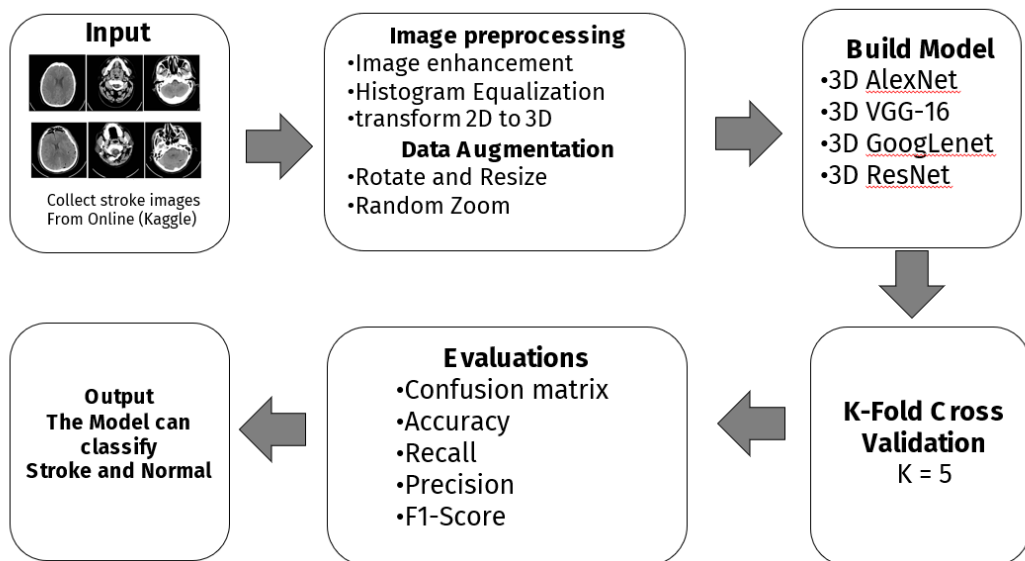


รูปที่ 18 ภาพประกอบการตัดสินใจแบบพิวซัน (33)

### บทที่ 3 แนวคิดและวิธีการวิจัย

งานวิจัยนี้นำเสนอการสร้างแบบจำลองการเรียนรู้เชิงลึกโดยโครงข่ายประสาทคอนโวลูชัน 3 มิติ ประยุกต์ร่วมกับ Pre-trained โมเดลทั้ง 4 แบบ ได้แก่ อเล็กซ์เน็ต, วีจีจี-16, กูเกิลเน็ต และเรสเน็ต เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติทั้ง 4 แบบ โดยใช้ชุดข้อมูลภาพของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยสุขภาพปกติ ลำดับวิธีการวิจัยแบ่งออกเป็น 4 ขั้นตอนหลัก ดังนี้

- 1) การเตรียมชุดข้อมูล
- 2) การสร้างแบบจำลองการทำนายโรคหลอดเลือดสมอง
- 3) การเปรียบเทียบประสิทธิภาพของแบบจำลอง
- 4) การวัดประสิทธิภาพแบบจำลองจากผลการทำนาย




รูปที่ 19 ขั้นตอนแนวคิดและวิธีการวิจัยเพื่อเปรียบเทียบโครงข่ายประสาทคอนโวลูชันสำหรับการจำแนกโรคหลอดเลือดสมอง


### 3.1 การเตรียมชุดข้อมูล

จัดเตรียมชุดข้อมูลภาพการฉายรังสีเอกซเรย์ของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และภาพของผู้ป่วยสุขภาพปกติ จากแหล่งข้อมูลออนไลน์ <https://www.kaggle.com/afridirahman/brain-stroke-ct-image-dataset>

โดยจากข้อมูลสามารถแบ่งข้อมูลได้เป็น 2 ประเภท คือ 1) ภาพผู้ป่วยที่เป็นโรคหลอดเลือดสมอง การฉายรังสีเอกซเรย์ (950 ภาพ จาก 40 คน) และ 2) ภาพผู้ป่วยปกติจากการฉายรังสีเอกซเรย์ (1551 ภาพ จาก 82 คน)



ตัวอย่างที่ 1 ภาพการฉายรังสีเอกซเรย์ของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง



ตัวอย่างที่ 2 ภาพการฉายรังสีเอกซเรย์ของผู้ป่วยไม่ที่มีสุขภาพปกติ

รูปที่ 20 ตัวอย่างชุดข้อมูลภาพการฉายรังสีเอกซเรย์ทั้ง 2 ประเภท  
ที่ใช้ในการฝึกฝนแบบจำลอง

จากภาพจะสังเกตเห็นได้ว่าโรคหลอดเลือดสมองในงานชิ้นนี้มีความท้าทาย ประการแรก คือ รูปร่าง (Shape), มาตรฐาน (Scale), ขนาด (Size) และตำแหน่งของรอยโรคจะมีความแตกต่างกันไป ประการที่สอง คือรอยโรคบางส่วนมีขอบเขตที่คลุมเครือมาก ทำให้เกิดความสับสนระหว่างผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยที่มีสุขภาพปกติ

ตารางที่ 1 ในการฝึกสอนและทดสอบแบบจำลอง จะแบ่งข้อมูลออกเป็น ข้อมูลสอน ข้อมูลตรวจสอบ และข้อมูลทดสอบ

ประเภทรูปภาพ	ข้อมูลสอน	ข้อมูลตรวจสอบ	ข้อมูลทดสอบ	จำนวนทั้งหมด
ภาพของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง	570	190	190	950
ภาพของผู้ป่วยที่มีสุขภาพปกติ	931	310	310	1,551
รวม	1,501	500	500	2,501

### 3.2 การสร้างแบบจำลองการทำนายโรคหลอดเลือดสมอง

ทดสอบแบบจำลองการเรียนรู้เชิงลึกแบบคอนโวลูชัน 3 มิติ ทั้ง 4 แบบ คือ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet โดยจะมีการปรับแต่งโครงสร้างพื้นฐาน จากการเพิ่มหรือลดจำนวนตัวกรอง (Filter) ของชั้นคอนโวลูชัน (Convolution Layer) และการเพิ่มชั้นความลึกตามโครงสร้างของโครงข่ายคอนโวลูชัน 3 มิติ เพื่อให้โมเดลสามารถที่จะทำนายได้มีประสิทธิภาพมากยิ่งขึ้น

### 3.3 การเปรียบเทียบประสิทธิภาพของแบบจำลอง

การเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 4 แบบ งานวิจัยนี้มีการนำเทคนิค K-Fold Cross Validation โดยการกำหนดให้ K=5 เพื่อใช้ในการเปรียบเทียบ และหาโมเดลที่มีประสิทธิภาพมากที่สุดจากทั้ง 4 แบบจำลอง โดยสามารถลด Bias ของแบบจำลองแต่ละแบบจากการใช้เทคนิค K-Fold Cross Validation

### 3.4 การวัดประสิทธิภาพแบบจำลองจากผลการทำนาย

การวัดประสิทธิภาพของแบบจำลองในงานวิจัยนี้ จะทำการตรวจสอบผลลัพธ์การทำนายด้วยค่าคอนฟิวชันเมทริกซ์ (Confusion Matrix) และนำค่าของผลลัพธ์ที่ได้คือ True Positive (TP), True Negative (TN), False Positive (FP) และ False Negative (FN) นำไปคำนวณวัดความถูกต้องของการพยากรณ์เพิ่มเติม ได้แก่ ค่าความแม่นยำ (Accuracy), ค่าความเที่ยงตรง (Precision), ค่าความครบถ้วน (Recall), และค่า F1-Score

### 3.5 การเตรียมชุดข้อมูลที่ใช้ในการทดสอบแบบจำลอง

ทำการอัปโหลดชุดข้อมูลภาพตัวอย่างจาก Google drive ซึ่งเป็นบริการเก็บข้อมูลแบบ cloud สามารถเข้าถึง และอัปโหลดข้อมูลได้จากทุกที่ โดยมีโครงสร้างโฟลเดอร์เป็น Normal , Stroke ซึ่งมีการใช้โค้ดในการเรียกข้อมูล ดังรูปที่ 21

```
!pip install --upgrade --no-cache-dir gdown
!gdown --id 19nx4Wu5X_CEQmVWhtor22N0GQvcngQ
!unzip -q /content/brainstroke.zip


...
Brain_Data_Organised\
Normal\
*.jpg
Stroke\
*.jpg
...

Looking in indexes: https://pypi.org/simple, https://us-python.pkg.dev/colab-wheels/public/simple/
Requirement already satisfied: gdown in /usr/local/lib/python3.8/dist-packages (4.4.0)
Collecting gdown
  Downloading gdown-4.6.4-py3-none-any.whl (14 kB)
Requirement already satisfied: six in /usr/local/lib/python3.8/dist-packages (from gdown) (1.15.0)
Requirement already satisfied: beautifulsoup4 in /usr/local/lib/python3.8/dist-packages (from gdown) (4.6.3)
Requirement already satisfied: requests[socks] in /usr/local/lib/python3.8/dist-packages (from gdown) (2.25.1)
Requirement already satisfied: tqdm in /usr/local/lib/python3.8/dist-packages (from gdown) (4.64.1)
Requirement already satisfied: filelock in /usr/local/lib/python3.8/dist-packages (from gdown) (3.9.0)
Requirement already satisfied: chardet<5,>=3.0.2 in /usr/local/lib/python3.8/dist-packages (from requests[socks]->gdown) (4.0.0)
Requirement already satisfied: certifi<=2017.4.17 in /usr/local/lib/python3.8/dist-packages (from requests[socks]->gdown) (2022.12.7)
Requirement already satisfied: idna<3,>=2.5 in /usr/local/lib/python3.8/dist-packages (from requests[socks]->gdown) (2.10)
Requirement already satisfied: urllib3<1.27,>=1.21.1 in /usr/local/lib/python3.8/dist-packages (from requests[socks]->gdown) (1.24.3)
Requirement already satisfied: PySocks<1.5.7,>=1.5.6 in /usr/local/lib/python3.8/dist-packages (from requests[socks]->gdown) (1.7.1)
Installing collected packages: gdown
  Attempting uninstall: gdown
    Found existing installation: gdown 4.4.0
    Uninstalling gdown-4.4.0:
      Successfully uninstalled gdown-4.4.0
  Successfully installed gdown-4.6.4
/usr/local/lib/python3.8/dist-packages/gdown/cli.py:121: FutureWarning: Option '--id' was deprecated in version 4.3.1 and will be removed in 5.0. You don't need to pass it anymore to use a file ID.
  warnings.warn(
Downloading ...
From: https://drive.google.com/uc?id=19nx4Wu5X_CEQmVWhtor22N0GQvcngQ
To: /content/brainstroke.zip
100% 63.3M/63.3M [00:01:00:00, 32.0MB/s]
Downloading ...
'Brain_Data_Organised Normal *.jpg\n Stroke *.jpg\n'
```

รูปที่ 21 ตัวอย่างการอัปโหลดข้อมูล

ในขั้นตอนการเรียกใช้รูปภาพเพื่อใช้ใน Google colab ใช้คำสั่ง gdown เพื่อดึงข้อมูลจาก Google colab มา หลังจากนั้นทำการ unzip ไฟล์ด้วยคำสั่ง unzip (!unzip -q /content/brainstroke.zip)

จากภาพแต่ละภาพของข้อมูลจะมีตำแหน่งของรอยโรคที่ความแตกต่างกันไป และมีความไม่ชัดเจนของรอยโรค เพื่อให้การจำแนกประเภทมีความแม่นยำมากขึ้น จึงใช้เทคนิคการประมวลผลภาพล่วงหน้า (Image preprocessing) กับชุดข้อมูลที่มีอยู่ทั้ง 2 ประเภท 1) ภาพของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง (950 ภาพ จาก 40 คน) และ 2) ภาพของผู้ป่วยที่มีสุขภาพปกติ (1551 ภาพ จาก 82 คน) โดยใช้เทคนิค Image Enhancement ร่วมกับการทำ Histogram Equalization เพื่อให้ภาพมีความคมชัดมากขึ้น โดยใช้คำสั่ง blur = 7, CANNY\_THRESH = 10 – 200 และทำการ Edge Detection เพื่อจัดการกับพื้นที่ขอบ ทำให้ภาพมีขอบเขตชัดเจนยิ่งขึ้น โดยตัวอย่างของการทำการประมวลผลภาพล่วงหน้าดังรูปตัวอย่างที่ 22



รูปที่ 22 ตัวอย่างการทำการประมวลผลภาพล่วงหน้ากับชุดข้อมูล

เนื่องจากแบบจำลองของงานวิจัยเป็นแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติ จึงต้องมีการแปลงภาพ จาก 2 มิติ เป็นภาพ 3 มิติ โดยกำหนดให้มีความลึกที่ 40 ชั้น ซึ่งเป็นจำนวนชั้นที่มากที่สุดที่สามารถนำภาพมาประกอบรวมกันเป็น 3 มิติได้ จากการหาค่าสูงสุดของภาพถ่ายรังสีเอกซเรย์ของแต่ละคน ดังรูปตัวอย่างที่ 23 โดยกรณีที่จำนวนภาพของคนที่มีมุมมองของภาพไม่ถึง 40 ภาพ จะใช้ชั้นพื้นสีดำแทนที่ภาพที่หายไปจนครบ 40 ชั้น ประกอบจนกระทั่งภาพมีความลึกเท่ากับ 40 ตามค่าที่งานวิจัยชิ้นนี้กำหนดไว้ ดังรูปตัวอย่างที่ 23 หลังจากนั้นจะกำหนดข้อมูลภาพที่ขนาด  $128 \times 128 \times 40$  เพื่อไม่ให้เป็นการ Bias ในแต่ละโมเดล

```

patience_dict = patience_class.label
abnormal_dict = {k:v for (k,v) in patience_dict.items() if v == 'Stroke'}
abnormal_list = list(abnormal_dict)

for case in abnormal_list:
    print(case)
    patience_case = int(case)
    patience_paths = sorted(glob(os.path.join(folder_path, f'{patience_case} (*) .jpg')))

    max_views = len(patience_paths)
    print('max view:', max_views)

    i = 1
    while i <= DEPTH:
        if i <= max_views:
            path_img = folder_path + "{} ({}).jpg".format(patience_case, i)

            if os.path.exists(path_img):
                gray_img = cv2.imread(path_img, cv2.IMREAD_GRAYSCALE)
                gray_img = resize_volume(gray_img)

                gray_img = np.float32(gray_img)/255
            else:
                gray_img = np.zeros((650, 650, 1), np.float32)
                gray_img = resize_volume(gray_img)/255
            else:
                gray_img = np.zeros((650, 650, 1), np.float32)
                gray_img = resize_volume(gray_img)/255

        if i == 1:
            tmp_array = gray_img
        else:
            tmp_array = np.dstack((tmp_array, gray_img))

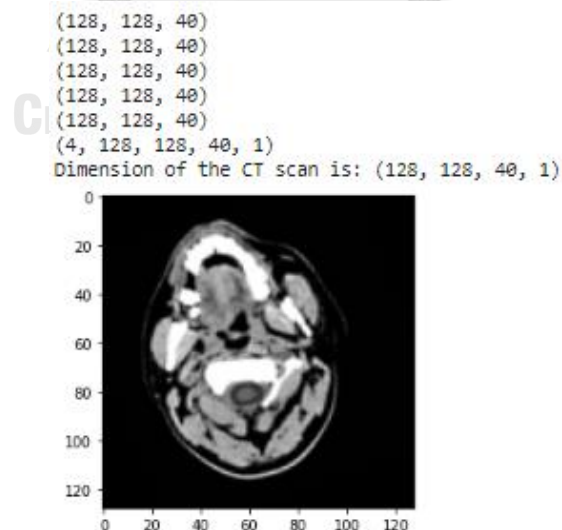
        i += 1

    tmp_list.append(tmp_array)

abnormal_scans = np.array(tmp_list)
tmp_list = []
max view: 29
128
max view: 28
125
max view: 40
117
max view: 29
104
max view: 29
120
max view: 30
99
max view: 29
126

```

รูปที่ 23 ตัวอย่างการประมวลผลภาพล่วงหน้าเพื่อกำหนดชั้นความลึกของข้อมูล



รูปที่ 24 ตัวอย่างการนำภาพฉายรังสีเอกซเรย์คนเป็นโรคหลอดเลือดสมอง

มาประกอบกันเป็นภาพ 3 มิติ ขนาด 128x128x40



เนื่องจากชุดข้อมูลมีขนาดเล็ก และมีจำนวนที่จำกัด จึงต้องทำการเพิ่มข้อมูล โดยทำการ Data Augmentation ดังรูปที่ 25 เพื่อเพิ่มจำนวนตัวอย่างของรูปภาพให้มีความหลากหลายมากขึ้น สำหรับชุดข้อมูลที่ใช้ในการฝึกสอนแบบจำลอง (Training dataset) โดยทำการใช้เทคนิคต่างๆของการทำ Data Augmentation ไม่ว่าจะเป็นการหมุนภาพ (Rotate) ,การปรับขนาดภาพ (Resize) และการซูม (Zoom) ผ่านคำสั่ง ImageDataGenerator โดยมีกำหนดค่าให้พารามิเตอร์ดังนี้

1. การหมุนภาพ (Rotation\_Range = 40)
2. การปรับขนาดภาพ (Resize) มีการกำหนดค่า Scale\_percent = 19.8 และใช้สูตร  $\text{Shape} \times \text{Scale percent} / 100$
3. การซูม (Zoom = 0.2) และ random\_zoom



```
def random_zoom(matrix, min_percentage=0.95, max_percentage=0.95):
    z = np.random.sample() * (max_percentage - min_percentage) + min_percentage
    zoom_matrix = np.array([[z, 0, 0],
                            [0, z, 0],
                            [0, 0, z],
                            [0, 0, 0, 1]])
    return ndimage.interpolation.affine_transform(matrix, zoom_matrix)

zoom_image = random_zoom(np.squeeze(image))

fig, ax = plt.subplots(1, 2, figsize=(16, 8))
ax[0].imshow(np.squeeze(image[:, :, view]), cmap="gray")
ax[1].imshow(np.squeeze(zoom_image[:, :, view]), cmap="gray")
plt.show()
```

รูปที่ 25 ตัวอย่างการเพิ่มจำนวนข้อมูล (Data Augmentation) สำหรับชุดข้อมูลที่ใช้ในการทดสอบ

### 3.6 การดำเนินการสร้างแบบจำลอง

เริ่มจากการนำเอาไลบรารีที่จำเป็นต่อการสร้างแบบจำลองจาก TensorFlow โดยจะนำมาใช้ในการสร้างแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติ โดยจะนำเอาแบบจำลอง pre-trained ทั้งหมดและนำมาใช้สร้างชั้นการเชื่อมต่อกันอย่างสมบูรณ์ เพื่อใช้ในการจำแนกภาพฉายรังสีเอกซเรย์ของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยที่มีสุขภาพปกติ ให้กับแบบจำลองโครงข่ายคอนโวลูชันทั้ง 4 รูปแบบ คือ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet ที่มีความแตกต่างจากโครงสร้างพื้นฐาน ที่มีการเพิ่มชั้นหรือลดจำนวนตัวกรอง (Filter) ของชั้นคอนโวลูชัน (Convolution Layer) การเพิ่มหรือลดขนาดของตัวกรองเพื่อให้แบบจำลองสามารถทำนายภาพการฉายรังสีเอกซเรย์โรคหลอดเลือดสมองได้แม่นยำมากยิ่งขึ้น

### 3.6.1 แบบจำลองโครงข่ายประสาทคอนโวลูชันอเล็กซ์เน็ต (Alexnet)

นำเข้าแบบจำลองโครงข่ายประสาทคอนโวลูชัน 3 มิติ โดยยึดโครงสร้างอเล็กซ์เน็ตเป็นพื้นฐานเพื่อให้ได้แบบจำลองที่สามารถจำแนกประเภทของคนเป็นโรคหลอดเลือดสมองได้แม่นยำ โดยจะทำการกำหนดขนาดของภาพเป็นขนาด  $128 \times 128$  (กว้าง  $\times$  สูง) เพิ่มจำนวนความลึก (Depth=40) ที่ได้จากการแปลงภาพตัวอย่าง 2 มิติให้เป็นภาพ 3 มิติ เพื่อไม่ให้เกิดการ Bias ของข้อมูล

โดยโครงสร้างของโครงข่ายประสาทคอนโวลูชันอเล็กซ์เน็ต 3 มิติ ประกอบไปด้วย 5 ชั้นคอนโวลูชัน (Conv Layer) 3 ชั้นเชื่อมโยงเต็มรูปแบบ (FC) และ 2 ชั้นดรอปเอาท์ (Dropout Layer) ในแต่ละ Conv layer จะประกอบด้วย Relu ใช้เพื่อลดขนาดมิติที่ใช้คำนวณลง โดยจะมีชั้นคอนโวลูชันที่ทำหน้าที่ดึงคุณลักษณะเด่นออกมา ชั้นที่ 1 (Conv1) มี 96 ตัวกรอง ขนาดตัวกรองที่ใช้คือ  $11 \times 11$  ชั้น ในชั้นที่ 2 (Conv2) มี 256 ตัวกรอง ขนาดตัวกรองที่ใช้คือ  $5 \times 5$  ชั้น ชั้นที่ 3 (Conv3), 4 (Conv4) มีตัวกรอง 384 และชั้นที่ 5 (Conv5) มีตัวกรอง 256 โดยขนาดตัวกรองที่ใช้ใน Conv3, Conv4 และ Conv5 คือ  $3 \times 3$  ซึ่งทั้ง 5 ชั้นคอนโวลูชันจะใช้ชั้นการรวมที่มีค่ามากที่สุด (Max Pooling Layer) มีขนาดที่  $2 \times 2$  โดยใน Conv1 และ Conv2 มีการใช้ค่าสไตรค์ (Stride) เป็น 2 พิกเซล ส่วนในชั้นที่เหลือจะกำหนดให้เป็น 1 พิกเซล โดยฟังก์ชันการกระตุ้น (Activation Function) ที่ใช้ในแต่ละชั้นคือ Relu function ยกเว้นชั้นที่แสดงผลให้เป็น Sigmoid เพื่อเป็นชั้นที่ไว้สำหรับการทำนายผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยสุขภาพปกติ รายละเอียดของโครงสร้างแต่ละชั้นตามรูปที่ 26

Model: "AlexNET"

Layer (type)	Output Shape	Param #
input_2 (InputLayer)	[(None, 128, 128, 40, 1)]	0
conv3d_5 (Conv3D)	(None, 118, 118, 30, 96)	127872
max_pooling3d_3 (MaxPooling3D)	(None, 59, 59, 15, 96)	0
conv3d_6 (Conv3D)	(None, 59, 59, 15, 256)	3072256
max_pooling3d_4 (MaxPooling3D)	(None, 29, 29, 7, 256)	0
conv3d_7 (Conv3D)	(None, 29, 29, 7, 384)	2654592
conv3d_8 (Conv3D)	(None, 29, 29, 7, 384)	3981696
conv3d_9 (Conv3D)	(None, 29, 29, 7, 256)	2654464
max_pooling3d_5 (MaxPooling3D)	(None, 29, 29, 7, 256)	0
flatten_1 (Flatten)	(None, 1507072)	0
dense_3 (Dense)	(None, 16)	24113168
dropout_2 (Dropout)	(None, 16)	0
dense_4 (Dense)	(None, 16)	272
dropout_3 (Dropout)	(None, 16)	0
dense_5 (Dense)	(None, 1)	17

=====  
 Total params: 36,604,337  
 Trainable params: 36,604,337  
 Non-trainable params: 0

รูปที่ 26 รายละเอียดโครงสร้างของแบบจำลองอเล็กซ์เน็ต 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง

### 3.6.2 แบบจำลองโครงข่ายประสาทคอนโวลูชันวิจิจี 16 (VGG-16)

นำเข้าแบบจำลองโครงข่ายประสาทคอนโวลูชัน 3 มิติโดยยึดโครงสร้างวิจิจี เป็นพื้นฐานเพื่อให้ได้แบบจำลองที่สามารถจำแนกประเภทของคนเป็นโรคหลอดเลือดสมองได้แม่นยำ โดยจะทำการกำหนดขนาดของภาพเป็นขนาด  $128 \times 128$  (กว้าง  $\times$  สูง) เพิ่มจำนวนความลึก (Depth=40) ที่ได้จากการแปลงภาพตัวอย่าง 2 มิติให้เป็นภาพ 3 มิติ และคงที่จำนวนตัวกรองที่ใช้ในแต่ละชั้นคอนโวลูชัน ซึ่งเป็นจุดเด่นของโครงข่ายประสาทคอนโวลูชันวิจิจี-16 เป็นการแทนที่ตัวกรองที่มีขนาดใหญ่ ด้วยตัวกรองที่มีขนาดเล็กลง ( $3 \times 3$ )

โดยโครงสร้างของโครงข่ายประสาทคอนโวลูชันวิจิจี แบบ 3 มิติประกอบไปด้วย 6 ชั้นคอนโวลูชัน (Conv Layer) และ 3 ชั้น เชื่อมโยงเต็มรูปแบบ (FC) ในแต่ละชั้นคอนโวลูชันจะประกอบด้วย Relu ใช้เพื่อลดขนาดมิติที่ใช้คำนวณลง โดยจะมีชั้นคอนโวลูชันทำหน้าที่

ดึงคุณลักษณะเด่นออกมา ชั้นที่ 1-2 (Conv1-2) มี 64 ตัวกรอง ในชั้นที่ 3-4 (Conv3-4) มี 128 ตัวกรอง ชั้นที่ 5-6 (Conv5-6) มีตัวกรอง 256 โดยขนาดตัวกรองที่ใช้ในทุกชั้นคอนโวลูชันคือ 3x3 ซึ่งชั้นคอนโวลูชันทั้งหมดจะใช้ชั้นการรวมที่มีค่ามากที่สุด (Max Pooling Layer) มีขนาดที่ 2 x 2 x 2 โดยในทุกชั้นจะมีการใช้ค่าสไตรค์ (Stride) เป็น 2 พิกเซล โดยฟังก์ชันการกระตุ้น (Activation Function) ที่ใช้ในแต่ละชั้นคือ Relu function ยกเว้นชั้นที่แสดงผลให้เป็น Softmax เพื่อเป็นชั้นที่ไว้สำหรับการทำนายผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยสุขภาพปกติ รายละเอียดของโครงสร้างแต่ละชั้นตามรูปที่ 27

```

Model: "VGG"
-----
Layer (type)                Output Shape                Param #
-----
input_3 (InputLayer)        [(None, 128, 128, 40, 1)  0
                               ]
conv3d_10 (Conv3D)           (None, 128, 128, 40, 64)  1792
conv3d_11 (Conv3D)           (None, 128, 128, 40, 64)  110656
max_pooling3d_6 (MaxPooling  (None, 64, 64, 20, 64)    0
3D)
conv3d_12 (Conv3D)           (None, 64, 64, 20, 128)   221312
conv3d_13 (Conv3D)           (None, 64, 64, 20, 128)   442496
max_pooling3d_7 (MaxPooling  (None, 32, 32, 10, 128)   0
3D)
conv3d_14 (Conv3D)           (None, 32, 32, 10, 256)   884992
conv3d_15 (Conv3D)           (None, 32, 32, 10, 256)   1769728
max_pooling3d_8 (MaxPooling  (None, 16, 16, 5, 256)    0
3D)
flatten_2 (Flatten)          (None, 327680)            0
dense_6 (Dense)              (None, 256)               83886336
dense_7 (Dense)              (None, 256)               65792
dense_8 (Dense)              (None, 2)                  514
-----
Total params: 87,383,618
Trainable params: 87,383,618
Non-trainable params: 0
-----

```

รูปที่ 27 รายละเอียดโครงสร้างของแบบจำลองวีจีจีแบบ 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง

### 3.6.3 แบบจำลองโครงข่ายประสาทคอนโวลูชันกูเกิลเน็ต (Googlenet)

นำเข้าแบบจำลองโครงข่ายประสาทคอนโวลูชัน 3 มิติโดยยึดโครงสร้างกูเกิลเน็ตเป็นพื้นฐานเพื่อให้ได้แบบจำลองที่สามารถจำแนกประเภทของผู้ป่วยที่เป็นโรคหลอดเลือดสมองได้แม่นยำ โดยจะกำหนดขนาดของภาพเป็นขนาด 128 x 128 (กว้าง x สูง) เพิ่มจำนวนความลึก (Depth=40) ที่ได้จากการแปลงภาพตัวอย่าง 2 มิติ ให้เป็นภาพ 3 มิติ โครงสร้างของกูเกิลเน็ตมีจุดเด่นคือมีองค์ประกอบที่เรียกว่า Inception modules โดยในแต่ละบล็อกจะมีขนาดของตัวกรองที่แตกต่างกันออกไป คือ 1x1, 3x3 และ 5x5 เพื่อที่สามารถหาคุณลักษณะที่มีความสัมพันธ์ที่หลากหลายมากยิ่งขึ้น ซึ่งจุดเด่นของกูเกิลเน็ตคือการใช้ขนาดตัวกรอง 1x1 (bottleneck layers) ซึ่งเป็นหน่วยที่เล็กที่สุดที่สามารถใส่ได้ เพื่อลด cost จากการเกิด parameters ได้ อีกทั้งยังสามารถช่วยหาความสัมพันธ์แนวลึกได้มากขึ้น มีการใช้ Relu function เป็นฟังก์ชันการกระตุ้น (Activation Function) ในแต่ละชั้น เพื่อที่จะสามารถเทรนโมเดลได้เร็วมากขึ้น โดยมีการแสดงผลเป็น Softmax เพื่อเป็นขั้นที่ไว้สำหรับการทำนายผู้ป่วยที่เป็นโรคหลอดเลือดสมอง หรือผู้ป่วยที่มีสุขภาพปกติ

```
#Build model.
GoogLeNet_model = get_GOOLENET(width=128, height=128, depth=40)
GoogLeNet_model.summary()

average_pooling3d (AveragePool
ing3D)                (None, 3, 3, 1, 512 0)    ['concatenate_2[0][0]']

average_pooling3d_1 (AveragePo
oling3D)              (None, 3, 3, 1, 528 0)    ['concatenate_5[0][0]']

conv3d_64 (Conv3D)    (None, 4, 4, 1, 384 319872) ['concatenate_7[0][0]']

conv3d_66 (Conv3D)    (None, 4, 4, 1, 384 74112)  ['conv3d_65[0][0]']

conv3d_68 (Conv3D)    (None, 4, 4, 1, 128 6272)   ['conv3d_67[0][0]']

conv3d_69 (Conv3D)    (None, 4, 4, 1, 128 106624) ['max_pooling3d_18[0][0]']

conv3d_32 (Conv3D)    (None, 3, 3, 1, 128 65664)   ['average_pooling3d[0][0]']

conv3d_51 (Conv3D)    (None, 3, 3, 1, 128 67712)   ['average_pooling3d_1[0][0]']

concatenate_8 (Concatenate) (None, 4, 4, 1, 102 0)    ['conv3d_64[0][0]',
4)                        'conv3d_66[0][0]',
                        'conv3d_68[0][0]',
                        'conv3d_69[0][0]']

flatten_2 (Flatten)    (None, 1152) 0 ['conv3d_32[0][0]']

flatten_3 (Flatten)    (None, 1152) 0 ['conv3d_51[0][0]']

global_average_pooling3d (Glob
alAveragePooling3D) (None, 1024) 0 ['concatenate_8[0][0]']

dense_6 (Dense)        (None, 1024) 1180672 ['flatten_2[0][0]']

dense_8 (Dense)        (None, 1024) 1180672 ['flatten_3[0][0]']

dropout_4 (Dropout)    (None, 1024) 0 ['global_average_pooling3d[0][0]']

dropout_2 (Dropout)    (None, 1024) 0 ['dense_6[0][0]']

dropout_3 (Dropout)    (None, 1024) 0 ['dense_8[0][0]']

dense_10 (Dense)       (None, 2) 2050 ['dropout_4[0][0]']

dense_7 (Dense)        (None, 2) 2050 ['dropout_2[0][0]']

dense_9 (Dense)        (None, 2) 2050 ['dropout_3[0][0]']

=====
Total params: 5,478,454
Trainable params: 5,478,454
Non-trainable params: 0
```

รูปที่ 28 รายละเอียดโครงสร้างของแบบจำลองกูเกิลเน็ตแบบ 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง

### 3.6.4 แบบจำลองโครงข่ายประสาทคอนโวลูชันเรสเน็ต (Resnet)

นำเข้าแบบจำลองโครงข่ายประสาทคอนโวลูชัน 3 มิติโดยยึดโครงสร้าง และจุดเด่นของแบบจำลองเรสเน็ต เป็นพื้นฐานเพื่อให้ได้แบบจำลองที่สามารถจำแนกประเภทของผู้ป่วยที่เป็นโรคหลอดเลือดสมองได้แม่นยำ โดยจะกำหนดขนาดของภาพเป็นขนาด 128 x 128 (กว้าง x สูง) เพิ่มจำนวนความลึก (Depth=40) ที่ได้จากการแปลงภาพตัวอย่าง 2 มิติให้เป็นภาพ 3 มิติ ซึ่งจุดเด่นของแบบจำลองเรสเน็ต คือการใช้ Skip หรือ Short cut connection (Residual block) ระหว่างทุกๆ 2 ชั้นคอนโวลูชัน เพื่อแก้ปัญหการหายไปของการเคลื่อนลง (Vanishing gradient) ซึ่งมักจะเกิดขึ้นกับโครงข่ายที่มีความลึกค่อนข้างมากงานวิจัยชิ้นนี้มีการนำจุดเด่นที่ใช้ในการแก้ปัญหา Vanishing gradient ซึ่งเกิดจากโครงข่ายที่มีความลึกค่อนข้างมาก

```
# Build model.
RESNET_model = get_RESNET(width=128, height=128, depth=40)
RESNET_model.summary()

)
add_12 (Add) (None, 8, 8, 3, 512 0) ['add_11[0][0]', 'conv3d_99[0][0]']
batch_normalization_26 (BatchW (None, 8, 8, 3, 512 2048) ['add_12[0][0]']
ormalization)
re_lu_26 (ReLU) (None, 8, 8, 3, 512 0) ['batch_normalization_26[0][0]']
conv3d_100 (Conv3D) (None, 8, 8, 3, 512 7078400) ['re_lu_26[0][0]']
batch_normalization_27 (BatchW (None, 8, 8, 3, 512 2048) ['conv3d_100[0][0]']
ormalization)
re_lu_27 (ReLU) (None, 8, 8, 3, 512 0) ['batch_normalization_27[0][0]']
conv3d_101 (Conv3D) (None, 8, 8, 3, 512 7078400) ['re_lu_27[0][0]']
add_13 (Add) (None, 8, 8, 3, 512 0) ['add_12[0][0]', 'conv3d_101[0][0]']
batch_normalization_28 (BatchW (None, 8, 8, 3, 512 2048) ['add_13[0][0]']
ormalization)
re_lu_28 (ReLU) (None, 8, 8, 3, 512 0) ['batch_normalization_28[0][0]']
conv3d_102 (Conv3D) (None, 8, 8, 3, 512 7078400) ['re_lu_28[0][0]']
batch_normalization_29 (BatchW (None, 8, 8, 3, 512 2048) ['conv3d_102[0][0]']
ormalization)
re_lu_29 (ReLU) (None, 8, 8, 3, 512 0) ['batch_normalization_29[0][0]']
conv3d_103 (Conv3D) (None, 8, 8, 3, 512 7078400) ['re_lu_29[0][0]']
add_14 (Add) (None, 8, 8, 3, 512 0) ['add_13[0][0]', 'conv3d_103[0][0]']
global_average_pooling3d_1 (Gl (None, 512) 0) ['add_14[0][0]']
obalAveragePooling3D)
dense_11 (Dense) (None, 2) 1026 ['global_average_pooling3d_1[0][0]']


=====
Total params: 70,568,450
Trainable params: 70,554,242
Non-trainable params: 14,208
```

รูปที่ 29 รายละเอียดโครงสร้างของแบบจำลองเรสเน็ตแบบ 3 มิติที่ปรับแต่งแล้วในแต่ละชั้น และจำนวนพารามิเตอร์ทั้งหมดของแบบจำลอง

สำหรับแบบจำลองเรสเน็ตจะมีการใช้ Skip (res\_block) ระหว่างทุก 2 ชั้นคอนโวลูชัน เปรียบเสมือนเป็นการปรับช่วงของข้อมูลส่งออกหรือฟังก์ชันลักษณะให้แต่ละชั้นอยู่ในช่วงใกล้เคียงกันก่อนผ่านตัวกรองในชั้นถัดไป มีการใช้ Relu function เป็นฟังก์ชันการกระตุ้น (Activation Function) ในแต่ละชั้นเพื่อป้องกันการเกิด Vanishing Gradient และสามารถช่วยให้เทรนโมเดลได้เร็วมากขึ้น โดยมีการแสดงผลเป็น Softmax เพื่อเป็นขั้นที่ไว้สำหรับการทำนายคนเป็นโรคหลอดเลือดสมองหรือคนปกติ

### 3.6.5 K-Fold Cross Validation (K=5)

หลังจากทำการสร้างแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติทั้ง 4 แบบ ได้แก่ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet เพื่อไม่ให้เกิดการทดลองโน้มเอียงในการแบ่งชุดข้อมูลฝึกสอน (Training data + Validation data) และ ชุดข้อมูลทดสอบ (Test data) งานวิจัยนี้เลือกใช้วิธี K-Fold Cross Validation เข้ามาช่วยในการแบ่งข้อมูลออกเป็นจำนวน K ส่วน โดยในแต่ละส่วนต้องมาจากการสุ่มเพื่อที่จะให้ข้อมูลของเรากระจายอย่างเท่าๆ กัน จากนั้นข้อมูลหนึ่งส่วนจะถูกนำมาเป็นชุดข้อมูลทดสอบ ส่วนที่เหลือจะถูกนำมาใช้เป็นข้อมูลฝึกสอน ดังรูปที่ 30



รูปที่ 30 การแบ่งข้อมูลแบบ K-Fold Cross Validation (25)


โดยงานวิจัยชิ้นนี้กำหนดให้ K = 5 หลังจากที้นำข้อมูลแบ่งส่วนเป็นที่เรียบร้อยแล้ว จึง Training Data จากนั้นนำค่าการทดลองที่ได้ทั้งหมดมาหาค่าเฉลี่ยค่าความแม่นยำ (Accuracy) เพื่อทดสอบว่าแบบจำลองชุดไหนทำงานได้มีประสิทธิภาพมากที่สุด

### 3.7 การเปรียบเทียบประสิทธิภาพ และประเมินแบบจำลองผลการทำนายโรคหลอดเลือดสมอง จากภาพการฉายรังสีเอกซเรย์

โดยงานวิจัยนี้ ตัวชี้วัดในการประเมินแบบจำลองโครงข่ายประสาทเทียมคอนโวลูชันสำหรับการทำนายโรคหลอดเลือดสมองจากภาพเอกซเรย์สมอง คือการนำแบบจำลองแต่ละแบบมาหาค่าคอนฟิวชันเมทริกซ์ (Confusion Matrix) เพื่อหาค่าความแม่นยำ (Accuracy), ค่าความเที่ยงตรง (Precision), ค่าความครบถ้วน (Recall) และ ค่า F1-Score แสดงดังสมการ (1), (2), (3) และ (4) ตามลำดับ ดังตัววัดประสิทธิภาพ 2.1.8 ที่ได้กล่าวไว้ข้างต้น

		Actual Class	
		1	0
Predicted Class	1	True Positive	False Positive
	0	False Negative	True Negative

รูปที่ 31 ตัวอย่างตารางคอนฟิวชันเมทริกซ์ (Confusion Matrix) (34)





## บทที่ 4

### การทดลองและผลการทดลอง

#### 4.1 สภาพแวดล้อมที่ใช้ในการทดลอง

##### 4.1.1 การเขียนโปรแกรมและเฟรมเวิร์คที่ใช้ในการทดลอง

มีการใช้โปรแกรม Google Colaboratory โดยมี โฮสต์โปรแกรม เป็น Jupyter Notebook ที่ทำงานบน Cloud โดยการเขียนโปรแกรมสำหรับโครงข่ายคอนโวลูชันทั้ง 4 แบบ ประกอบด้วย อเล็กซ์เน็ต, กูเกิลเน็ต, วีจีจี-16 และเรสเน็ต โดยภาษาหลักที่ใช้จะเป็นภาษา Python ที่ใช้ในการเขียน และรันโมเดลร่วมกับเฟรมเวิร์ค Tensorflow และ Keras โดยจะมีการปรับปรุงเพิ่มเติมจากโครงสร้างของแบบจำลองต่างๆจากต้นฉบับ

##### 4.1.2 ชุดข้อมูลที่ใช้ในการทดลอง และเทคนิคการเพิ่มขนาดของชุดข้อมูล


ชุดข้อมูลที่ใช้ในการทดลองเป็นข้อมูลที่นำมาจากฐานข้อมูลออนไลน์ใน <https://www.kaggle.com/afriDirahman/brain-stroke-ct-image-dataset> โดยชุดข้อมูลภาพแบ่งเป็นภาพการฉายรังสีเอกซเรย์ของคนเป็นโรคหลอดเลือดสมอง และไม่เป็นโรคหลอดเลือดสมอง

มีการปรับปรุงประสิทธิภาพของชุดข้อมูลจากการประมวลผลภาพล่วงหน้า (Image Preprocessing) โดยใช้เทคนิค Image Enhancement และ Histogram Equalization หลังจากนั้นนำทำการแปลงภาพให้เป็นชุดข้อมูลภาพ 3 มิติ โดยนำภาพที่มีอยู่มาทับซ้อนกันตามกลุ่มของข้อมูล หลังจากนั้นมีการเพิ่มข้อมูลภาพโดยใช้เทคนิคการทำ Data Augmentation เพื่อเพิ่มจำนวนตัวอย่างของรูปภาพให้มีความหลากหลายเพิ่มขึ้น โดยทำการใช้เทคนิคการหมุนภาพ (Rotate) ,การปรับขนาดภาพ (Resize) และการซูม (Zoom)

#### 4.2 การดำเนินการทดลอง


##### 4.2.1 การเตรียมชุดข้อมูลสำหรับการทดลอง (Preparing Data)

ในขั้นตอนแรกของงานวิจัยชิ้นนี้ คือการเตรียมข้อมูล โดยงานวิจัยชิ้นนี้สามารถแบ่งข้อมูลได้เป็น 2 ประเภท คือ 1) ภาพผู้ป่วยที่โรคหลอดเลือดสมอง (950 ภาพ จาก 40 คน) และ 2) ภาพผู้ป่วยที่มีสุขภาพปกติ (1551 ภาพ จาก 82 คน) จากรูปตัวอย่างที่ 32 โดยปกติภาพฉายรังสีเอกซเรย์ของคนหนึ่งคนจะมีจำนวนภาพที่ได้ออกมาไม่เท่ากัน และในทางการแพทย์จำเป็นต้องตรวจเช็คทุกรูปจากภาพฉายรังสีเอกซเรย์เพื่อที่จะประกอบการตัดสินใจในการวินิจฉัยโรค



รูปที่ 32 รูปตัวอย่างภาพถ่ายรังสีเอกซเรย์ของคนเป็นโรคหลอดเลือดสมองต่อหนึ่งคน

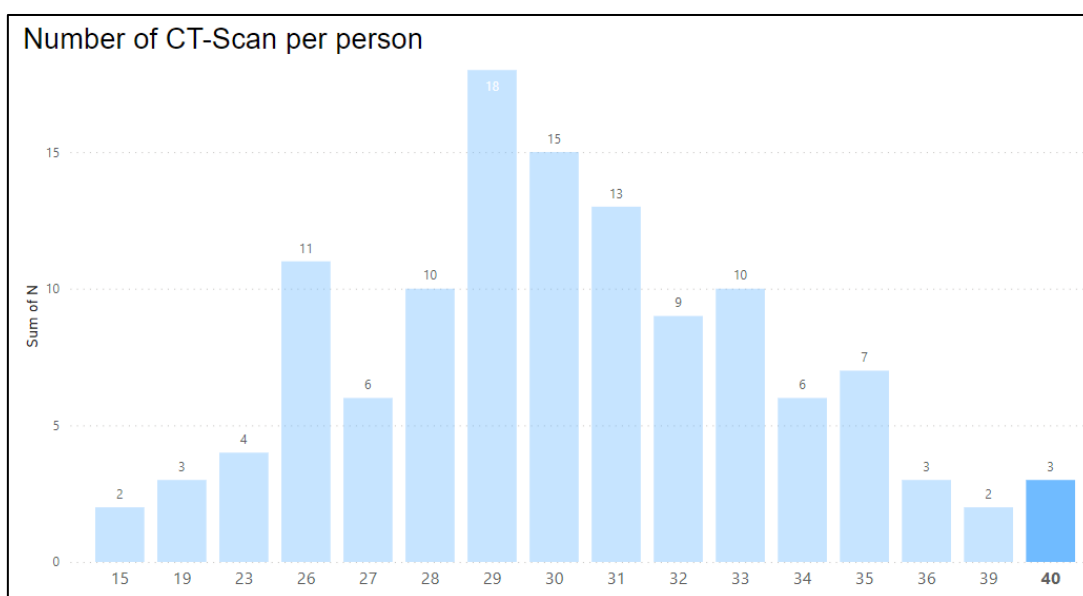
งานวิจัยชิ้นนี้มีการนำเสนอการใช้เทคนิคการประมวลผลภาพล่วงหน้ามาใช้ โดยเทคนิค Image Enhancement และ Histogram Equalization เพื่อให้ภาพสามารถแบ่งพื้นที่สีให้มีความเข้ม (Intensity) หรือความคมชัดมากขึ้น เปรียบเสมือนการทำให้สามารถมองเห็นภาพที่มีรายละเอียดที่ขาดหายไปได้มากยิ่งขึ้น เพื่อช่วยในการเพิ่มประสิทธิภาพของแบบจำลอง ดังตัวอย่างรูปที่ 33



รูปที่ 33 ตัวอย่างการทำ Histogram equalization


หลังจากนั้นงานวิจัยนี้ทำการแปลงภาพชุดข้อมูล จาก 2 มิติ ให้เป็นรูปแบบ 3 มิติ เพื่อสอดคล้องกับแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติ โดยที่ต้องกำหนดความลึกของการทำเป็น 3 มิติ ซึ่งงานวิจัยชิ้นนี้มีการกำหนดขอบข่ายความลึกที่ 40 ชั้น เนื่องจากเป็นจำนวนชั้นที่มากที่สุดจากการหาค่าสูงสุดของภาพถ่ายรังสีเอกซเรย์ของแต่ละคน (Number of CT-Scan per person) ดังรูปตัวอย่างที่ 34 หลังจากนั้นนำรูปของกลุ่มตัวอย่างมาทับซ้อนกันเพื่อให้เกิดเป็นภาพ 3 มิติ โดยจำนวน

ภาพของคนที่มีมุมมองความลึกไม่ถึง 40 ชั้น จะใช้พื้นที่สีดำแทนจำนวนชั้นที่ขาดหายไป ดังรูปที่ 24 งานวิจัยนี้เลือกไม่ใช้การตัดจำนวนภาพเนื่องจากป้องกันการขาดหายไปในจุดสำคัญของจำนวนภาพถ่ายจากรังสีเอกซเรย์ โดยที่การจัดการกับภาพให้เป็น 3 มิติ จะใช้ชุดข้อมูลภาพของผู้ป่วยรายเดียวกันเท่านั้น จะไม่มีการนำข้อมูลของผู้ป่วยรายอื่นมาประกอบรวมกันเพื่อให้เกิดภาพ 3 มิติ หลังจากนั้นจะทำการปรับขนาดชุดข้อมูลเป็น 128x128x40 เพื่อลดการ Bias ในแต่ละแบบจำลอง




รูปที่ 34 ตัวอย่างภาพการหาค่าสูงสุดของภาพถ่ายรังสีเอกซเรย์ของแต่ละคน

ดังที่กล่าวไว้ในหัวข้อ 3.5 การเตรียมชุดข้อมูลที่ใช้ในการทดสอบแบบจำลอง เนื่องจากชุดข้อมูลมีขนาดที่ค่อนข้างเล็ก จึงมีการใช้เทคนิคการเพิ่มขนาดของข้อมูล (Data Augmentation) เพื่อให้แบบจำลองมีการเรียนรู้ที่มากขึ้น สามารถจดจำภาพที่มีความหลากหลายได้มากขึ้น เพื่อเป็นการเพิ่มประสิทธิภาพของแบบจำลอง โดยมีการใช้เทคนิคการหมุนภาพ (Rotate), ปรับขนาดภาพ (Resize) และการซูม (Zoom) ดังรูปที่ 35,36



รูปที่ 35 ตัวอย่างรูปภาพหลังการใช้เทคนิค Data Augmentation รูปแบบ  
การ Resize และ Zoom



รูปที่ 36 ตัวอย่างรูปภาพหลังการใช้เทคนิค Data Augmentation ในรูปแบบการ Rotate

#### 4.2.2 การสอนแบบจำลอง (Model Training)

การสอนแบบจำลองเป็นขั้นตอนที่จะสร้างแบบจำลองสำหรับการทำนายผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยปกติ เนื่องจากข้อมูลของงานวิจัยชิ้นนี้เป็นรูปแบบประเภทภาพขนาด  $650 \times 650$  ซึ่งมีจำนวนพิกเซลที่ต้องใช้คำนวณจำนวนมาก และในแต่ละแบบจำลองมีโครงสร้างของการนำเข้าข้อมูล (input) ที่แตกต่างกัน งานวิจัยชิ้นนี้จึงทำการตัดสินใจเพื่อที่จะลดปัญหาการ Bias ของข้อมูลโดยการปรับขนาดของข้อมูลนำเข้าของแต่ละโมเดล ด้วยรูปภาพขนาด  $128 \times 128 \times 40$  ซึ่งเห็นได้จากรูปตัวอย่างที่ 24 โดยจากการกำหนดค่าความลึกที่ 40 ชั้น มาจากการทำการประมวลผลภาพล่วงหน้า (Image Preprocessing) ดังที่กล่าวไว้ในหัวข้อ 4.2.1

หลังจากนั้นทำการปรับค่าน้ำหนักของนิวรัลเน็ตเวิร์ค และตัวกรอง รวมไปถึงคำนวณหาค่าน้ำหนักฟังก์ชันกระตุ้นและปรับค่าตาม optimizer ที่ใช้ในแต่ละโครงสร้างที่ได้อธิบายไว้ในบทที่ 3.6 ซึ่งโครงข่ายประสาทเทียมคอนโวลูชันทั้ง 4 แบบจำลอง ประกอบด้วย 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet

หลังจากที่มีการเตรียมแบบจำลองทั้ง 4 รูปแบบ ดังที่กล่าวไว้ในหัวข้อ 3.6 การดำเนินการสร้างแบบจำลอง จะมีการนำเทคนิค K-Fold Cross Validation เข้ามาเพื่อใช้จัดการกับปัญหาการ Bias ของแบบจำลอง รวมถึงเพื่อปรับปรุงสมรรถนะของแบบจำลองให้ดียิ่งขึ้น

#### 4.2.2 ผลการทดสอบแบบจำลอง

จากการสร้างแบบจำลองทั้ง 4 โครงสร้าง และการใช้เทคนิค K-Fold Cross Validation กับโมเดลทั้ง 4 รูปแบบ ต่อมาเป็นขั้นตอนของการทดสอบแบบจำลองด้วยชุดข้อมูลทดสอบ ใช้ค่า prediction ค่าทำนายเท่ากับ 0 หมายถึงทำนายว่าเป็นภาพของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และเมื่อค่าทำนายเท่ากับ 1 หมายถึงทำนายว่าเป็นภาพของผู้ป่วยที่สุขภาพปกติ โดยเลือกทำนายข้อมูลจากชุดข้อมูลทดสอบ จากนั้นทำการสรุปผลเป็น Confusion matrix และแสดงผลการทำนายเป็นแต่ละค่าดังนี้ precision, recall, f1 score และ accuracy ดังตารางที่ 2


ตารางที่ 2 การวัดประสิทธิภาพของแบบจำลองทั้ง 4 รูปแบบ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet

ตัวชี้วัด Model	Confusion matrix				Macro average			Accuracy
	TP	FN	FP	TN	Precision	Recall	F1-Score	
3D - Alexnet	289	15	46	150	90.91%	76.53%	83.10%	87.80%
3D - VGG16	283	32	47	138	81.18%	74.59%	77.75%	84.20%
3D - Googlenet	303	10	30	157	94.01%	83.96%	88.70%	92.00%
3D - ResNet	273	49	46	132	72.93%	74.16%	73.54%	81.00%

จากผลการทดลองสมรรถภาพของแบบจำลองทั้ง 4 โครงสร้างคือ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet จากตารางที่ 1 พบว่าแบบจำลองที่ให้ค่าความแม่นยำที่สูงที่สุดเมื่อเทียบกับโมเดลอื่นคือ 3D Googlenet และมีแบบจำลอง 3D Alexnet, 3D VGG16, 3D Resnet เป็นจำลองที่ให้ค่าความแม่นยำที่รองลงมาตามลำดับ ที่มีค่าความแม่นยำที่ 92.00%, 87.80%, 84.20% และ 81.00% ตามลำดับ

ซึ่งแบบจำลอง 3D Resnet ให้ค่าความแม่นยำที่ต่ำที่สุดเมื่อมีการเปรียบเทียบกับแบบจำลองอื่น เนื่องจากตัวแบบจำลองมีข้อจำกัดในการกำหนดชั้นด้วยความลึก (Depth) เท่ากับ 40 ตามข้อจำกัดของภาพฉายรังสีเอกซเรย์ อาจทำให้แบบจำลองบางโครงสร้างไม่สามารถดึงคุณลักษณะ

เด่นของแบบจำลองออกมาได้ ซึ่งส่งผลต่อการทดสอบสมรรถนะของแบบจำลองในการแยกคุณลักษณะของรูปภาพชุดใหม่ได้ไม่ดีมากนัก จากที่กล่าวมาข้างต้นเนื่องจากแบบจำลองโครงข่ายคอนโวลูชันเรสเน็ต ซึ่งมีความสามารถเด่นในการจัดการกับโครงข่ายที่มีความลึกที่ค่อนข้างมาก แต่เนื่องด้วยข้อจำกัดของความลึกของภาพที่มีเพียง 40 ชั้น ส่งผลให้โครงข่ายคอนโวลูชันเรสเน็ตไม่สามารถแสดงประสิทธิภาพของแบบจำลองได้อย่างเต็มรูปแบบ และส่งผลให้เกิดปัญหาแบบจำลอง 3D Resnet เกิดความไม่เสถียรในการเรียนรู้ ดังรูปที่ 37

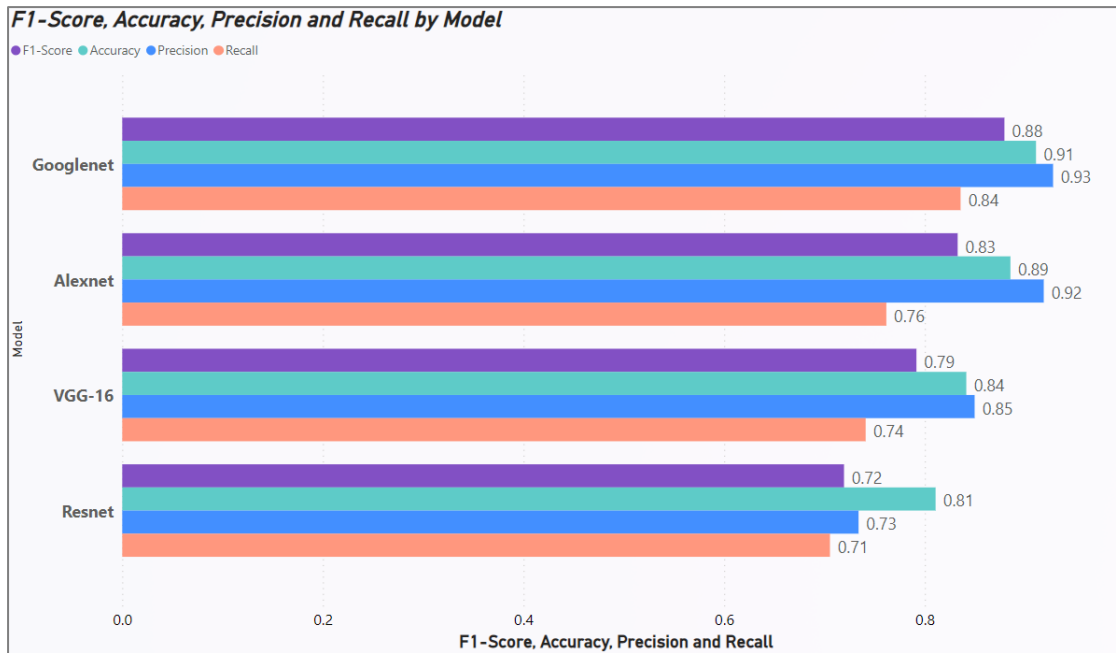


รูปที่ 37 ตัวอย่างปัญหาความไม่เสถียรของการทดสอบแบบจำลอง 3D Resnet

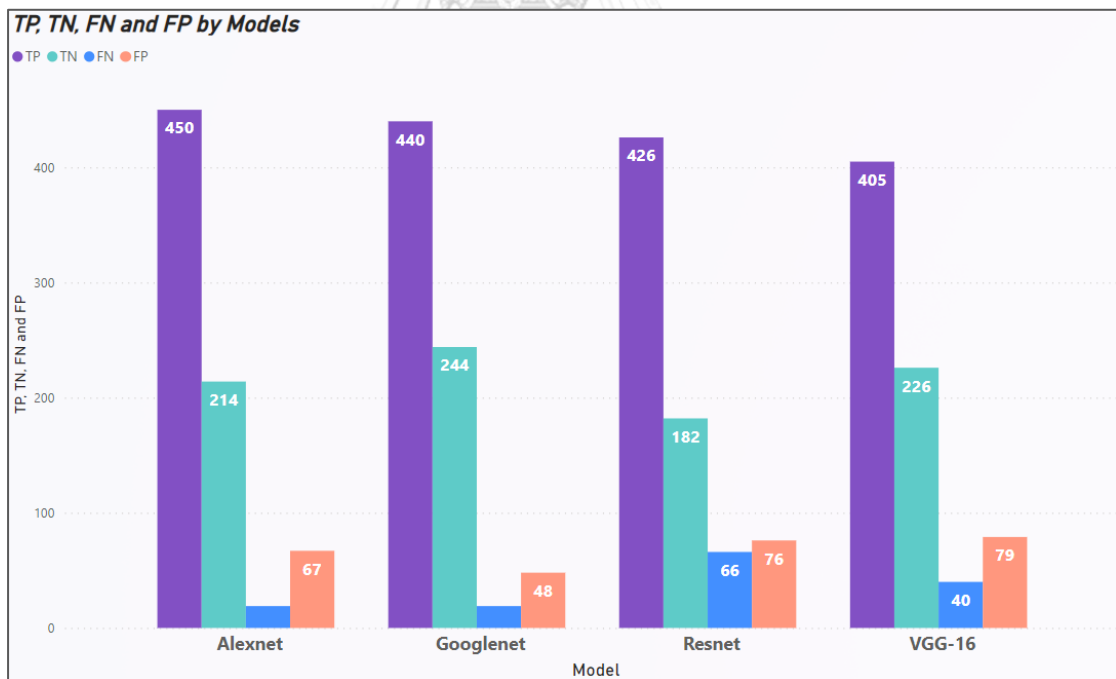
โดยสมรรถนะของแบบจำลองทั้ง 4 โครงสร้าง คือ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet สามารถดูผลการทดสอบแบบจำลองได้ดังตารางที่ 3

ตารางที่ 3 ประสิทธิภาพการฝึกสอนของแบบจำลองทั้ง 4 รูปแบบ 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet

Models	Learning rate	Total Parameters	Training time (s)	Final Loss
3D - Alexnet	0.0001	36,604,337	1,023	0.5340
3D - VGG16		87,383,618	1,427	0.1041
3D - Googlenet		5,478,454	1,560	0.4250
3D - ResNet		70,568,450	1,308	0.8294



รูปที่ 38 กราฟแท่งแสดงการเปรียบเทียบ Precision, Recall, F1-score, และ Accuracy




รูปที่ 39 กราฟแท่งแสดงการเปรียบเทียบ TP, TN, FP, และ FN

จากงานวิจัยของ Kehan Qi และ Hao Yang (32) มีการนำโครงข่ายคอนโวลูชันแต่ละโมเดล มาใช้ในการช่วยแบ่งส่วนรอยโรคของสมอง โดยใช้เทคนิคของโมเดล U-net และ X-net มาประยุกต์ใช้กับโมเดล Resnet ซึ่งให้ผลลัพธ์ Precision และ Recall ที่ 59.41% และ 45.37% ตามลำดับ และงานวิจัยของ Liwei Tan (10) การนำเสนอเทคนิคการทำ Faster R-CNN เพื่อการตรวจจับ และวิเคราะห์รอยโรคของสมองโดยการนำแบบจำลอง VGG-16 และ Resnet-101 มาประยุกต์ใช้ โดยผลลัพธ์จากความแม่นยำในการตรวจจับมีความใกล้เคียงกันที่ค่า Precision เท่ากับ 89.77%

ดังที่กล่าวไว้ข้างต้น งานวิจัยจำนวนมากที่นำโครงข่ายคอนโวลูชันเข้ามาเพื่อช่วยในการตรวจจับรอยโรคทางการแพทย์ เพื่อการวินิจฉัยในขั้นตอนถัดไป งานวิจัยชิ้นนี้มีแนวคิดโดยการนำโครงข่ายคอนโวลูชันประยุกต์เข้ากับรูปแบบ 3 มิติ มาใช้ในการจำแนกรโรค โดยใช้ชุดข้อมูลของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง ซึ่งแบบจำลองที่ดีที่สุดของงานวิจัยนี้คือ Googlenet ที่มีค่า Accuracy ที่ 92.00% ซึ่งโดยรวมสามารถเปรียบเทียบกับงานวิจัยที่กล่าวข้างต้นได้


จากการศึกษาในงานวิจัยชิ้นนี้ มีการตรวจสอบภาพของผู้ป่วยที่เป็นโรคหลอดเลือดสมองที่แบบจำลองมักจะเกิดข้อผิดพลาดในการจำแนกประเภทมักจะเป็นรูปที่มีลักษณะที่ติดอยู่กับส่วนกะโหลก และส่วนท้ายทอย ซึ่งจะแสดงให้เห็นถึงความไม่ชัดเจนของรอยโรคเนื่องจากมีส่วนที่ติดอยู่กับกะโหลกหรือส่วนของโครงสร้างกระดูกที่ค่อนข้างมาก ดังตัวอย่างรูปที่ 40



รูปที่ 40 ตัวอย่างรูปของคนเป็นโรคหลอดเลือดสมองที่แบบจำลองทำนายผิด

อีกทั้งมีการตรวจสอบรูปของคนที่ไม่เป็นโรคหลอดเลือดสมอง ซึ่งแบบจำลองทำนายผิดพลาดว่ามีลักษณะแบบไหน พบว่าลักษณะส่วนใหญ่จะมีรูปแบบที่เป็นลักษณะของเนื้อสมองที่ไม่สามารถตรวจสอบได้จากรูปเพียงรูปเดียวต้องมีการดูในหลากหลายมุมมอง ดังตัวอย่างรูปที่ 41





รูปที่ 41 ตัวอย่างรูปของคนไม่เป็นโรคหลอดเลือดสมองที่แบบจำลองทำนายผิด

งานวิจัยชิ้นนี้สามารถที่จะสรุปได้ว่า จากผลการทดลองชี้ให้เห็นว่าแบบจำลองโครงข่ายคอนโวลูชันภูเกิลเน็ต 3 มิติ เป็นแบบจำลองที่มีประสิทธิภาพมากที่สุดจากการวัดประสิทธิภาพดังตารางที่ 2 ซึ่งการนำรูปแบบ 3 มิติมา ร่วมกับการใช้โครงข่ายคอนโวลูชัน สามารถขจัดปัญหาในเรื่องของการที่รูปภาพของกลุ่มตัวอย่างบางรูปภาพที่จำเป็นต้องมองในหลากหลายมุมมอง จึงจะสามารถทำนายผลลัพธ์ได้ แต่ก็ยังคงมีข้อผิดพลาดจากการที่มุมมองภาพสมองบางภาพแสดงภาพเพียงในส่วนของเนื้อกระดูก หรือมีรอยโรคที่ไม่ชัดเจน ทำให้แบบจำลองแต่ละโครงข่ายยังมีข้อผิดพลาดในการทำนายผล

## บทที่ 5

### สรุปผลการวิจัยและข้อเสนอแนะ

#### 5.1 สรุปผลการวิจัย

วิทยานิพนธ์นี้ได้เสนอการประยุกต์โครงข่ายคอนโวลูชัน 3 มิติที่ได้มีการปรับโครงสร้างจากแบบจำลองทั้ง 4 รูปแบบ ประกอบด้วย 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet โดยมีการปรับโครงสร้างให้เหมาะสมกับชุดข้อมูลการทำนายภาพฉายรังสีเอกซเรย์ของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง อีกทั้งมีการดึงจุดเด่นในการคัดแยกคุณลักษณะสำคัญของแต่ละแบบจำลองมาใช้ในการปรับเปลี่ยนโครงสร้างของแบบจำลอง โดยดำเนินการตามขอบเขตดังนี้

1. ทำนายผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยปกติ จากภาพฉายรังสีเอกซเรย์ด้วยโครงข่ายประสาทคอนโวลูชัน 3 มิติ ที่มีโครงสร้างแบบ Pre-trained โมเดล ได้แก่ Alexnet, VGG-16, Googlenet และ Resnet

2. การใช้เทคนิคการเพิ่มข้อมูลเพื่อเพิ่มสมรรถนะให้กับแบบจำลอง ได้แก่

- การทำ Image Preprocessing เพื่อปรับปรุงคุณภาพของภาพ และแปลงภาพฉายรังสีเอกซเรย์ให้เป็นรูปแบบ 3 มิติ

- การเพิ่มข้อมูลด้วยเทคนิค Data Augmentation

3. การใช้เทคนิค K-Fold Cross Validation เพื่อลดปัญหาการ Bias ของแบบจำลอง

4. การเปรียบเทียบสมรรถนะของโครงสร้างแต่ละแบบด้วย Confusion Matrix

สำหรับการทดลองเพื่อจำแนกภาพฉายรังสีเอกซเรย์ของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และผู้ป่วยปกติ โดยใช้ชุดข้อมูลที่ถูกรวบรวมจากออนไลน์ที่น่าเชื่อถือ และมีขนาด 650 x 650 โดยจะถูกนำมาแปลงภาพให้กลายเป็นรูปแบบ 3 มิติ ที่กำหนดชั้นความลึก 40 ชั้น และขนาดภาพ 128x128x40 เพื่อให้สามารถเข้าสู่กระบวนการของแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติได้ และมีการเพิ่มจำนวนข้อมูลด้วยการใช้เทคนิค Data Augmentation ในขั้นตอนถัดไปผู้วิจัยได้สร้างแบบจำลองโครงข่ายคอนโวลูชัน 3 มิติ ซึ่งประกอบไปด้วย 3D Alexnet, 3D VGG-16, 3D Googlenet และ 3D Resnet

ในขั้นตอนถัดไปการใช้เทคนิค K-Fold Cross Validation เข้ามาเพื่อช่วยในการลดปัญหาของการ Bias ในแต่ละแบบจำลอง ซึ่งมีการนำทุกแบบจำลองใช้เทคนิค K-Fold Cross Validation ก่อน และหลังจากนั้นจึงนำมาทำการเปรียบเทียบประสิทธิภาพของแบบจำลองโดยใช้เครื่องมือ Confusion Matrix ในการหาค่า accuracy, precision, recall และ f1 score โดยผลการทดสอบที่ได้ผลลัพธ์ที่ให้ค่าความแม่นยำมากที่สุดคือแบบจำลอง 3D Googlenet ที่ให้ค่า 92.00% และให้ค่า precision, recall, f1-score มีค่าเป็น 94.01%, 83.96%, 88.70% ตามลำดับ

งานวิจัยชิ้นนี้สามารถสรุปเหตุผลในการเปรียบเทียบกันระหว่างแบบจำลอง 3D Googlenet ที่มีผลการทดลองที่ดีที่สุด ผู้วิจัยเชื่อว่า เนื่องมาจากแบบจำลองโครงข่ายคอนโวลูชัน กูเกิลเน็ต เป็นแบบจำลองที่มีแนวคิดที่จะพัฒนาการดึงคุณลักษณะสำคัญของตัวข้อมูลไม่เพียงแค่ว่า แนวนวลึก แต่ยังสนใจในแนวกว้างด้วย จึงสามารถที่จะ Capture ความสัมพันธ์ที่หลากหลายมากขึ้น อีกทั้งยังมีการใช้จุดเด่นของ Kernel size 1x1 ซึ่งทำให้สามารถช่วย Capture ความสัมพันธ์แนวนวลึกได้เป็นอย่างดี ซึ่งงานวิจัยชิ้นนี้ที่มีข้อจำกัดของความลึกของข้อมูลภาพ ส่งผลให้แบบจำลอง 3D Googlenet มีผลการทดลองที่มีประสิทธิภาพมากที่สุดในงานวิจัยชิ้นนี้ โดยที่อีกทั้ง 2 แบบจำลอง ประกอบด้วย แบบจำลอง 3D Alexnet และ 3D VGG-16 ที่มีผลการทดสอบรองลงมาตามลำดับจากแบบจำลอง 3D Googlenet ผู้วิจัยเชื่อว่าความลึกของชั้นที่ 40 ชั้น ไม่ได้ส่งผลต่อแบบจำลองทั้ง 2 แบบมากนัก เนื่องจากเป็นแบบจำลองที่ไม่ได้มีชั้นของคอนโวลูชันที่มีจำนวนมาก ต่างจากแบบจำลองคอนโวลูชันเรสเน็ต แต่ผู้วิจัยมีความเชื่อว่าตัวอย่างของข้อมูลที่มีอยู่อย่างจำกัด เป็นตัวแปรสำคัญของแบบจำลองทั้ง 2 แบบนี้ เนื่องจากแบบจำลองคอนโวลูชันขนาดเล็กซ์เน็ต และวีจีจี 16 เป็นแบบจำลองที่มีความเหมาะสมกับชุดข้อมูลที่มีปริมาณที่มาก และข้อมูลที่ครอบคลุมลักษณะสำคัญในชุดข้อมูล เนื่องจากทั้ง 2 แบบจำลองมีจุดเด่นที่ความสามารถในการจดจำลักษณะของข้อมูลได้ดี ซึ่งงานวิจัยชิ้นนี้มีข้อจำกัดในเรื่องของชุดข้อมูลที่มีอยู่อย่างจำกัด จึงอาจส่งผลให้ประสิทธิภาพของทั้ง 2 แบบจำลองแสดงประสิทธิภาพออกมาได้อย่างไม่เต็มที่

จากที่กล่าวข้างต้น เนื่องจากข้อจำกัดของจำนวนความลึกของชั้นในชุดข้อมูลภาพที่มีเพียง 40 ชั้น อาจส่งผลกระทบต่อประสิทธิภาพของแบบจำลอง 3D Resnet ที่มีความสามารถในการจัดการกับโครงข่ายที่มีความลึก อาทิเช่น Resnet-50 หรือแม้กระทั่ง Resnet -101 แต่เนื่องด้วยข้อจำกัดของความลึกของภาพที่มีเพียง 40 ชั้น เต็มที่ ซึ่งส่งผลต่อการทดสอบสมรรถนะของแบบจำลองในการแยกคุณลักษณะของรูปภาพชุดใหม่ได้ไม่ดีมากนัก ผู้วิจัยเชื่อว่านี่เป็นเหตุผลสำคัญที่ทำให้แบบจำลอง 3D Resnet ไม่สามารถแสดงประสิทธิภาพของแบบจำลองได้เต็มประสิทธิภาพ

จากผลการทดสอบทั้งสิ้น ในการวิจัยในการจำแนกคนเป็นโรคหลอดเลือดสมองโดยการใช้แบบจำลองคอนโวลูชัน 3 มิติ ในแต่ละแบบในการจำแนกแบ่งออกเป็น 2 ประเภท 1) ภาพของผู้ป่วยที่เป็นโรคหลอดเลือดสมอง และ 2) ภาพของผู้ป่วยสุขภาพปกติ ซึ่งจะเห็นได้ว่า แบบจำลอง 3D Googlenet มีประสิทธิภาพและสามารถจำแนกภาพของผู้ป่วยที่เป็นโรคหลอดเลือดสมองได้ดีกว่าแบบจำลองอื่นที่ทำการทดสอบ อีกทั้งแบบจำลองยังสามารถทำนายข้อมูลภาพที่ไม่เคยเห็นได้อย่างมีประสิทธิภาพถึงแม้จะมีข้อมูลในการเรียนรู้ที่ค่อนข้างจำกัด รวมไปถึงข้อจำกัดของจำนวนความลึกของชั้นภาพ

โดยประโยชน์ของงานวิจัยชิ้นนี้ ผู้วิจัยเชื่อว่าการประยุกต์ใช้โครงข่ายคอนโวลูชันร่วมกับรูปแบบ 3 มิติ ในการจำแนกภาพทางการแพทย์ สามารถที่จะพัฒนาต่อยอดได้ในอนาคต และสามารถช่วยให้แพทย์ลดระยะเวลาในการวินิจฉัยเบื้องต้นในการตรวจหาคนเป็นโรคทางการแพทย์ได้ อีกทั้งช่วยให้แพทย์ลดข้อผิดพลาดในการวินิจฉัยได้ โดยสามารถนำแบบจำลอง 3D Googlenet ไปเลือกใช้ในการจัดการ และพัฒนาต่อได้ ผู้วิจัยเชื่อว่า จะส่งผลให้ลดปัญหาการขาดแคลนบุคลากรทางการแพทย์ได้ และทำให้เทคโนโลยีทางการแพทย์มีคุณภาพที่ดีขึ้น

## 5.2 ข้อเสนอแนะ

งานวิจัยนี้ ได้ปรับปรุงโครงสร้างของโครงข่ายประสาทเทียมคอนโวลูชันแต่ละรูปแบบ แต่ยังคงใช้จุดเด่นของขนาดตัวกรอง และรูปแบบที่เป็นลักษณะเด่นที่ใช้ในการดึงคุณลักษณะสำคัญของแต่ละแบบจำลองไว้อยู่ ซึ่งการปรับเปลี่ยนโครงสร้าง และการนำเทคนิคของแต่ละแบบของแต่ละโครงสร้างแบบจำลองมาใช้ร่วมกัน เพื่อให้สามารถช่วยให้แบบจำลองนั้นมีประสิทธิภาพที่ดีขึ้นเมื่อใช้กับชุดข้อมูลภาพเอกซเรย์ผู้ป่วยที่เป็นโรคหลอดเลือดสมอง

ในทางกลับกัน การปรับเปลี่ยนโครงสร้างของแต่ละแบบจำลองเกิดขึ้นมาจากข้อจำกัดในเรื่องของชุดข้อมูล เนื่องจากข้อมูลที่นำมาใช้ในการทดลองครั้งนี้ เป็นข้อมูลที่มีขนาดเล็ก ซึ่งในการนำข้อมูลภาพมาใช้ในการทำนายรูปภาพโดยโครงข่ายประสาทคอนโวลูชันนั้น จะเกิดประสิทธิภาพสูงที่สุดเมื่อใช้กับข้อมูลที่มีขนาดใหญ่มาก โดยอ้างอิงจากงานวิจัยในอดีต การทดสอบกับชุดข้อมูลที่มีขนาดใหญ่ นั้นจะช่วยให้การยืนยันผลการทดลองให้มีความชัดเจน และได้ประสิทธิภาพมากขึ้น ข้อจำกัดของชุดข้อมูลในงานวิจัยครั้งนี้ไม่เพียงแต่การที่มีชุดข้อมูลขนาดเล็ก แต่ยังติดข้อจำกัดในเรื่องความลึกของข้อมูล เนื่องจากงานวิจัยครั้งนี้เป็นการนำโครงข่ายประสาทคอนโวลูชัน 3 มิติ มาใช้ในการทดลอง ทำให้ขนาดความลึกมีความสำคัญอย่างมากในโครงสร้างของแบบจำลองแต่ละแบบ แต่ข้อจำกัดความลึกที่มีเพียงจำนวน 40 ชั้น ส่งผลต่อโครงข่ายประสาทคอนโวลูชันที่มีจุดเด่นในการจัดการกับข้อมูลที่มีจำนวนหลายชั้นคอนโวลูชันแสดงประสิทธิภาพออกมาได้อย่างไม่เต็มที่ อีกทั้งงานวิจัยชิ้นนี้มีข้อจำกัดในความต้องการขจัดปัญหาการ Bias ของแต่ละแบบจำลองจึงมีการปรับโครงสร้างของแต่ละแบบจำลองรวมไปถึงชุดข้อมูลที่ใช้ในการนำเข้าสู่ซึ่งผู้วิจัยเชื่อว่ามีส่วนสำคัญที่ส่งผลให้แบบจำลองแต่ละแบบมีผลการทดลองที่ไม่เต็มประสิทธิภาพ

การประยุกต์ใช้เทคนิคอื่นมารวมกันกับการใช้โครงข่ายประสาทคอนโวลูชัน อาจส่งผลให้เกิดประสิทธิภาพที่ดีขึ้นกว่าเดิม เช่น การใช้เทคนิคการประมวลผลล่วงหน้าเพื่อขจัดความไม่คมชัดของรูปภาพบางอย่างเพื่อให้มองเห็นพื้นที่ที่ต้องการได้ดีขึ้น การใช้เทคนิคแบ่งส่วนรอยโรคสมอง การตรวจจับ และวิเคราะห์รอยโรคหลอดเลือดสมอง เพื่อให้โมเดลสามารถจำแนกภาพได้ดียิ่งขึ้น รวมไปถึงการแก้ปัญหาในการกำหนดชั้นความลึก หากมีการปรับเปลี่ยนโครงสร้างของแบบจำลองโดย

การเพิ่มชั้น Batch Normalization จะส่งผลให้แบบจำลองขจัดปัญหาของการกำหนดชั้นความลึกของแบบจำลองออกไปได้

งานวิจัยชิ้นนี้ถ้าหากมองในแง่ของการปรับปรุงประสิทธิภาพ สำหรับแนวทางการวิจัยในอนาคต หากมีการนำวิธีการ Grad-CAM ที่เป็นการไล่ระดับสีของภาพ หรือการทำ Heatmap จากข้อมูลที่แบบจำลองเรียนรู้จะทำให้สามารถสังเกตเห็นจุดที่แบบจำลองเกิดข้อผิดพลาด หรือจุดที่แบบจำลองสนใจได้ดีมากยิ่งขึ้น และสามารถนำไปพัฒนาต่อในแง่การปรับปรุงประสิทธิภาพของการเตรียมข้อมูลให้แบบจำลองเรียนรู้



## บรรณานุกรม

1. World Stroke Organization. World Stroke Organization. 2021; from <https://ncdalliance.org/world-stroke-organization-0>
2. Fartakov EI, Tarkova AR, Kretov EI, Lomivorotov VV, Zykov IS. Possibilities and prospects of hypothermia in the treatment of ischemic stroke, ResearchGate. DOI: 10.21688/1681-3472-2019-15-S18-S25; 2019.
3. Zhang H, Yang J, Guo J, Yang Z, et al. Pan Y. Identification and Diagnosis of Cerebral Stroke through Deep Convolutional Neural Network-Based Multimodal MRI Images., Hindawi XML Corpus. 2021.
4. Dickson B. What are convolutional neural networks (CNN). 2021.
5. H. Fan, X. Niu, Q. Liu, W. Luk. FPGA-based 3-dimensional convolutional neural network, in: International Conference on Field Programmable Logic and Applications (FPL). Institute of Electrical and Electronics Engineers (IEEE); 2017.
6. V. Bhanumathi, R. Sangeetha. CNN Based Training and Classification of MRI Brain Images. Institute of Electrical and Electronics Engineers (IEEE); 2019.
7. Ottesen, Jon André Yi, Darvin Tong, Elizabeth Iv, Michael Latysheva, Anna et al. 2.5D and 3D segmentation of brain metastases with deep learning on multinational MRI data.: Frontiers in Neuroinformatics; 2023.
8. A.V. Dobshik, S.K. Verbitskiy, I.A. Pestunov, K.M. Sherman, Yu.N. Sinyavskiy, A.A. Tulupov, V.B. Berikov. Acute ischemic stroke lesion segmentation in non-contrast CT images using 3D convolutional neural networks.: arXivLabs; 2023; from <https://doi.org/10.48550/arXiv.2301.06793>
9. Sparsh Mittal V. A survey of accelerator architectures for 3D convolution neural networks.: ScienceDirect; 2021; from <https://doi.org/10.1016/j.sysarc.2021.102041>
10. Liwei Tan, Hongyan Wang, Jianli Meng Shuhao Xu. Stroke Lesion Detection and Analysis in MRI Images Based on Deep Learning. Hindawi2021.
11. Balasubramanian Raman, Anjali Gautam. Towards effective classification of brain hemorrhagic and ischemic stroke using CNN. ScienceDirect; 2021.

12. Anurag Bhardwaj, J.W., and Wei Di. Deep Learning Essentials: Your Hands-on Guide to the Fundamentals of Deep Learning and Neural Network Modeling. Packt Publishing; 2018.
13. Lovekesh Vig, Michele De Filippo De Grazia, Maurizio Corbetta, Shandar Ahmad1 and Marco Zorzi Sucheta Chauhan1. A Comparison of Shallow and Deep Learning Methods for Predicting Cognitive Performance of Stroke Patients From MRI Lesion Images, Front in Neuroinform. 2019; from <https://doi.org/10.3389/fninf.2019.00053>
14. Hassan Mu. VGG16 – Convolutional Network for Classification and Detection. 2018; from <https://neurohive.io/en/popular-networks/vgg16/>
15. Andrew Zisserman Karen Simonyan. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv. 1409.1556; 2015.
16. Ilya Sutskever, Geoffrey E. Hinton. Alex Krizhevsky. ImageNet Classification with Deep Convolutional Neural Networks. ACM Digital Library. 2017; from <https://doi.org/10.1145/3065386>
17. Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. Szegedy C. Going deeper with convolutions. Institute of Electrical and Electronics Engineers (IEEE); 2015.
18. Xiangyu Zhang, Shaoqing Ren, Jian Sun Kaiming He. Deep Residual Learning for Image Recognition. Institute of Electrical and Electronics Engineers (IEEE); 2015.
19. Sivaram T. All You Need to Know About Skip Connections. Analytics Vidhya; 2021.
20. Sharma. A. A. Confusion Matrix in Machine Learning. GeeksforGeeks; 2020; from <https://www.geeksforgeeks.org/confusion-matrix-machine-learning/>
21. Jungyoon Kim, Jihye Lim, Songhee Cheon. The Use of Deep Learning to Predict Stroke Patient Mortality. MDPI. 2019; from <https://doi.org/10.3390/ijerph16111876>
22. Ravindra Kr. Purwar, Varun Srivastava. Classification of CT Scan Images of Lungs Using Deep Convolutional Neural Network with External Shape-Based Features. Springer; 2019.
23. Sofat Sanjeev, Kaur Simranpreet Hooda Rahul, Meriaudeau Fabrice Mitta Ajay. Deep-learning: A potential method for tuberculosis detection using chest radiography.

Institute of Electrical and Electronics Engineers (IEEE); 2017.

24. Markus Ojala, Gemma C. Garriga. Permutation Tests for Studying Classifier Performance. Institute of Electrical and Electronics Engineers (IEEE); 2009.
25. Pushpendra Singh, Shiv DuttJoshi, Narendra Kumar Mishra. Automated detection of COVID-19 from CT scan using convolutional neural network. ScienceDirect; 2021.
26. Aurélien Géron. Hands-On Machine Learning with Scikit-Learn and TensorFlow. 2<sup>nd</sup>. O'Reilly Media, Inc.; 2019.
27. Gonzalez, Rafael C., Woods, Richard E. Digital Image Processing. 3<sup>rd</sup>. Pearson; 2007.
28. Fabian Pedregosa, et al. Scikit-learn: Machine learning in Python. the Journal of machine Learning research. 2011: 2825-30.
29. Andrew Maranhão Ventura Dadário, Joselisa Péres Queiroz Paiva, Rodrigo Caruso Chate, Birajara Soares Machado, corresponding author and Gilberto Szarf. Artificial Intelligence Distinguishes COVID-19 from Community Acquired Pneumonia on Chest CT. PubMed Central; 2020.
30. Olli Ojanen, Teemu Makkela, Eero Salli, Sauli Savolainen & Marko Kangasniemi. 3D convolutional neural networks applied to CT angiography in the detection of acute ischemic stroke. 2019. จุฬาลงกรณ์มหาวิทยาลัย
31. Wangxia Zuo, Fuqiang Zhou, Yuzhu He, Xiaosong Li. Automatic classification of lung nodule candidates based on a novel 3D convolution network and knowledge transferred from a 2D network., American Association of Physicists in Medicine. 2019; from <https://doi.org/10.1002/mp.13867>
32. Hao Yang, Cheng Li, Zaiyi Liu, Meiyun Wang, Qiegen Liu, Shanshan Wang Kehan Qi. X-Net: Brain Stroke Lesion Segmentation Based on Depthwise Separable Convolution and Long-Range Dependencies. 2019.
33. Pinki Roy, Sivaji Bandyopadhyay, Sujit Kumar Das. Identifying COVID19 from Chest CT Images: A Deep Convolutional Neural Networks Based Approach. Hindawi. 2020; from <https://doi.org/10.1155/2020/8843664>



34. Deepak Kumar Sharma, Mayukh Chatterjee, Gurmehak Kaur, Suchitha Vavilala. (),  
Deep Learning for Medical Applications with Unique Data. ScienceDirect; 2022.



## ประวัติผู้เขียน

ชื่อ-สกุล	ชานนท์ วรโชติสีบตระกูล
วัน เดือน ปี เกิด	15 November 1995
วุฒิการศึกษา	2561 เศรษฐศาสตร์บัณฑิต คณะเศรษฐศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ที่อยู่ปัจจุบัน	19/129 หมู่บ้านปรีญดา ถนนกาญจนาภิเษก เขตบางแค แขวงบางแค กรุงเทพมหานคร 10160



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY