



การจำแนกผลตรวจจากภาพแมมโมแกรมด้วยการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ

BI-RADS CLASSIFICATION IN MAMMOGRAM USING
DEEP CONVOLUTIONAL NEURAL NETWORK

จุฑามาศ คุณณา

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2566

การจำแนกผลตรวจจากภาพแมมโมแกรมด้วยการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ



จุฑามาศ คุณา

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

BI-RADS CLASSIFICATION IN MAMMOGRAM USING
DEEP CONVOLUTIONAL NEURAL NETWORK



JUTAMAS KHUTCHA

A Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์
เรื่อง
การจำแนกผลตรวจจากภาพแมมโมแกรมด้วยการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ
ของ
จุฑามาศ คุณณา

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)
คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก
(อาจารย์ ดร.โสภณ มงคลลักษณ์)

..... ประธาน
(รองศาสตราจารย์ ดร.อรรณพ หมั่นสกุล)

..... ที่ปรึกษาร่วม
(รองศาสตราจารย์ ดร.วรพันธ์ คู่สกุลนิรันดร์)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การจำแนกผลตรวจจากภาพแมมโมแกรมด้วยการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ
ผู้วิจัย	จุฑามาศ คุตตา
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	อาจารย์ ดร. โสภณ มงคลลักษณ์
อาจารย์ที่ปรึกษาร่วม	รองศาสตราจารย์ ดร. วรพันธ์ คุ้มสกุลนิรันดร์

มะเร็งเต้านมเป็นมะเร็งที่พบบ่อยที่สุดในเพศหญิง การตรวจคัดกรองมะเร็งเต้านมด้วยเครื่องดิจิตอลแมมโมแกรมเป็นวิธีที่ดีที่สุดในการค้นพบความผิดปกติได้ตั้งแต่ระยะเริ่มแรกและสามารถรักษาให้หายขาดได้ งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อสร้างแบบจำลองการจำแนกความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS 5 Classes (BI-RADS 1,2,3,4,5) จากภาพแมมโมแกรมด้วยการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Deep Convolutional Neural Networks : CNN) และเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) ร่วมกับการทดลองสร้างแบบจำลองการจำแนกความหนาแน่นของเต้านม (Density) โดยใช้ชุดข้อมูลภาพแมมโมแกรมด้านตรง (Craniocaudal View : CC) จาก VinDR-Mammo ผ่านกระบวนการจัดเตรียมข้อมูลภาพด้วยการแบ่งส่วนเต้านมออกจากพื้นหลัง (Segmentation Largest Contour) แก้ไขปัญหาความไม่สมดุลของข้อมูล รวมถึงการเสริมข้อมูล จากนั้นใช้เทคนิคการถ่ายโอนความรู้ (Transfer Learning) จาก VGG16 และ ResNet50 เพื่อสร้างแบบจำลอง ผลการวิจัย พบว่าการสร้างแบบจำลอง Deep Convolutional Neural Networks ด้วยการ Transfer Learning โดยใช้ pre-trained model จาก ResNet50 มีความแม่นยำโดยรวมดีกว่า VGG16 โดยที่ค่า Accuracy เท่ากับ 40% และ 37% ตามลำดับ ในการจำแนกความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View และเมื่อพิจารณาใน BI-RADS Classes พบว่า ทั้ง ResNet50 และ VGG16 สามารถทำนาย BI-RADS 5 ได้มีประสิทธิภาพดีที่สุด โดยที่ค่า Recall เท่ากับ 65% และ 59% ตามลำดับ แสดงให้เห็นว่าภาพแมมโมแกรม BI-RADS 5 มีรอยโรคชัดเจนที่สุด อีกทั้งการที่แบบจำลองสามารถจำแนก BI-RADS ได้มีความแม่นยำโดยรวมน้อยกว่าจำแนกความหนาแน่นเต้านม เพราะ คุณลักษณะสำคัญของรอยโรคเต้านมใน BI-RADS มีขนาดเล็ก ดังนั้นจึงขอแนะนำการจำแนก BI-RADS กับการทำ Segmentation Region of Interest (ROI) ร่วมด้วยเพื่อพัฒนาประสิทธิภาพของแบบจำลอง

คำสำคัญ : การรายงานผลแมมโมแกรม, การถ่ายโอนความรู้, โครงข่ายประสาทเทียมแบบสังวัตนาการ, ภาพแมมโมแกรม, มะเร็งเต้านม

Title	BI-RADS CLASSIFICATION IN MAMMOGRAM USING DEEP CONVOLUTIONAL NEURAL NETWORK
Author	JUTAMAS KHUTCHA
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Dr. Sophon Mongkolluksamee
Co Advisor	Associate Professor Dr. Worapan Kusakunniran

Breast cancer is the most common cancer among women. The most common screening technology is digital mammography, which is the best method for detecting abnormalities early and providing effective treatment. This study aims to develop a model for classifying the risk of breast lesions based on the BI-RADS 5 Classes (BI-RADS 1, 2, 3, 4, 5) criteria using a craniocaudal view (CC) mammogram from the VinDR-Mammo dataset. The data preprocessing involves segmenting the largest contour, data imbalance issues, and data augmentation. Then, transfer learning techniques from VGG16 and ResNet50 are employed to build the models. The research findings indicate that building deep convolutional neural network models using transfer learning with pre-trained models from ResNet50 yields better overall accuracy compared to VGG16, with accuracies of 40% and 37%, respectively. In predicting the risk levels of breast lesions according to BI-RADS criteria from Full-Field Mammogram CC View, both ResNet50 and VGG16 perform best in predicting BI-RADS 5 lesions, with recalls of 65% and 59%, respectively. This suggests that BI-RADS5 lesions exhibit the most distinct characteristics on mammogram images. Furthermore, the overall accuracy of the model in predicting BI-RADS is lower compared to predict breast density, as important features of breast lesions in BI-RADS are small. Therefore, combining BI-RADS classification with region of interest (ROI) segmentation is recommended to improve model performance.

Keyword : BI-RADS, breast cancer, deep convolutional neural network, mammogram, transfer learning

กิตติกรรมประกาศ

สารนิพนธ์นี้สำเร็จลุล่วงไปได้ด้วยความกรุณาของ อาจารย์ ดร.โสภณ มงคลลักษณ์ อาจารย์ที่ปรึกษาหลัก ขอกราบขอบพระคุณท่านที่ได้เสียสละเวลาอันมีค่าในการให้คำปรึกษา คำแนะนำ และข้อเสนอแนะที่เป็นประโยชน์อย่างยิ่งในการจัดทำสารนิพนธ์ฉบับนี้ รวมถึงกรุณาติดตาม สอบถาม และให้ความช่วยเหลือจนสารนิพนธ์ฉบับนี้สำเร็จสมบูรณ์

ขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.วพันธ์ คู่สกุลนิรันดร์ อาจารย์ที่ปรึกษาร่วม ที่ได้ให้คำปรึกษา คำแนะนำเกี่ยวกับแนวทางในการศึกษาเรื่อง Medical Image Classification รวมถึงข้อเสนอแนะในการทำวิจัยครั้งนี้จนสำเร็จ

ขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.อรรณพ หมั่นสกุล และ ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ ที่ได้กรุณาเป็นคณะกรรมการสอบสารนิพนธ์ฉบับนี้ รวมถึงให้ข้อเสนอแนะในการปรับปรุงแก้ไขข้อบกพร่องในสารนิพนธ์ฉบับนี้จนเสร็จสมบูรณ์

ขอขอบพระคุณ อาจารย์ประจำหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ที่คอยให้ความรู้และสนับสนุนเป็นอย่างดี

ขอขอบคุณ เพื่อนร่วมชั้นเรียน ที่คอยให้คำปรึกษา ให้กำลังใจ รวมถึงให้ความช่วยเหลือในทุก ๆ เรื่อง จนสามารถดำเนินการให้สารนิพนธ์ฉบับนี้เสร็จสมบูรณ์ได้

สุดท้ายนี้ขอกราบขอบพระคุณ คุณพ่อ คุณแม่ น้องชาย และน้องสาว ที่คอยให้กำลังใจในการทำสารนิพนธ์ฉบับนี้จนสำเร็จ

จุฑามาศ คุณา

สารบัญ

หน้า

บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ	ฎ
บทที่ 1 บทนำ.....	1
1.1 ความสำคัญและความเป็นมาของงานวิจัย.....	1
1.2 วัตถุประสงค์ของงานวิจัย	3
1.3 ขอบเขตของการวิจัย	3
1.4 กรอบแนวคิดในการวิจัย	3
1.5 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย	4
บทที่ 2 วรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 การตรวจเต้านมด้วยวิธีแมมโมแกรม (Mammogram)	5
2.2 การรายงานผลการตรวจ Mammogram โดยใช้ระบบThe Breast Imaging Reporting and Data system (BI-RADS)	6
2.3 ทฤษฎีเกี่ยวกับการเตรียมข้อมูล (Data Preprocessing)	8
2.3.1 การทำความสะอาดข้อมูล (Data Cleansing)	8
2.3.2 การจัดการความไม่สมดุลกันของข้อมูล (Imbalanced Data)	9
2.3.3 การเสริมข้อมูล (Data Augmentation)	10

2.4 ทฤษฎีเกี่ยวกับอัลกอริทึมการจำแนกประเภทข้อมูลภาพ (Image Classification Algorithm)	11
2.4.1 ทฤษฎีการเรียนรู้เชิงลึก Deep learning	11
2.4.2 ทฤษฎีการ Transfer Learning	12
2.4.3 การปรับแต่งแบบจำลอง (Tuning) และ Hyperparameters	16
2.5 การวัดประสิทธิภาพของแบบจำลอง (Model Evaluation)	17
2.6 งานวิจัยที่เกี่ยวข้อง	19
บทที่ 3 การดำเนินงานวิจัย	27
3.1 กระบวนการทำงานของแบบจำลอง	27
3.2 ชุดข้อมูล (Dataset)	28
3.3 การสำรวจข้อมูล (Exploratory Data Analysis : EDA)	28
3.4 การเตรียมข้อมูล	35
3.4.1 การครอบตัดรูปภาพต้นฉบับ	36
3.4.2 การใช้ตัวกรองค่ามัธยฐานเพื่อลบจุดรบกวน	36
3.4.3 การทำมาสก์ด้านม	36
3.4.4 การใช้มาสก์ด้านมกับภาพต้นฉบับ	36
3.4.5 การครอบตัดตามขนาดรูปร่างที่ใหญ่ที่สุด	36
3.4.6 การสร้างภาพสีเหลี่ยมจัตุรัส	37
3.4.7 การจัดการความไม่สมดุลของข้อมูลภาพ	37
3.4.8 การแบ่งชุดข้อมูล	38
3.4.9 การเสริมข้อมูล	39
3.5 การสร้างแบบจำลอง	40
3.6 การวัดประสิทธิภาพของแบบจำลอง	43

บทที่ 4 ผลการดำเนินงานวิจัย	44
4.1 ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram	44
4.2 ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram ที่มีการ ปรับแต่งแบบจำลอง (Tuning).....	48
4.3 เปรียบเทียบการทำงานของแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) และประเมินประสิทธิภาพของแบบจำลองแต่ละชนิด	51
4.4 ผลลัพธ์ของการจำแนกระดับ Density จากภาพ Full-Field Mammogram	52
บทที่ 5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	58
5.1 สรุปผลการวิจัยและอภิปรายผล	58
5.2 ข้อเสนอแนะ	61
บรรณานุกรม	62
ประวัติผู้เขียน.....	66

สารบัญตาราง

	หน้า
ตาราง 1 จำนวนภาพ Full-Field Mammogram จำแนกตาม BI-RADS 1-5	29
ตาราง 2 Hyperparameters ที่สำคัญในการการสร้างแบบจำลอง	40
ตาราง 3 โครงสร้าง VGG16 with pre-trained Model	41
ตาราง 4 โครงสร้าง ResNet50 with pre-trained Model	41
ตาราง 5 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก VGG16.....	45
ตาราง 6 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก ResNet50	46
ตาราง 7 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก VGG16 Tuning	48
ตาราง 8 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก ResNet50 Tuning	50
ตาราง 9 ผลลัพธ์การเปรียบเทียบการทำงานของแบบจำลองการจำแนกระดับ BI-RADS และ ประเมินประสิทธิภาพของแบบจำลอง	52
ตาราง 10 ผลลัพธ์ที่ได้จากการทดลองจำแนกระดับความหนาแน่นเต้านม (Density) ด้วยการ Transfer Learning จาก VGG16	52
ตาราง 11 ผลลัพธ์ที่ได้จากการทดลองจำแนกระดับความหนาแน่นเต้านม (Density) ด้วยการ Transfer Learning จาก VGG16 with CLAHE.....	55
ตาราง 12 ผลลัพธ์การเปรียบเทียบการทำงานของแบบจำลองการจำแนกระดับ Density และ ประเมินประสิทธิภาพของแบบจำลอง	56

สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 ตัวอย่างภาพถ่ายเต้านมด้วยวิธีแมมโมแกรม	6
ภาพประกอบ 2 ตัวอย่างลักษณะความหนาแน่นของเต้านม (Breast Density)	7
ภาพประกอบ 3 เทคนิคการจัดการความไม่สมดุลกันของข้อมูล (Imbalanced Data)	10
ภาพประกอบ 4 กระบวนการทำงานของ Deep Convolutional neural networks	12
ภาพประกอบ 5 โครงสร้าง ResNet50	14
ภาพประกอบ 6 โครงสร้าง VGG16	15
ภาพประกอบ 7 ลักษณะตารางของ Confusion Matrix	18
ภาพประกอบ 8 Mammogram papers Tasks (Abdelrahman et al., 2021)	22
ภาพประกอบ 9 Augmentation Method (Rafid et al., 2022)	23
ภาพประกอบ 10 Confusion Matrix (K.-J. Tsai et al., 2022)	25
ภาพประกอบ 11 Performance Model (K.-J. Tsai et al., 2022)	25
ภาพประกอบ 12 Flow diagram of BI-RADS Classification in Mammogram using Deep Convolutional Neural Network	27
ภาพประกอบ 13 จำนวนภาพ Full-Field Mammogram จำแนกตาม BI-RADS 1-5	29
ภาพประกอบ 14 ตัวอย่างภาพ Full-Field Mammogram CC View และ MLO View	30
ภาพประกอบ 15 จำนวนภาพ Full-Field Mammogram CC View	30
ภาพประกอบ 16 ตัวอย่างภาพ Mammogram CC View BI-RADS 1	31
ภาพประกอบ 17 ตัวอย่างภาพ Mammogram CC View BI-RADS 2	31
ภาพประกอบ 18 ตัวอย่างภาพ Mammogram CC View BI-RADS 3	31
ภาพประกอบ 19 ตัวอย่างภาพ Mammogram CC View BI-RADS 4	32
ภาพประกอบ 20 ตัวอย่างภาพ Mammogram CC View BI-RADS 5	32

ภาพประกอบ 21 จำนวนภาพ Full-Field Mammogram จำแนกตาม BI-RADS 1-5 และ Density Level	33
ภาพประกอบ 22 Mammogram CC View BI-RADS 1 Density C	33
ภาพประกอบ 23 Mammogram CC View BI-RADS 2 Density C	34
ภาพประกอบ 24 Mammogram CC View BI-RADS 3 Density C	34
ภาพประกอบ 25 Mammogram CC View BI-RADS 4 Density C	34
ภาพประกอบ 26 Mammogram CC View BI-RADS 5 Density C	35
ภาพประกอบ 27 Data Explorer Kaggle : VinDr-Mammo dataset.....	35
ภาพประกอบ 28 Processed_Images folder structure	36
ภาพประกอบ 29 ตัวอย่างผลลัพธ์ของการปรับปรุงข้อมูลภาพ Full-Field Mammogram สำหรับขั้นตอน 3.4.1-3.4.6	37
ภาพประกอบ 30 จำนวนข้อมูลที่ผ่านการทำ Random Undersampling	37
ภาพประกอบ 31 การแบ่งชุดข้อมูล	38
ภาพประกอบ 32 Dataset folder structure.....	38
ภาพประกอบ 33 การเสริมข้อมูล (Data Augmentation)	39
ภาพประกอบ 34 ตัวอย่างข้อมูลภาพจากการทำ Data Augmentation	40
ภาพประกอบ 35 ตัวอย่าง Source Code ทำการ Tuning Model.....	42
ภาพประกอบ 36 Small Data Set for Classify Density	43
ภาพประกอบ 37 Confusion Matrix ด้วยการ Transfer Learning จาก VGG16 ในการจำแนก ระดับ BI-RADS	45
ภาพประกอบ 38 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก VGG16 ในการจำแนก ระดับ BI-RADS	46
ภาพประกอบ 39 Confusion Matrix ด้วยการ Transfer Learning จาก ResNet50 ในการจำแนก ระดับ BI-RADS	47

ภาพประกอบ 40 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก ResNet50 ในการ จำแนกระดับ BI-RADS	47
ภาพประกอบ 41 Confusion Matrix ด้วยการ Transfer Learning จาก VGG16 Tuning ในการ จำแนกระดับ BI-RADS	49
ภาพประกอบ 42 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก VGG16 Tuning ในการ จำแนกระดับ BI-RADS	49
ภาพประกอบ 43 Confusion Matrix ด้วยการ Transfer Learning จาก ResNet50 Tuning ใน การจำแนกระดับ BI-RADS.....	50
ภาพประกอบ 44 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก ResNet50 Tuning ใน การจำแนกระดับ BI-RADS.....	51
ภาพประกอบ 45 Confusion Matrix ด้วยการ Transfer Learning จาก VGG16 ในการจำแนก ระดับ Density	53
ภาพประกอบ 46 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก VGG16 ในการจำแนก ระดับ Density	54
ภาพประกอบ 47 Confusion Matrix ด้วยการ Transfer Learning จาก VGG16 with CLAHE ใน การจำแนกระดับ Density.....	55
ภาพประกอบ 48 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก VGG16 with CLAHE ในการจำแนกระดับ Density.....	56

บทที่ 1

บทนำ

1.1 ความสำคัญและความเป็นมาของงานวิจัย

มะเร็งเต้านมเป็นมะเร็งที่พบบ่อยที่สุดในเพศหญิงและเป็น 1 ใน 5 อันดับแรกของสาเหตุการเสียชีวิตด้วยโรคมะเร็งของคนทั่วโลก การตรวจหามะเร็งเต้านมในระยะเริ่มต้นจะสามารถรักษาให้หายขาดและเพิ่มอัตราการรอดชีวิตได้ ซึ่งจากการดำเนินของโรคมะเร็งเต้านมนั้นผู้ป่วยมักจะไม่มีอาการผิดปกติ โดยเฉพาะในระยะเริ่มแรกมักไม่มีอาการเจ็บปวด แต่หากสามารถตรวจพบก้อนเนื้อที่เป็นมะเร็งได้ตั้งแต่วัยแรกซึ่งขนาดของก้อนเนื้อยังมีขนาดเล็ก และก้อนเนื้อยังอยู่เฉพาะที่เต้านมยังไม่พบการแพร่กระจายไปยังอวัยวะอื่น ๆ จะทำให้การรักษามีโอกาสหายขาดได้มากกว่าเมื่อเทียบกับการตรวจแล้วพบว่าก้อนเนื้อมีขนาดใหญ่และแพร่กระจายไปยังอวัยวะอื่น ๆ แล้ว ดังนั้นผู้หญิงจึงมีความจำเป็นและสำคัญเป็นอย่างมากที่ต้องทำการตรวจคัดกรองมะเร็งเต้านมอย่างสม่ำเสมอ อย่างไรก็ตามการวินิจฉัยมะเร็งเต้านมนั้นจะใช้การแสดงร่วมกับการตรวจทางรังสีวิทยา ได้แก่ การทำแมมโมแกรม (Mammogram) และอัลตราซาวด์ (Ultrasound) เป็นหลัก

การตรวจเต้านมด้วยวิธีแมมโมแกรม เป็นวิธีการที่น่าเชื่อถือในการตรวจหาความผิดปกติในเต้านม โดยเป็นการตรวจทางรังสีชนิดพิเศษคล้ายการตรวจเอกซเรย์ มีประสิทธิภาพในการตรวจมะเร็งเต้านมได้ตั้งแต่วัยเริ่มแรก ทำให้การรักษาได้ผลดีและเป็นไปอย่างมีประสิทธิภาพ การตรวจแมมโมแกรมเป็นวิธีตรวจคัดกรองมะเร็งเต้านมที่น่าเชื่อถือที่สุดในปัจจุบัน สามารถตรวจพบลักษณะผิดปกติในเต้านมหรือรอยโรคที่มีขนาดเล็กได้ ในการตรวจเต้านมด้วยวิธีแมมโมแกรมจะมีวัตถุประสงค์อยู่ 2 อย่าง คือ การตรวจเพื่อคัดกรองสำหรับกลุ่มที่ไม่มีอาการ และการตรวจเพื่อวินิจฉัยสำหรับติดตามการรักษาของผู้ป่วยที่ตรวจพบความผิดปกติที่เต้านม ตามปกติแล้วในการตรวจแมมโมแกรมนั้น จะทำการตรวจอยู่ 2 ท่า คือ ภาพถ่ายเต้านมด้านตรง (Cranio-caudal view - CC) และแนวเอียง (Mediolateral oblique view - MLO)

ปัจจุบันการรายงานผลการตรวจ Mammogram ใช้ระบบ The Breast Imaging Reporting and Data system (BI-RADS) ซึ่งถูกพัฒนาขึ้นโดย The American College of Radiology to standardize mammographic reporting โดยประเมินจากความเสี่ยงต่อการเป็นมะเร็งในแต่ละกลุ่มมาช่วยในการตัดสินใจส่งตรวจชิ้นเนื้อ แม้การตรวจแมมโมแกรมจะเป็นวิธีคัดกรองมะเร็งเต้านมที่มีประสิทธิภาพสูงสุดในปัจจุบันแต่ก็มีค่าใช้จ่ายสูงค่อนข้างสูง

เพราะส่วนใหญ่รังสีแพทย์มักจะทำการตรวจแมมโมแกรมร่วมกับอัลตราซาวนด์ เพื่อการแปลผล BI-RADS ที่แม่นยำ ส่งผลให้ประชาชนกลุ่มเสี่ยงที่ขาดแคลนทุนทรัพย์ไม่สามารถเข้าถึงได้ การตรวจคัดกรองมะเร็งเต้านมด้วยวิธีแมมโมแกรม ได้จนเกิดการละเลยไปจนก่อนนี้อาจกลายเป็นมะเร็งได้ รวมถึงปัญหาการขาดแคลนรังสีแพทย์ที่มาแปลผลการตรวจแมมโมแกรมนั้นไม่เพียงพอต่อผู้รับบริการ

จากที่กล่าวมาข้างต้นด้วยความท้าทายของภาพแมมโมแกรมที่รอยโรคมีขนาดเล็กมาก ทำให้เกิดความยากลำบากในการตีความผลลัพธ์สำหรับรังสีแพทย์ จึงมักทำการตรวจอัลตราซาวนด์ร่วมด้วย เพื่อประเมินระดับความเสี่ยงของรอยโรคที่ตรวจพบในเต้านมได้แม่นยำมากขึ้น เนื่องจากความผิดปกติบางอย่าง สำหรับการวินิจฉัยด้วยการมองภาพแมมโมแกรมของรังสีแพทย์นั้น บางมุมอาจต้องใช้การมองจากภาพอัลตราซาวนด์ร่วมด้วย จะทำให้แปลผลระดับความผิดปกติของรอยโรคเต้านมได้แม่นยำมากยิ่งขึ้น แต่ด้วยความก้าวหน้าของเทคโนโลยีทำให้ขีดความสามารถในการแยกแยะภาพของคอมพิวเตอร์ (Computer Vision) นั้น ไม่ได้ด้อยไปกว่าความสามารถของมนุษย์ซึ่งปัจจุบันมีการพัฒนาและนำมาประยุกต์ใช้อย่างแพร่หลายในวงการแพทย์ รวมไปถึงความสามารถของปัญญาประดิษฐ์โดยใช้โครงข่ายประสาทเทียม (Deep Learning) สามารถสกัดคุณลักษณะอัตโนมัติ (Automate Feature Extraction) จากข้อมูลได้ ทำให้เหมาะสำหรับการตรวจหาความผิดปกติจากภาพแมมโมแกรมและจำแนกระดับความเสี่ยงของรอยโรคจากภาพได้อย่างแม่นยำ

ในงานวิจัยนี้ผู้วิจัยมีความสนใจที่จะนำเสนอการสร้างแบบจำลองระบบคอมพิวเตอร์ที่สามารถเรียนรู้ได้ด้วยตนเองโดยใช้ข้อมูล (Machine Learning Model) ที่สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม โดยใช้เทคนิคโครงข่ายประสาทแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Networks : CNN) จะสามารถบรรเทาช่วยให้ประชาชนกลุ่มเสี่ยงส่วนใหญ่ที่เข้ามาตรวจคัดกรองด้วยแมมโมแกรมที่มีผลการตรวจเป็นปกติไม่จำเป็นต้องตรวจอัลตราซาวนด์ควบคู่กันอีกต่อไป ซึ่งจะช่วยลดภาระรังสีแพทย์ในการตรวจอัลตราซาวนด์ที่ไม่จำเป็นลงได้ ทำให้แพทย์มีเวลาในการตรวจผู้ป่วยที่มีรอยโรคต้องสงสัยเสี่ยงเป็นโรคมะเร็งได้มากขึ้น อีกทั้งยังช่วยบรรเทาภาระให้ค่าใช้จ่ายในการตรวจสุขภาพ และสามารถเข้าถึงการคัดกรองมะเร็งเต้านมด้วยวิธีแมมโมแกรมได้มากขึ้น ช่วยเพิ่มโอกาสในการตรวจพบมะเร็งตั้งแต่ระยะเริ่มแรกและได้รับผลลัพธ์ที่ดีขึ้นในการรักษา

1.2 วัตถุประสงค์ของงานวิจัย

ในการวิจัยครั้งนี้ผู้วิจัยได้กำหนดเป้าหมายไว้ดังนี้

1. เพื่อสร้างแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) ที่สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม โดยใช้เทคนิค Deep Convolutional Neural Networks (CNN)
2. เพื่อเปรียบเทียบการทำงานของแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) และประเมินประสิทธิภาพของแบบจำลองแต่ละชนิด

1.3 ขอบเขตของการวิจัย

1. งานวิจัยนี้ใช้ข้อมูลภาพแมมโมแกรม (Mammogram) จาก Open Dataset VinDr-Mammo (Vietnamese dataset of digital mammography)) ที่เป็นภาพ Full-Field Mammogram CC View
2. ปรับปรุงข้อมูลภาพแมมโมแกรม โดยใช้เทคนิคสำหรับการจัดการความไม่สมดุลกันของข้อมูล (Imbalanced Data), การแบ่งส่วนภาพเต้านม (Largest Contour Segmentation) และการเสริมข้อมูล (Data Augmentation)
3. ใช้เทคนิค Deep Convolutional Neural Networks (CNN) เพื่อจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม
4. ใช้ภาพแมมโมแกรม ที่มีระดับความผิดปกติเป็น BI-RADS 1 ถึง BI-RADS 5

1.4 กรอบแนวคิดในการวิจัย

การพัฒนาแบบจำลองเพื่อจำแนกระดับความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม จะแบ่งออกเป็น 3 ขั้นตอนหลักๆ ดังนี้

ขั้นตอนแรกทำการนำเข้าข้อมูลภาพแมมโมแกรม ตามกลุ่มเป้าหมายระดับความเสี่ยงของรอยโรคเต้านม BI-RADS 1 – 5 หลังจากนั้นทำการสำรวจข้อมูลในมุมมองต่าง ๆ (Exploratory Data Analysis : EDA)

ขั้นตอนที่สองจะมุ่งเน้นไปที่การเตรียมข้อมูล (Image Pre-processing) ด้วยการการแบ่งส่วนภาพเต้านม (Largest Contour Segmentation) และแก้ปัญหาความไม่สมดุลกันของข้อมูล (Imbalance Data) ด้วยการใช้เทคนิค Under-Sampling หลังจากนั้นทำการเสริมข้อมูล (Data Augmentation)

ขั้นตอนสุดท้ายจะมุ่งเน้นไปที่การพัฒนาแบบจำลองการทำนายระดับความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม ซึ่งเป็นปัญหาแบบการจำแนกหลายประเภท (Multi-Class Classification) ประกอบไปด้วย BI-RADS 1, BI-RADS 2, BI-RADS 3, BI-RADS 4 และ BI-RADS 5 โดยใช้โครงข่ายประสาทแบบคอนโวลูชันเชิงลึกประกอบด้วยแบบจำลอง ResNet50 และ VGG16 โดยทำการแบ่งข้อมูลออกเป็น Training 80% ของข้อมูลทั้งหมดเพื่อนำไปสร้างแบบจำลอง และ Testing 20% (Test 10% , Validation 10%) ของข้อมูลทั้งหมดเพื่อนำไปทดสอบแบบจำลอง จากนั้นประเมินประสิทธิภาพของแบบจำลองโดยใช้ Classification report , Confusion Matrix เพื่อดำหนดค่า Accuracy, Recall และ F1-Score

1.5 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย

1. สามารถนำแบบจำลองไปใช้ในการทำนายระดับความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม ได้โดยอัตโนมัติ
2. แบบจำลองการทำนายระดับความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม สามารถช่วยลดภาระรังสีแพทย์ในการตรวจอัลตราซาวนด์ ที่ไม่จำเป็นลงได้ ทำให้แพทย์มีเวลาในการตรวจผู้ป่วยที่มีรอยโรคต้องสงสัยเสี่ยงเป็นโรคมะเร็งได้มากขึ้น
3. ทำให้ภาระค่าใช้จ่ายในการตรวจเช็คสุขภาพถูกลง และสามารถเข้าถึงการคัดกรองมะเร็งเต้านมด้วยวิธีแมมโมแกรมได้มากขึ้น ช่วยเพิ่มโอกาสในการตรวจพบมะเร็งตั้งแต่ระยะเริ่มแรก เพื่อให้ได้รับผลลัพธ์ที่ดีขึ้นในการรักษา

บทที่ 2

วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในการวิจัยครั้งนี้ ผู้วิจัยได้ศึกษาเอกสารทฤษฎีและงานวิจัยที่เกี่ยวข้องกับการพัฒนาแบบจำลองในการทำนายระดับความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS ด้วยภาพ Mammogram และได้นำเสนอตามหัวข้อ ดังต่อไปนี้

2.1 การตรวจเต้านมด้วยวิธีแมมโมแกรม (Mammogram)

2.2 การรายงานผลการตรวจแมมโมแกรม Mammogram โดยใช้ระบบ The Breast Imaging Reporting and Data system (BI-RADS)

2.3 ทฤษฎีเกี่ยวกับการเตรียมข้อมูล (Data Preprocessing)

2.4 ทฤษฎีเกี่ยวกับอัลกอริทึมการจำแนกประเภทข้อมูลภาพ (Image Classification Algorithm)


2.5 การวัดประสิทธิภาพของแบบจำลอง (Model Evaluation)

2.6 งานวิจัยที่เกี่ยวข้อง

2.1 การตรวจเต้านมด้วยวิธีแมมโมแกรม (Mammogram)


การตรวจคัดกรองโรคมะเร็งเต้านมเป็นการตรวจค้นหา มะเร็งเต้านมระยะเริ่มแรกในผู้ที่ ยังไม่มีอาการของโรค เพื่อวินิจฉัยและรักษาตั้งแต่ระยะเริ่มต้นของโรค ทำให้ลดอัตราการเสียชีวิต จากโรคมะเร็งได้ วิธีการตรวจคัดกรองเพื่อค้นหา มะเร็งเต้านมนั้น มีอยู่ 3 วิธี ได้แก่ การตรวจเต้านม ด้วยตนเอง การตรวจเต้านมโดยแพทย์หรือบุคลากรทางการแพทย์ที่ได้รับการฝึกอบรม และการ ตรวจด้วยเครื่องถ่ายภาพรังสีเต้านม นั่นคือ การตรวจด้วยวิธีแมมโมแกรม (Mammogram) ซึ่งเป็นวิธีคัดกรองที่ใช้อย่างแพร่หลาย โดยการตรวจคัดกรองมะเร็งเต้านมด้วยวิธีแมมโมแกรมนั้น เป็นการตรวจทางรังสีชนิดหนึ่งคล้ายกับการเอกซเรย์แต่มีปริมาณรังสีน้อยกว่ารังสีจากการ เอกซเรย์ทั่วไปหลายเท่า จึงทำให้ไม่กระจายรังสีไปยังอวัยวะอื่นของร่างกาย โดยทั่วไปจะทำ 2 ท่า คือ ถ่ายเต้านมด้านตรง (Craniocaudal view - CC) และแนวเอียง (Mediolateral oblique view – MLO) ดังตัวอย่างในภาพประกอบ 1 โดยภาพเอกซเรย์ที่ออกมาจะสามารถแสดงให้เห็นถึง ความผิดปกติภายในเต้านม เช่น ก้อนเนื้อหรือแม้แต่หินปูนขนาดเล็กที่อาจเป็นสัญญาณของ โรคมะเร็งเต้านมได้ การตรวจคัดกรองมะเร็งเต้านมไม่ใช่การลดความเสี่ยงของโรค แต่ความสำคัญ คือ การที่สามารถตรวจพบมะเร็งในระยะเริ่มต้นจะทำให้สามารถรักษาให้หายขาดได้ การตรวจเต้านมด้วยวิธีแมมโมแกรมเป็นเครื่องมือที่ได้รับการยอมรับจากทั่วโลกว่ามีประสิทธิภาพมากในการ

ตรวจพบหินปูนในเต้านม หินปูนบางชนิดพบในมะเร็งเต้านมระยะเริ่มแรก ซึ่งไม่สามารถค้นพบจากการตรวจร่างกายทั่วไปได้ ผู้หญิงทุกคนมีโอกาสเป็นมะเร็งเต้านมได้ โดยพบมากในช่วงอายุ 40 ปีขึ้นไป และมีแนวโน้มในการเป็นมะเร็งเต้านมที่เพิ่มสูงขึ้นเรื่อย ๆ ดังนั้นการตรวจแมมโมแกรมจึงเป็นวิธีที่มีประสิทธิภาพในการคัดกรองความผิดปกติ หรืออาการที่เกิดขึ้นในเต้านมในระดับเนื้อเยื่อได้ เพื่อช่วยในการวินิจฉัยว่าความผิดปกตินั้นมีความเสี่ยงต่อการเป็นมะเร็งเต้านม (National Cancer Institute, 2023; Pisano et al., 2004)



Mediolateral oblique View : MLO

ภาพถ่ายเต้านมแนวเอียง



Craniocaudal View : CC

ภาพถ่ายเต้านมด้านตรง

ภาพประกอบ 1 ตัวอย่างภาพถ่ายเต้านมด้วยวิธีแมมโมแกรม

2.2 การรายงานผลการตรวจ Mammogram โดยใช้ระบบ The Breast Imaging Reporting and Data system (BI-RADS)


ปัจจุบันการรายงานผลการตรวจ Mammogram ใช้ระบบ The Breast Imaging Reporting and Data system (BI-RADS) ซึ่งถูกพัฒนาขึ้นโดย The American College of Radiology to standardize mammographic reporting เริ่มใช้ในปี พ.ศ. 2535 และปรับปรุงเรื่อยมาจนกระทั่งล่าสุดในปี พ.ศ. 2566 เป็นฉบับที่ 5 โดยประเมินจากความเสี่ยงต่อการเป็นมะเร็งในแต่ละกลุ่มมาช่วยในการตัดสินใจส่งตรวจชิ้นเนื้อ แบ่งออกเป็น 7 กลุ่ม ซึ่งจะบ่งบอกระดับความเสี่ยงต่อการเป็นมะเร็งเต้านม และแนวทางในรักษาหรือติดตามต่อไปอย่างไร ดังนี้

BI-RADS 0	ยังรายงานผลแน่นอนไม่ได้ ต้องการการตรวจอย่างอื่นเพิ่มเติม
BI-RADS 1	ไม่พบความผิดปกติใด แนะนำให้ตรวจติดตามเป็นประจำทุกปี
BI-RADS 2	มีสิ่งตรวจพบแต่ไม่ใช่มะเร็ง เช่น หินปูนชนิดที่ไม่เกี่ยวข้องกับมะเร็ง แนะนำให้ตรวจติดตามเป็นประจำทุกปี

BI-RADS 3	สิ่งที่ตรวจพบน่าจะไม่ใช่มะเร็ง (โอกาสเป็นมะเร็งไม่เกิน 2%) แนะนำให้ตรวจติดตามทุก 6 เดือน
BI-RADS 4	สิ่งที่ตรวจพบไม่สามารถระบุได้ว่าเป็นมะเร็งหรือไม่ จำเป็นต้อง เจาะชิ้นเนื้อหรือผ่าตัดเพื่อการวินิจฉัยที่ถูกต้อง
BI-RADS 5	ความผิดปกติที่พบสงสัยอย่างยิ่งว่าเป็นมะเร็งเต้านม กรณีนี้ต้อง ทำการเจาะชิ้นเนื้อเพื่อวินิจฉัยอย่างเร่งด่วน
BI-RADS 6	ได้รับการวินิจฉัยทางพยาธิวิทยาแล้วว่าเป็นมะเร็งเต้านมอยู่ ระหว่างการรักษา เพื่อประเมินการตอบสนองต่อยาเคมีหรือ วางแผนผ่าตัด เป็นต้น

(American College of Radiology, 2013)

สำหรับการรายงานผลการตรวจ Mammogram นอกจากเพื่อหาความผิดปกติที่เสี่ยงต่อ
การเป็นมะเร็งแล้ว ผลการตรวจ Mammogram ยังเอาไปใช้ในการพิจารณาความหนาแน่นของเต้านม
(Breast Density) อีกด้วย โดยความหนาแน่นของเต้านมแบ่งออกเป็น 4 ประเภท ดังนี้



ภาพประกอบ 2 ตัวอย่างลักษณะความหนาแน่นของเต้านม (Breast Density)

หมายเหตุ. ดัดแปลงจาก Breast Density and Your Mammogram Report โดย (American College of Radiology, 2013). (<https://www.cancer.org/cancer/types/breast-cancer/screening-tests-and-early-detection/mammograms/breast-density-and-your-mammogram-report.html>)

ส่วนประกอบของเต้านม ได้แก่ ไขมันเต้านมและเนื้อเยื่อเต้านม ซึ่งสำหรับเนื้อเยื่อเต้านม นั้นหากมีความหนาแน่นสูงก็อาจก่อให้เกิดความเสี่ยงต่อโรคมะเร็งได้ โดยความหนาแน่นของ เนื้อเยื่อเต้านมสูง หมายความว่า เต้านมประกอบด้วยเนื้อเยื่อเต้านมมากกว่า 50% ซึ่งพบได้บ่อย ในผู้หญิงเอเชีย และนอกจากจะเพิ่มความเสี่ยงต่อมะเร็งเต้านมแล้ว เนื้อเยื่อเต้านมที่สูงนี้ ยังสามารถลดความแม่นยำของการรายงานผลการตรวจ Mammogram ได้อีกด้วย

2.3 ทฤษฎีเกี่ยวกับการเตรียมข้อมูล (Data Preprocessing)

เมื่อเริ่มทำงานเกี่ยวกับ Deep Learning ปัญหาส่วนใหญ่ที่จะต้องเผชิญคือเรื่องของ ชุดข้อมูล (Dataset) ที่มีจำนวนจำกัด โดยเฉพาะสำหรับการศึกษานี้ คือ ภาพแมมโมแกรม (Mammogram) ซึ่งเป็นภาพทางการแพทย์ที่มีข้อจำกัดมากมายในการเข้าถึงข้อมูล ซึ่งวิธีการ แก้ปัญหาดังกล่าว คือ การใช้ชุดข้อมูลสาธารณะ (Public Dataset) ที่มีความหลากหลายของ ข้อมูล ซึ่งก็จะพบว่ามีความหลากหลายของข้อมูลที่แตกต่างกัน ลักษณะของภาพไม่ได้อยู่ภายใต้หลักเกณฑ์ เดียวกัน เช่น ความคมชัด ความสว่างของภาพ มุมการถ่ายต่าง ๆ และจำนวนจุดสี (Pixel) ของ ภาพที่ไม่เท่ากัน กลายเป็นประเด็นที่ซับซ้อนและยากที่จะแก้ไขเมื่อนำไปใช้งานจริง ทำให้ต้องมีการใช้เทคนิคต่าง ๆ ในการเตรียมข้อมูลเพื่อมาเพิ่มประสิทธิภาพของจำนวนข้อมูลที่มี อยู่อย่างจำกัดให้เกิดประโยชน์สูงสุดต่อการใช้งานเป็นขั้นตอนสำคัญในกระบวนการวิเคราะห์ ข้อมูลและสร้างโมเดล เพื่อให้ข้อมูลพร้อมใช้งานในการศึกษาและการทำงานต่อไป มีหลายทฤษฎี และหลักการที่เกี่ยวข้องกับการเตรียมข้อมูล ดังนี้

2.3.1 การทำความสะอาดข้อมูล (Data Cleansing)

เป็นกระบวนการที่ใช้เพื่อตรวจสอบและปรับปรุงคุณภาพของข้อมูลเพื่อให้ข้อมูลเป็นไป ตามเกณฑ์ที่ต้องการ โดยมุ่งเน้นไปที่การตรวจสอบข้อมูลเพื่อค้นหาข้อผิดพลาด ข้อมูลที่ไม่ถูกต้อง หรือข้อมูลที่หายไปหรือขาดหายไป และทำการแก้ไขหรือลบข้อมูลที่ไม่ถูกต้องออกไปเพื่อให้ข้อมูล ที่จะมีประสิทธิภาพและมีคุณภาพตรงกับที่ต้องการมากที่สุด ความจำเป็นที่ต้องมีการทำความสะอาด ข้อมูลก็เพื่อหลีกเลี่ยงผลลัพธ์ที่ไม่ถูกต้องแม่นยำ ซึ่งวิธีการต่าง ๆ ในการทำความสะอาด ข้อมูลจะขึ้นอยู่กับชนิดและลักษณะของข้อมูลที่ใช้ สำหรับการศึกษานี้ข้อมูลตั้งต้นเป็นภาพ Full-Field Mammogram ที่มีจุดรบกวน (Noise) ของภาพติดมาด้วย ผู้วิจัยจึงทำการกำจัดจุด รบกวนออกจากภาพ Full-Field Mammogram เพื่อป้องกันไม่ให้มันเป็นคุณลักษณะที่สำคัญ (Features) ที่อาจจะส่งผลต่อการประมวลผลของแบบจำลอง (Model) โดยใช้วิธีการทำการแบ่ง ส่วนภาพเต้านม (Largest Contour Segmentation)

2.3.2 การจัดการความไม่สมดุลกันของข้อมูล (Imbalanced Data)

ข้อมูลไม่สมดุล (Imbalanced Dataset) หมายถึง ชุดข้อมูลที่มีจำนวนข้อมูลในแต่ละกลุ่มหรือคลาสที่แตกต่างกันอย่างมาก อาจเกิดขึ้นเนื่องจากลักษณะปกติของข้อมูลที่มีความแตกต่างของจำนวนในแต่ละกลุ่ม ข้อมูลไม่สมดุลพบได้ในหลายรูปแบบ โดยทั่วไปแล้ววิธีการจำแนกข้อมูลมีแนวโน้มที่จะทำนายข้อมูลในคลาสกลุ่มใหญ่ (Majority Class) ซึ่งทำให้ประสิทธิภาพในการทำนายคลาสกลุ่มน้อย (Minority Class) มีประสิทธิภาพต่ำ

ในการแก้ไขปัญหาข้อมูลไม่สมดุลในขั้นตอนการเตรียมข้อมูล (pre-processing data) ทำได้โดยการปรับให้ข้อมูลทั้งสองกลุ่มมีจำนวนที่ใกล้เคียงกัน ดังนี้


1. การสุ่มตัวอย่างเพิ่ม (Oversampling) เป็นการเพิ่มจำนวนข้อมูลในคลาสที่มีจำนวนน้อยโดยการสุ่มสร้างข้อมูลใหม่จากข้อมูลที่มีอยู่ในคลาสนั้น ๆ อาจใช้เทคนิคเช่นการสุ่ม (random sampling) หรือการสร้างข้อมูลใหม่โดยใช้เทคนิคเช่น SMOTE (Synthetic Minority Over-sampling Technique) เพื่อสร้างตัวอย่างที่คล้ายคลาสน้อยโดยไม่ซ้ำกับข้อมูลที่มีอยู่ เพื่อป้องกันการเกิดปัญหา overfitting จากการสร้างข้อมูลที่ซ้ำกันมากเกินไป

2. การสุ่มตัวอย่างลด (Undersampling) เป็นการลดจำนวนข้อมูลในคลาสที่มีจำนวนมากโดยการสุ่มลบข้อมูลออกไปจนเหลือจำนวนที่เท่าเดิมกับคลาสน้อย ๆ แต่อาจทำให้สูญเสียข้อมูลที่สำคัญได้ และไม่สามารถแสดงประสิทธิภาพที่ดีในบางกรณี

3. การใช้เทคนิค Hybrid Sampling เป็นการผสมการสุ่มตัวอย่างเพิ่ม (Oversampling) และการสุ่มตัวอย่างลด (Undersampling) เข้าด้วยกัน เพื่อลดผลกระทบที่อาจเกิดขึ้นจากการสุ่มข้อมูลหรือการลบข้อมูลออกไปโดยไม่คำนึงถึงข้อมูลที่สำคัญ

4. การใช้เทคนิค Weighted Loss Function เป็นการปรับค่าน้ำหนักใน loss function โดยให้ความสำคัญต่ำลงกับคลาสที่มีจำนวนมาก และให้ความสำคัญสูงขึ้นกับคลาสที่มีจำนวนน้อย ซึ่งช่วยให้โมเดลสามารถเรียนรู้และทำนายคลาสน้อยได้ดีขึ้น

โดยการสุ่มตัวอย่างลดจะเหมาะกับข้อมูลขนาดใหญ่ ซึ่งมีข้อเสียคือทำให้สูญเสียสารสนเทศของข้อมูล ส่วนการสุ่มตัวอย่างเพิ่มเหมาะกับข้อมูลที่มีขนาดเล็ก แต่มีข้อเสียคือทำให้ใช้เวลาในการประมวลผลเพิ่มขึ้น แต่การใช้ข้อมูลไม่สมดุลในโครงสร้างโมเดลในบางกรณีสามารถใช้โครงสร้างโมเดลที่สามารถจัดการกับข้อมูลไม่สมดุลได้อย่างเฉพาะเจาะจง เช่น การใช้โมเดลที่สามารถรับน้ำหนักของคลาสต่าง ๆ หรือการใช้โมเดลที่มีส่วนช่วยการเรียนรู้ต่าง ๆ เพื่อช่วยในการแก้ไขปัญหาข้อมูลไม่สมดุลได้



ภาพประกอบ 3 เทคนิคการจัดการความไม่สมดุลกันของข้อมูล (Imbalanced Data)

หมายเหตุ. จาก 10 Techniques to Solve Imbalanced Classes in Machine Learning

(Updated 2024) โดย (Analyticsvidhya, 2024)

สำหรับในงานวิจัยของเราจะใช้ การสุ่มตัวอย่างลด (Under-sampling) กลุ่มส่วนมาก เพื่อแก้ปัญหาข้อมูลไม่สมดุล จากนั้นจึงค่อยทำ Data Augmentation เพื่อเพิ่มข้อมูล

2.3.3 การเสริมข้อมูล (Data Augmentation)

การเสริมข้อมูล (Data Augmentation) เป็นกลยุทธ์ที่ใช้ในการขยายข้อมูลภาพโดยการทำการปรับเปลี่ยนหรือแก้ไขภาพในขั้นตอนการฝึกโมเดลของการเรียนรู้ของเครื่อง (machine learning) เพื่อเพิ่มประสิทธิภาพในการฝึกโมเดลและป้องกันการเกิดปัญหาของการเรียนรู้ที่เกิดขึ้นจากข้อมูลภาพที่จำกัดหรือไม่เพียงพอ การทำ image augmentation) เป็นเทคนิคที่ใช้ในการเพิ่มข้อมูลโดยการสร้างข้อมูลที่แก้ไขจากข้อมูลที่มีอยู่ ซึ่งการทำ Augmentation เป็นกระบวนการสำคัญและใช้งานกันมากในงานด้าน Computer Vision

วิธีการเสริมข้อมูล (Data Augmentation) ที่พบมากที่สุดโดยใช้วิธีการนำรูปภาพเดิมมาดำเนินการ ดังนี้

1. การเลื่อนภาพ (Shift) เป็นการปรับเปลี่ยนตำแหน่งของวัตถุหรือสิ่งของในภาพโดยการเลื่อนภาพไปทางต่าง ๆ เช่น ด้านบนล่าง หรือด้านซ้ายขวา เพื่อสร้างข้อมูลภาพเสริมใหม่ที่มีการเลื่อนตำแหน่งของวัตถุหรือสิ่งของภายใน

2. การหมุน (Rotation) เป็นการหมุนภาพเพื่อสร้างภาพใหม่ที่มีมุมมองต่าง ๆ

3. การพลิกภาพ (Flip) เป็นการสลับทิศทางของภาพ ซึ่งมีสองวิธีหลักในการพลิกภาพคือการพลิกแนวนอน (Horizontal Flip) พิกเซลของภาพจะถูกสลับทิศทางจากซ้ายไปขวาหรือจากขวาไปซ้าย ซึ่งทำให้วัตถุหรือรูปแบบในภาพที่อยู่ทางซ้ายมาขวาหรือทางขวามาซ้าย และการพลิกแนวตั้ง (Vertical Flip) พิกเซลของภาพจะถูกสลับทิศทางจากบนลงล่างหรือจากล่างขึ้นบน ซึ่งทำให้วัตถุหรือรูปแบบในภาพที่อยู่ด้านบนมาล่างหรือทางล่างมาด้านบน

4. การตัดบางส่วนออก (Cropping) เป็นการตัดเอาส่วนหนึ่งของภาพออกมาเพื่อสร้างภาพใหม่

5. การปรับแสงสีความคมของภาพ (Brightness and Contrast Adjustment) เป็นการปรับแก้ไขคุณภาพของภาพโดยการเปลี่ยนแปลงระดับความสว่างและความคมชัดของภาพ เพื่อเพิ่มหรือลดความเข้มของสีและความคมชัดของภาพ เพื่อให้ได้ภาพที่มีคุณภาพและดูดีขึ้น

6. การปรับขนาด (Resizing) เป็นกระบวนการที่ใช้ในการเปลี่ยนขนาดของภาพ โดยปรับขนาดความกว้างและความสูงของภาพให้เป็นขนาดที่ต้องการ การปรับขนาดภาพมักถูกนำมาใช้ในการเสริมข้อมูลหรือปรับปรุงคุณภาพของภาพเพื่อให้เหมาะสมกับการใช้งานที่ต่าง ๆ


สำหรับการดำเนินการที่ได้กล่าวไปในข้างต้นเพื่อให้ได้ข้อมูลที่ต่างไปจากเดิมเล็กน้อยแต่ยังคงมีความหมายเหมือนเดิม ซึ่งการทำ Augmentation เป็นวิธีที่สามารถลดการเกิด Overfitting ได้ การสร้างโมเดลเพื่อให้คอมพิวเตอร์ช่วยในการวิเคราะห์ทำนายหรือจำแนกข้อมูลนั้นจำเป็นต้องอาศัยฐานข้อมูลเพื่อฝึกสอน (Training) ให้โมเดลเรียนรู้ การมีข้อมูลที่มากเพียงพอจะทำให้โมเดลมีประสิทธิภาพในการวิเคราะห์ได้ถูกต้องแม่นยำ แต่เนื่องจากบางครั้งข้อมูลที่มีอยู่นั้นมีจำนวนจำกัด ดังนั้นเทคนิคการเสริมข้อมูล (image augmentation) จึงเข้ามาช่วยในการแก้ปัญหาได้ โดยมักจะใช้ในงานด้านการประมวลผลภาพ เช่น การจำแนกประเภทภาพ (image classification) หรือการตรวจจับวัตถุ (object detection) และงานอื่น ๆ ที่เกี่ยวข้องกับการประมวลผลภาพด้วยโมเดลเชิงลึก (deep learning models)

2.4 ทฤษฎีเกี่ยวกับอัลกอริทึมการจำแนกประเภทข้อมูลภาพ (Image Classification Algorithm)

2.4.1 ทฤษฎีการเรียนรู้เชิงลึก Deep learning

ความรู้เกี่ยวกับการเรียนรู้เชิงลึก Deep learning เป็นแนวคิดในการสร้างและฝึกแบบจำลองของระบบปัญญาประดิษฐ์ที่มีโครงสร้างหลายชั้น (Deep Neural Networks) เพื่อให้คอมพิวเตอร์สามารถเรียนรู้และเข้าใจข้อมูลได้อย่างเชิงลึก โดย Deep learning มุ่งเน้นการเรียนรู้ลักษณะหรือลักษณะเฉพาะของข้อมูลจากชุดข้อมูลใหญ่ ๆ ที่มีความซับซ้อน เช่น ภาพ, เสียง, ข้อความ หรือวิดีโอ เพื่อทำนายผลลัพธ์หรือจำแนกแยกข้อมูลตามลักษณะที่ได้รับมา โดยมีสถาปัตยกรรมการเรียนรู้ข้อมูลของคอมพิวเตอร์มากมาย Convolutional Neural Networks (CNNs) เป็นชนิดหนึ่งของ Deep Neural Networks ที่เป็นที่นิยมในงานที่เกี่ยวข้องกับภาพ โดย CNNs มีโครงสร้างที่ถูกออกแบบมาเพื่อการประมวลผลภาพอย่างเฉพาะเจาะจง และมีความสามารถในการจดจำลักษณะที่เป็นลักษณะของภาพได้อย่างมีประสิทธิภาพ

การทำงานของ Convolutional neural networks เป็นกระบวนการแบบ feed-forward ซึ่งหมายความว่าข้อมูลจะถูกส่งผ่านจากชั้นที่หนึ่งไปยังชั้นถัดไปโดยไม่มีการส่งย้อนกลับ โดยในส่วนของ Hidden layers นั้นจะมี Convolutional layers เพิ่มขึ้นมาเพื่อสกัดลักษณะเฉพาะของภาพออกมา โดยใช้ kernel function จากนั้นนำมาผ่าน Activation Functions สำหรับใช้ในการเพิ่มความสมจริงและการเรียนรู้ให้กับโมเดลของ CNN รวมถึงส่วนที่เรียกว่า Pooling Layers โดยส่วนนี้จะทำหน้าที่ปรับขนาดของข้อมูลให้มีขนาดเล็กลงโดยยังคงรักษารายละเอียดหรือลักษณะที่สำคัญของข้อมูลไว้ ซึ่งเป็นขั้นตอนที่สำคัญในการลดการคำนวณและทำให้โมเดลมีประสิทธิภาพมากขึ้น โดยส่วนนี้มักจะใช้เทคนิค pooling เช่น max pooling หรือ average pooling เพื่อทำการรวมข้อมูลในบริเวณที่กำหนดขนาดเล็กลง และในส่วนสุดท้ายก็จะเป็น Fully connected layer ที่จะคอยเชื่อมต่อในแต่ละชั้นเข้าด้วยกัน ดังภาพประกอบ 4



ภาพประกอบ 4 กระบวนการทำงานของ Deep Convolutional neural networks

หมายเหตุ. จาก Deep Learning vs. Traditional Computer Vision โดย (Walsh et al., 2019).

DOI: 10.1007/978-3-030-17795-9_10

2.4.2 ทฤษฎีการ Transfer Learning

การ Transfer Learning เป็นกระบวนการในการใช้ความรู้ที่ได้จากการฝึกโมเดล (model) บนชุดข้อมูลหนึ่งไปใช้ในการฝึกโมเดลบนชุดข้อมูลอื่น ๆ โดยใช้โมเดลที่ถูกฝึกไว้แล้ว (pre-trained model) เป็นพื้นฐานกระบวนการ Transfer Learning นี้มักจะนำโมเดลที่ถูกฝึกด้วยชุดข้อมูลใหญ่เช่น ImageNet มาใช้ในงานหรือชุดข้อมูลที่มีขนาดเล็กกว่า โดยการนำความรู้และคุณสมบัติที่ได้เรียนรู้มากมายจากชุดข้อมูลใหญ่นั้น มาใช้ในงานหรือชุดข้อมูลอื่น ๆ

การฝึกฝนโมเดล Deep learning ที่มีขนาดใหญ่และซับซ้อนอาจต้องใช้เวลาและทรัพยากรการคำนวณมากมาย การฝึกฝนโมเดลที่ซับซ้อนอาจต้องใช้เวลานานหลายวันหรือแม้กระทั่งสัปดาห์เพื่อให้ได้โมเดลที่มีประสิทธิภาพ เนื่องจากต้องใช้ชุดข้อมูลขนาดใหญ่และมีการประมวลผลที่มหาศาลในการปรับค่าตัวแปร(weight) ของโมเดล เพื่อให้โมเดลเรียนรู้และปรับปรุงความแม่นยำของการทำนาย ดังนั้นการใช้ Transfer learning จึงเป็นเทคนิคที่ช่วยลดเวลาการฝึกโมเดล Deep learning อย่างมีประสิทธิภาพ ด้วยการนำบางส่วนจากโมเดลที่ฝึกฝนเรียบร้อยแล้วกับงานที่ใกล้เคียงกันมาใช้เป็นส่วนหนึ่งของโมเดลใหม่ สำหรับโมเดลที่นำมาใช้ในงานวิจัยนี้คือ ResNet50 และ VGG16


สำหรับ ResNet50 เป็นโมเดล Convolutional Neural Network (CNN) ที่มีความลึก 50 layers ซึ่งใช้โครงสร้างของ Residual Network (ResNet) โดยมีความสำคัญอยู่ที่การใช้ "skip connection" หรือ "shortcut connection" เพื่อช่วยให้การฝึกฝนโมเดลเชิงลึกได้ดีขึ้น โดยลดปัญหาของการหา gradient ได้ยาก (vanishing gradient) ที่เป็นปัญหาที่พบในโครงข่ายเชิงลึก ถูกพัฒนาขึ้นโดยทีมวิจัยของ Microsoft Research โดยนำเสนอครั้งแรกในงานวิชาการปี 2015 ซึ่งชนะการแข่งขัน ImageNet Large Scale Visual Recognition Challenge (ILSVRC) ในหมวดหมู่ของการจำแนกประเภทภาพ (image classification) ด้วยความแม่นยำสูงสุดในเวลานั้น สำหรับโครงสร้างของ ResNet50 สามารถอธิบายได้ดังนี้:

1. Input Layer รับภาพขนาดเท่ากับ 224x224 pixels (RGB)
2. Convolutional Layers มีชุดของ convolutional layers ตามที่กำหนดไว้ในโมเดล โดยมีการใช้ kernel size เป็น 7x7, 3x3 และ 1x1 พร้อมกับการใช้ stride เท่ากับ 2 ในบางชั้นเพื่อลดขนาดของ feature map
3. Residual Blocks ResNet50 ประกอบด้วยหลายๆ residual blocks ที่ประกอบด้วย convolutional layers, batch normalization, activation function (โดยทั่วไปใช้ ReLU), และการใช้ skip connection เพื่อเชื่อมต่อกับ output ของ convolutional layers ก่อนหน้า ซึ่งช่วยให้โมเดลสามารถฝึกได้ลึกขึ้นโดยไม่เกิดปัญหาของการหา gradient ได้ยาก
4. Global Average Pooling (GAP) หลังจากที่ผ่านมา residual blocks ทั้งหมดแล้ว โมเดลจะใช้ GAP เพื่อลดขนาดของ feature map ลงเหลือเพียงค่าเดียวต่อ channel เพื่อเตรียมการใช้ Fully Connected Layers

5. Fully Connected Layers (Dense Layers) มีชั้นของ fully connected layers สำหรับการจำแนกประเภทของภาพ โดยใช้ activation function เป็น softmax สำหรับการคำนวณความน่าจะเป็นของแต่ละประเภท

6. Output Layer ชั้นสุดท้ายของโมเดลเป็น output layer ที่ให้ผลลัพธ์ในรูปแบบของความน่าจะเป็นสำหรับแต่ละประเภทที่จำแนกได้

โมเดล ResNet50 มีโครงสร้างที่มีความซับซ้อนและประสิทธิภาพสูงในการทำงานต่าง ๆ ที่เกี่ยวข้องกับการมองเห็นคอมพิวเตอร์ เช่น การจำแนกประเภทภาพ, การตรวจจับวัตถุ, และการค้นหาและจัดการภาพ โดยมีการนำไปใช้ในหลายงานและโปรเจกต์ในวงการ Deep Learning



ภาพประกอบ 5 โครงสร้าง ResNet50

หมายเหตุ. ดัดแปลงจาก Automatic Detection of COVID-19 Disease in Chest X-Ray Images using Deep Neural Networks โดย (Khan et al., 2020). DOI: 10.1109/R10-HTC49770.2020.9357034

สำหรับ VGG16 เป็นโมเดล Convolutional Neural Network (CNN) มีความลึกทั้งหมด 16 layers ซึ่งโดยส่วนมากประกอบด้วยชั้น convolutional layers และชั้นการรวมข้อมูล (pooling layers) ซึ่งมีโครงสร้างที่ถูกออกแบบอย่างละเอียดและซับซ้อน โดย VGG16 ถูกพัฒนาโดยทีมนักวิจัยของ Visual Geometry Group (VGG) ที่มหาวิทยาลัย Oxford และเป็นหนึ่งในโมเดลที่ได้รับความนิยมในการจำแนกประเภทภาพและงานด้านการมองเห็นคอมพิวเตอร์ โครงสร้างของ VGG16 ประกอบด้วยหลายชั้น convolutional layers และชั้นการรวมข้อมูล (pooling layers) โดยมีความลึกทั้งหมด 16 layers ดังนี้

1. Input Layer รับภาพขนาด 224x224 pixels (RGB) เป็นข้อมูลนำเข้าเพื่อเริ่มต้นกระบวนการการทำงานของโมเดล


2. Convolutional Layers มี convolutional layers ทั้งหมด 13 ชั้น ที่ใช้ kernel size เป็น 3x3 และ stride เท่ากับ 1 โดยมีการใช้ activation function เป็น ReLU หลังการสร้าง feature maps

3. Pooling Layers มีชั้นของ pooling layers (max pooling) หลังจากบาง convolutional layers เพื่อลดขนาดของ feature maps และเพิ่มความถี่ของลักษณะที่สำคัญ

4. Fully Connected Layers (Dense Layers) หลังจาก pooling layers แล้วมีชั้นของ fully connected layers ซึ่งมีหลายชั้นโดยมีจำนวน units ของแต่ละชั้นลดลงเรื่อย ๆ เพื่อลดการ overfitting และปรับความซับซ้อนของโมเดล

5. Output Layer ชั้นสุดท้ายของโมเดลเป็น output layer ที่ให้ผลลัพธ์ในรูปแบบของความน่าจะเป็นสำหรับแต่ละประเภทที่จำแนกได้

โครงสร้างของ VGG16 มีความซับซ้อนและมีจำนวนพารามิเตอร์มาก เนื่องจากมีการใช้ convolutional layers และ fully connected layers ในจำนวนมาก ซึ่งทำให้ VGG16 เป็นโมเดลที่มีประสิทธิภาพสูงในการจำแนกประเภทภาพและงานด้านการมองเห็นคอมพิวเตอร์ที่ซับซ้อน



ภาพประกอบ 6 โครงสร้าง VGG16

หมายเหตุ. จาก Illumination-robust face recognition based on deep convolutional neural networks architectures โดย (Bendjillali et al., 2020)

2.4.3 การปรับแต่งแบบจำลอง (Tuning) และ Hyperparameters

หลังจากเทรนโมเดลด้วยโมเดลที่มีอยู่ (pre-trained model) อีกหนึ่งขั้นตอนที่สำคัญ คือ การปรับแต่งโมเดล (Tuning) ให้เหมาะกับงานหรือชุดข้อมูลที่เราต้องการใช้ โดยการ Fine-tune เราสามารถใช้โมเดลที่ได้มาจากการฝึกด้วยชุดข้อมูลใหญ่ เช่น ImageNet และปรับแต่งให้เหมาะสมกับงานหรือชุดข้อมูลที่เราต้องการใช้ โดยไม่ต้องเริ่มต้นฝึกโมเดลใหม่จากเริ่มต้น

การ Fine-tune โมเดลสามารถทำได้ด้วยขั้นตอนต่อไปนี้

1. โหลดโมเดล Pre-trained เริ่มต้นโดยโหลดโมเดลที่มีอยู่ที่ได้ถูกฝึกด้วยชุดข้อมูลใหญ่ เช่น VGG16, ResNet50 จากไลบรารีหรือที่มาของโมเดล
2. ปรับแต่งโครงสร้าง เพื่อให้เหมาะสมกับงานหรือชุดข้อมูลที่เราต้องการ ซึ่งอาจจะปรับแก้ชั้นสุดท้าย (output layer) เพื่อให้ตรงกับจำนวนของคลาสที่ต้องการใช้ในงาน
3. แชร์ (Freeze) ชั้นบางส่วน เพื่อปิดการอัปเดตน้ำหนักของชั้นบางส่วนของโมเดล เช่น ชั้น convolutional layers ซึ่งถูกสร้างจากโมเดล Pre-trained และสามารถการเรียนรู้ที่ได้แล้วจากชุดข้อมูลใหญ่ได้ เพื่อลดเวลาการฝึกและป้องกันการสูญเสียของข้อมูลที่ได้จากชุดข้อมูลใหญ่
4. ทำการฝึกโมเดลด้วยชุดข้อมูลที่เราต้องการใช้ โดยปรับปรุงน้ำหนักของชั้นที่เราไม่ได้แชร์ (unfreeze) เช่น ชั้น fully connected layers
5. ปรับแต่งพารามิเตอร์ของโมเดลเพื่อทำให้โมเดลมีประสิทธิภาพมากขึ้นต่องานที่เราต้องการ
6. ประเมินประสิทธิภาพของโมเดลที่ฝึกด้วยชุดข้อมูลทดสอบเพื่อประเมินประสิทธิภาพและปรับปรุงต่อไปตามความต้องการ

ดังนั้นการ Fine-tune โมเดลช่วยให้สามารถใช้โมเดลที่มีอยู่ (pre-trained model) มาปรับแต่งให้เหมาะสมกับงานหรือชุดข้อมูลที่เราต้องการใช้ได้อย่างมีประสิทธิภาพ โดยไม่ต้องฝึกโมเดลใหม่จากเริ่มต้นซึ่งสามารถประหยัดเวลาและทรัพยากรการคำนวณได้มาก

นอกจากการ Fine-tune โมเดลแล้ว สำหรับ Convolutional Neural Network (CNN) Model มี hyperparameters หลายอย่างที่สำคัญที่จะต้องพิจารณาในขณะปรับแต่งโมเดลเช่นกัน ซึ่งอาจแตกต่างกันไปตามโมเดลและงานที่ทำ แต่ละ hyperparameters มีผลต่อประสิทธิภาพของ

โมเดลในการฝึกและการทำนาย ดังนั้นการเลือกและปรับ hyperparameters อย่างเหมาะสมจึงเป็นสิ่งสำคัญที่จะพิจารณาอย่างรอบคอบ โดยมี hyperparameters ที่สำคัญควรพิจารณา ดังนี้

1. Learning Rate (อัตราการเรียนรู้) อัตราการเรียนรู้กำหนดความเร็วในการปรับค่าของพารามิเตอร์ในระหว่างการเทรน หาก learning rate มากเกินไปอาจทำให้โมเดลไม่สามารถ converge ได้ แต่หากมีค่าน้อยเกินไปอาจทำให้การเทรนช้าลง การทำ fine-tuning มักจะใช้ learning rate ที่น้อยกว่าในการ pre-training แต่ยังขึ้นอยู่กับงานและข้อมูลที่ใช้

2. Batch Size (ขนาดแบทช์) Batch size กำหนดจำนวนข้อมูลที่ใช้ในการคำนวณ gradient แต่ละครั้ง การเลือก batch size ที่เหมาะสมสามารถช่วยให้การเทรนเร็วขึ้น และลดการใช้ทรัพยากรเช่นหน่วยประมวลผลกราฟิก (GPU) และหน่วยความจำ

3. Number of Epochs (จำนวนรอบการเทรน) จำนวนรอบการเทรนหรือ epochs หมายถึงจำนวนครั้งที่โมเดลจะทำการเรียนรู้จากชุดข้อมูลฝึกซึ่งส่งผลต่อความสามารถในการเรียนรู้และปรับค่าพารามิเตอร์

4. Dropout Rate (อัตราการ Dropout) Dropout เป็นเทคนิคที่ใช้ในการลด overfitting โดยการสุ่มปิดชั้น (neurons) บางส่วนในระหว่างการเทรน เพื่อป้องกันโมเดลจับตัวลักษณะเฉพาะในชุดข้อมูลฝึก

5. Weight Decay (การหดหน่วย) Weight decay เป็นเทคนิคที่ใช้ในการลด overfitting โดยการเพิ่มค่าพิณัย (penalty) ในค่าของพารามิเตอร์ขณะการคำนวณ loss function

6. Optimizer (ตัวปรับค่า) ตัวปรับค่าคืออัลกอริทึมที่ใช้ในการปรับค่าของพารามิเตอร์ เช่น Stochastic Gradient Descent (SGD), Adam, RMSprop เป็นต้น

7. กำหนดขั้นที่จะทำ Fine-tuning ในกรณีที่ใช้ pre-trained model จำเป็นต้องกำหนดขั้นที่จะทำ Fine-tuning ว่าจะปรับแต่งเฉพาะชั้นบางส่วนหรือทั้งหมด

โดยการปรับแต่ง hyperparameters เหล่านี้จะต้องผ่านกระบวนการทดลองและประเมินเป็นระยะ ๆ เพื่อหาค่าที่เหมาะสมที่สุดสำหรับโมเดล

2.5 การวัดประสิทธิภาพของแบบจำลอง (Model Evaluation)

หลังจากการ Transfer Learning แบบจำลอง Deep Convolutional neural networks มาประยุกต์ใช้กับการจำแนกประเภทของข้อมูลแล้ว การวัดประสิทธิภาพของแบบจำลอง (model evaluation) เป็นขั้นตอนที่สำคัญในการประเมินความสามารถของแบบจำลองในการ

ทำนายหรือจัดหมวดหมู่ข้อมูล โดยเครื่องมือที่สำคัญและมักถูกนำมาใช้เพื่อทำการวิเคราะห์ประสิทธิภาพของแบบจำลองในการทำนายข้อมูล คือ Confusion Matrix (เมทริกซ์ความสับสน) จะช่วยให้เห็นภาพรวมเกี่ยวกับประสิทธิภาพของโมเดลโดยรวม แบ่งเป็น 4 ส่วนหลัก ๆ ดังภาพประกอบ 7

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

ภาพประกอบ 7 ลักษณะตารางของ Confusion Matrix

จะเห็นว่าในตารางจะมีตัวอักษรอยู่ 4 ช่อง โดยมีรายละเอียด ดังนี้

1. True Positives (TP) จำนวนข้อมูลที่ไม่เดลทำนายถูกต้องว่าเป็น Positive Class (ส่วนที่มีค่าเป็น Positive) ตามกลุ่มคลาสที่จริง
2. True Negatives (TN) จำนวนข้อมูลที่ไม่เดลทำนายถูกต้องว่าเป็น Negative Class (ส่วนที่มีค่าเป็น Negative) ตามกลุ่มคลาสที่จริง
3. False Positives (FP) จำนวนข้อมูลที่ไม่เดลทำนายผิดว่าเป็น Positive Class (ส่วนที่มีค่าเป็น Positive) แต่จริงๆ แล้วเป็น Negative Class ตามกลุ่มคลาสที่จริง
4. False Negatives (FN) จำนวนข้อมูลที่ไม่เดลทำนายผิดว่าเป็น Negative Class (ส่วนที่มีค่าเป็น Negative) แต่จริงๆ แล้วเป็น Positive Class ตามกลุ่มคลาสที่จริง

โดยจาก Confusion Matrix สามารถคำนวณหรือสร้างตัวชี้วัดประสิทธิภาพต่างๆ ได้โดยมีรายละเอียด ดังนี้

1. Accuracy (ความแม่นยำของการทำนายผลโมเดลทั้งหมด) หมายถึง ความสามารถของแบบจำลองในการทำนายถูกต้องโดยเปรียบเทียบกับข้อมูลที่ทดสอบทั้งหมด ซึ่งมีสูตรการคำนวณ ดังนี้

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

2. Precision (ความถูกต้องของประเด็นที่โมเดลสนใจที่จะทำนาย) หมายถึง สัดส่วนของข้อมูลที่ถูกตั้งที่แบบจำลองทำนายว่าเป็น Positive และตรงกับความจริง เทียบกับข้อมูลที่ถูกตั้งที่แบบจำลองทำนายว่าเป็น Positive ซึ่งมีสูตรการคำนวณ ดังนี้

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

3. Recall (สัดส่วนที่โมเดลสามารถทำนายประเด็นที่เราสนใจทั้งหมด) หมายถึง สัดส่วนของข้อมูลที่ถูกตั้งที่แบบจำลองทำนายว่าเป็น Positive และตรงกับความจริง เทียบกับข้อมูลที่ถูกตั้งที่แบบจำลองตรวจจับได้ทั้งหมดที่เป็น Positive ซึ่งมีสูตรการคำนวณ ดังนี้

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

4. F1 Score เป็นค่าผสมระหว่าง Precision และ Recall ที่นำมาคำนวณเป็นค่าเดียว เป็นวิธีการวัดประสิทธิภาพที่ดีในกรณีที่ความสำคัญของ Precision และ Recall เท่าเทียมกัน เรียกว่าเป็น ค่าเฉลี่ยแบบ harmonic ของ Precision กับ Recall ซึ่งมีสูตรการคำนวณ ดังนี้

$$F1\ Score = 2 \frac{(Precision \cdot Recall)}{(Precision + Recall)}$$

การเลือกวิธีการวัดประสิทธิภาพขึ้นอยู่กับลักษณะของงานและข้อมูลที่มีอยู่ โดยส่วนใหญ่ควรใช้หลายวิธีการรวมกันเพื่อให้เกิดภาพรวมที่ครอบคลุมและเป็นประสิทธิภาพ สำหรับการประเมินแบบจำลอง

2.6 งานวิจัยที่เกี่ยวข้อง

การทบทวนวรรณกรรมของงานวิจัยนี้ได้ทำการศึกษาค้นคว้างานวิจัยที่เกี่ยวข้องกับการจำแนกผลตรวจจากภาพแมมโมแกรม ด้วยการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ รวมทั้งเทคนิคการเตรียมข้อมูลภาพแมมโมแกรม โดยงานวิจัยที่เกี่ยวข้องมีรายละเอียดดังนี้

1.บทความวิจัยเรื่อง Abnormality Detection in Mammography using Deep Convolutional Neural Networks (Xi et al., 2018)

งานวิจัยนี้ได้ทำการศึกษาความผิดปกติของเต้านมจากภาพ Mammogram โดยใช้ Deep Convolutional Neural Networks (CNN) เรียนรู้คุณลักษณะอัตโนมัติและการสร้างตัวแยกประเภท ในการตรวจแมมโมแกรมโดยใช้คอมพิวเตอร์ช่วย โดย Deep Convolutional Neural Networks (CNN) ไม่สามารถฝึกได้โดยตรงบนภาพแมมโมแกรมแบบเต็มได้ ต้องทำการตัดมาบางส่วน(Crop) มาเฉพาะบริเวณ Region of Interest (ROIs) และทำการจำแนกหีนูน และ ก้อนเนื้อ จากภาพ Mammogram จากนั้นประยุกต์ใช้ Class Activation Mapping เพื่อระบุรอยโรค บนภาพ Full Mammogram ด้วยวิธี Transfer Learning โดยใช้ชุดข้อมูล Open Dataset CBIS-DDSM (Curated Breast Imaging Subset of DDSM) มีการทำ Data Pre-processing โดยใช้เทคนิค Data augmentation ด้วยการหมุนภาพแบบสุ่มระหว่าง 0 ถึง 360 องศาเพื่อจำนวนของ Training Data แล้วนำไปสร้างแบบจำลอง Deep CNN 4 โมเดล ได้แก่ AlexNet, VGGNet, GoogleNet และ ResNet ผลการทดลอง พบว่า VGGNet มี Accuracy โดยรวมสูงสุด 92.53% จากนั้นใช้ ResNet ที่ Tune มาเรียบร้อยแล้วคำนวณ CAM เพื่อที่จะระบุว่ารอยโรคอยู่ในตำแหน่งไหนของภาพใหญ่ (Full Mammogram)

2.บทความวิจัยเรื่อง Mammographic mass classification according to Bi-RADS lexicon โดย Ferkous and Merouani (2017)

งานวิจัยนี้ได้เสนอระบบ computer-aided diagnosis (CADx) ในการจำแนกความแตกต่างระหว่าง BI-RADS 4 Classes (Bi-RADS2, Bi-RADS3, Bi-RADS4 และ Bi-RADS5) ในภาพแมมโมแกรมที่มีก้อนเนื้อ(Mass) จากชุดข้อมูล Open Dataset DDSM 480 mammographic masses โดยใช้ ภาพ ROIs และ Mass segmentation และมีการนำเสนอคุณลักษณะที่สำคัญในการจำแนกความแตกต่างระหว่าง BI-RADS 4 Classes พบว่า รูปร่าง ขอบ ขนาด ความหนาแน่นของเนื้อเยื่อเต้านม จากภาพแมมโมแกรมที่มีก้อนเนื้อ รวมถึงอายุของผู้ป่วย มีต่อการจัดประเภทความผิดปกติในระดับ BI-RADS ได้ จากนั้นได้ทำการสร้างโมเดลจำแนกความผิดปกติในระดับ BI-RADS โดยใช้ CNN แบบ Multilayer Perceptron (MLP) ได้ผลลัพธ์คือ Accuracy โดยรวมในการจำแนกระดับ BI-RADS สูงสุด 83.85%

3.บทความวิจัยเรื่อง Classification of Mammographic Breast Microcalcifications Using a Deep Convolutional Neural Network : A BI- RADS- Based Approach (Schönenberger et al., 2021)

งานวิจัยนี้ได้ทำการศึกษาการจำแนกหีนปูนขนาดเล็กในด้านมด้วยภาพแมมโมแกรมบนพื้นฐานหลักการ BI-RADS จากชุดข้อมูลภาพแมมโมแกรมของโรงพยาบาลจำนวน 268 ภาพที่มีผลการตรวจเป็น BI-RADS 4 และ BI-RADS 5 จากจำนวนผู้ป่วย 94 คน มีการทำ Data Pre-processing ด้วยการ labeled ROIs จากภาพ Full Mammogram BI-RADS4 กับ 5 เป็นภาพ ROIs 3 classes (BI-RADS 1, BI-RADS2/3, BI-RADS4/5) และบันทึก ROIs เป็นขนาดใหม่ (351 X 380 pixels) จากนั้นได้ทำ Data Augmentation ด้วยการเลื่อนภาพ (shift) ในแนวนอนและแนวตั้ง จากนั้นสร้างโมเดลในการจำแนกโดยการออกแบบโมเดลดังนี้ CNN 13 layers fully connected 4 dense layers Train Model โดยกำหนด Batch size = 40 และ Epochs = 130 โดยในงานวิจัยนี้คณะผู้วิจัยได้สร้างโมเดล 3 โมเดลที่มีโครงสร้างเหมือนกันแต่ Train กับ Dataset 3 รูปแบบ ได้แก่ Cohort of Bi-RADS4, Cohort of Bi-RADS5 และ Cohort of Bi-RADS4-5 พบว่า Accuracy ของ Deep CNN ทั้ง 3 โมเดล เปนดังนี้ 39.0 %, 80.9 % และ 76.6 % ตามลำดับ จากนั้นนำไปประยุกต์ใช้กับภาพ Full Mammogram ว่าแต่บริเวณของภาพเต้านม (ROIs) แต่ละตำแหน่งมีระดับความเสี่ยงอยู่ระดับใดใน BI-RADS 3 classes (BI-RADS 1, BI-RADS2/3, BI-RADS4/5)


4.บทควมวิจัย Multi - Class classification of breast cancer abnormalities using Deep Convolutional Neural Network (CNN) (Heenaye-Mamode Khan et al., 2021)

งานวิจัยนี้ได้ทำการศึกษาเพื่อพัฒนา Deep Convolutional Neural Network (CNN) ในการจำแนกความผิดปกติของเต้านม 4 Classes จากภาพ Mammogram ได้แก่ Mass, Calcification, Asymmetry, Carcinomas จากชุดข้อมูล CBIS-DDSM (Mass, Calcification) และ ชุด ข้อมูล UPMC (Asymmetry, Carcinomas) งานวิจัยนี้เป็นงานประเภท Multi-Classification เหมือนกับงานที่เรากำลังทำอยู่ แล้วมีการใช้เทคนิค Contrast-limited adaptive histogram equalization (CLAHE) ในการเน้นส่วนที่เป็นรอยโรคที่สำคัญในภาพ ซึ่งจะค่อนข้างเหมาะสมงานประเภท Multi-Class Classification เพราะการแยกออกเป็น Multi-Class กับรอยโรคขนาดเล็กที่อาจจะต่างกันเพียงเล็กน้อยเป็นความท้าทายอย่างมากที่โมเดลจะสามารถ Classify ได้อย่างถูกต้อง ดังนั้นการใช้เทคนิคดังกล่าวมีส่วนช่วยปรับปรุงคุณภาพของภาพให้สามารถจำแนกความผิดปกติได้ดีขึ้น ความเข้มระหว่างเนื้อเต้านมและพื้นหลังได้รับการปรับปรุงเพื่อให้เน้นเนื้อเยื่อเต้านมได้ดีขึ้น และลด Noise ในภาพได้ ประกอบกับการทำ Data augmentation by flipping, rotation, cropping เพื่อแก้ปัญหา Class imbalance และลดการเกิดปัญหา Over-fitting รวมถึงการใช้ Deep CNN ในการจำแนกความผิดปกตินั้นจะ

ช่วยสกัด feature ที่สำคัญในการ Classify ได้ดี สร้างโมเดลโดยใช้การ Transfer learning ด้วย pre-trained ResNet50 เปรียบเทียบกับการสร้าง Enhanced CNN model เอง พบว่า pre-trained ResNet50 ได้ Accuracy 81.5% และ Enhanced CNN Model Accuracy 88%

5. บทความ Convolutional neural networks for breast cancer detection in mammography: A survey (Abdelrahman et al., 2021)

งานวิจัยนี้เป็น Survey Paper ที่เกี่ยวกับ Convolutional neural networks for breast cancer detection in mammography ได้ทำการศึกษาข้อมูล Survey ตั้งแต่ปี 2012-2020 จะเห็นว่าในเรื่อง BIRADS Classification อยู่ในกลุ่ม Task Density Classification ซึ่งเป็น Task ที่คนสนใจน้อยที่สุด เพราะว่า ในการจำแนก BI-RADS นั้น จำเป็นต้องเตรียมข้อมูลที่หลากหลายสำหรับการฝึกฝนโมเดล อีกทั้งเป็นเรื่องที่เกี่ยวกับการคัดกรองโรคเบื้องต้นไม่ได้ชี้เฉพาะเจาะจงว่าเป็นมะเร็งหรือไม่เป็นมะเร็งซึ่งจะละเอียดมากกว่า ประกอบกับเป็นลักษณะปัญหา Multi-Class ที่จะสามารถจำแนกได้ยากกว่าปัญหา binary class




ภาพประกอบ 8 Mammogram papers Tasks (Abdelrahman et al., 2021)

หมายเหตุ. จาก Convolutional neural networks for breast cancer detection in mammography: A survey โดย (Abdelrahman et al., 2021)

6.บทความ An Effective Ensemble Machine Learning Approach to Classify Breast Cancer Based on Feature Selection and Lesion Segmentation Using Preprocessed Mammograms (Rafid et al., 2022)

งานวิจัยนี้ได้ทำการศึกษเกี่ยวกับแนวทางการพัฒนา Machine Learning เพื่อการจำแนกเกี่ยวกับเนื้องอกเต้านม 4 แบบ ได้แก่ Benign Calcification, Benign Mass, Malignant

Calcification, Malignant Mass ด้วยเทคนิคการปรับปรุงข้อมูลภาพแมมโมแกรม โดยการลบสิ่งที่ไม่เกี่ยวข้องกับข้อมูลออก (Artifacts Removal) ทำการแบ่งส่วนเต้านม (Largest Contour Detection) เพื่อเลือกเฉพาะบริเวณสำคัญที่เป็นเต้านมเท่านั้น และมีการปรับปรุงข้อมูลภาพ Mammogram ด้วยเทคนิค Image Enhancement โดยใช้ Gamma Correction และ contrast limited adaptive histogram equalization (CLAHE) ด้วยความถี่ข้อมูลที่ใช้มีขนาดไม่เพียงพอต่อการฝึกฝนโมเดล ทำให้ผู้วิจัยได้ใช้เทคนิคการเสริมข้อมูลภาพด้วยการหมุนภาพ 30 องศาและกลับด้านภาพ (flip) เพื่อทำให้ข้อมูลมีความหลากหลายและมีขนาดใหญ่ขึ้นสำหรับฝึกฝนโมเดล โดยทำการฝึกฝนและทดสอบโมเดล 11 แบบ จากนั้นมีการผสมผสานทำโมเดลซ้อนกัน 3 แบบ (Ensemble Model) ซึ่งในทั้ง 3 โมเดล Random Forest-XGBoost ensemble model มีประสิทธิภาพเหนือกว่าโมเดลอื่น ๆ มีความแม่นยำในการทดสอบ 98.05%



ภาพประกอบ 9 Augmentation Method (Rafid et al., 2022)

หมายเหตุ. จาก An Effective Ensemble Machine Learning Approach to Classify Breast Cancer Based on Feature Selection and Lesion Segmentation Using Preprocessed Mammograms โดย (Rafid et al., 2022)

7.บทความ VinDr-Mammo: A large-scale benchmark dataset for computer-aided diagnosis in full-field digital mammography (Nguyen et al., 2023)

งานวิจัยนี้เป็นการศึกษาชุดข้อมูลคู่เปรียบเทียบขนาดใหญ่สำหรับการวินิจฉัยโดยใช้คอมพิวเตอร์ช่วยในการตรวจแมมโมแกรมดิจิทัลแบบเต็มฟิลด์ ชื่อว่า VinDr-Mammo ซึ่งเป็นชุดข้อมูลการตรวจแมมโมแกรมดิจิทัลของชาวเวียดนามพร้อมการประเมินระดับเต้านมและคำอธิบายประกอบระดับรอยโรคที่ครอบคลุม ซึ่งช่วยเพิ่มความหลากหลายของข้อมูลการตรวจแมมโมแกรมที่เปิดเผยต่อสาธารณะ ชุดข้อมูลประกอบด้วยภาพการตรวจแมมโมแกรมจำนวน 5,000 รายการ ซึ่งแต่ละการตรวจมีมุมมองมาตรฐาน 4 มุมมอง (RMLO, RCC, LMLO, LCC) โดยวัตถุประสงค์ของชุดข้อมูลนี้คือเพื่อประเมินการรายงานและระบบข้อมูลการถ่ายภาพเต้านม (BI-RADS) และความหนาแน่นของเต้านมในระดับเต้านมแต่ละบุคคล

8.บทความ A High-Performance Deep Neural Network Model for BI-RADS Classification of Screening Mammography (K.-J. Tsai et al., 2022)

งานวิจัยนี้เป็นการศึกษาแบบจำลองที่ใช้โครงข่ายประสาทเชิงลึก (DNN) ซึ่งเป็นเครื่องมือที่มีประสิทธิภาพและเชื่อถือได้ในการช่วยนักรังสีวิทยาในการตีความภาพแมมโมแกรมเป็น BI-RADS หมวดหมู่ 0, 1, 2, 3, 4A, 4B, 4C และ 5 แบบจำลองที่นำเสนอได้รับการฝึกฝนโดยใช้รูปภาพแบบบล็อกซึ่งแบ่งส่วนจากชุดข้อมูลแมมโมแกรม โดยมีประสิทธิภาพแม่นยำของแบบจำลองโดยรวม accuracy 94.22% , sensitivity 95.31% specificity 99.15% และพื้นที่ใต้เส้นโค้ง (AUC) 0.9723 เมื่อนำไปใช้กับการตรวจคัดกรองมะเร็งเต้านมสำหรับผู้หญิงเอเชียที่มีแนวโน้มว่าจะมีหน้าอกหนาแน่น คาดว่าโมเดลนี้จะมีความแม่นยำสูงกว่าโมเดลอื่น ๆ โดยในการทดลองนี้ BI-RADS Class ที่โมเดลสามารถทำนายได้มีประสิทธิภาพดีที่สุดเมื่อพิจารณาค่า sensitivity แต่ละBI-RADS เป็นสำคัญ คือ BI-RADS 5 โดยกรณีของรอยโรค BI-RADS หมวดหมู่ 0, 4A, 4B, 4C ก็มีประสิทธิภาพต่างกันไม่มากเป็นการยืนยันว่ารอยโรคดังกล่าวสามารถจำแนกได้ดีโดยใช้งานนี้และสามารถวินิจฉัยโรคมะเร็งเต้านมระยะเริ่มแรกได้ในกรณีของรอยโรค BI-RADS หมวดหมู่ 2 และ 3 ตัวชี้วัดประสิทธิภาพทั้งหมดจะอยู่สูงกว่า 92% ซึ่งต่ำกว่า 5 Classes ที่อ้างถึงข้างต้นเล็กน้อย น้อยที่สุดคือประสิทธิภาพการทำงานเกิดขึ้นในกรณีของรอยโรค BI-RADS ประเภท 1 sensitivity 81.22% และ precision 85.91% ตามลำดับด้วยเหตุผล คือ ภาพที่ไม่มีรอยโรคทั้งหมดจัดอยู่ในประเภท BI-RADS 1 ซึ่งนำไปสู่ลักษณะที่ไม่โดดเด่นซึ่งวินิจฉัยได้ยาก

0 -	10503	133	0	4	0	0	0	1
1 -	372	12059	894	783	144	158	166	271
2 -	11	893	12343	61	2	4	4	4
3 -	4	619	52	11872	6	4	3	6
4A -	2	114	2	3	6247	0	1	0
4B -	1	81	3	1	0	7161	0	1
4C -	0	70	3	1	0	2	8929	0
5 -	0	67	4	0	0	0	0	11614
	0	1	2	3	4A	4B	4C	5

ภาพประกอบ 10 Confusion Matrix (K.-J. Tsai et al., 2022)

หมายเหตุ. จาก A High-Performance Deep Neural Network Model for BI-RADS
Classification of Screening Mammography โดย (K.-J. Tsai et al., 2022)

BI-RADS	Sensitivity (%)	Specificity (%)	Precision (%)	F1-Score (%)
0	98.7031	99.4803	96.4197	97.5481
1	81.2218	97.2090	85.9148	83.5024
2	92.6513	98.6761	92.7975	92.7243
3	94.4772	98.8334	93.2967	93.8832
4A	98.0845	99.8084	97.6246	97.8540
4B	98.7997	99.7858	97.7077	98.2507
4C	99.1560	99.7731	98.0885	98.6194
5	99.3924	99.6176	97.6212	98.4989
Mean	95.3107	99.1480	94.9339	95.1101
Accuracy (%)	94.2171			

ภาพประกอบ 11 Performance Model (K.-J. Tsai et al., 2022)

หมายเหตุ. จาก A High-Performance Deep Neural Network Model for BI-RADS
Classification of Screening Mammography โดย (K.-J. Tsai et al., 2022)

9.บทความ Deep Learning Based Framework for Breast Cancer Mammography Classification Using Resnet50 (Dash et al., 2022)

งานวิจัยนี้เป็นการศึกษาการใช้โครงข่ายประสาทเทียมแบบ Convolutional Neural Network (CNN) เพื่อดึงคุณลักษณะที่มีความหนาแน่นต่างกัน และเพื่อแยกความแตกต่างระหว่างบริเวณปกติและบริเวณที่น่าสงสัยในการตรวจ Mammogram และมีการเปรียบเทียบประสิทธิภาพของโมเดลในการทำนาย ได้แก่ VGG-16, MobileNetV2 และ ResNet50 โดยมีประสิทธิภาพความแม่นยำในการทดสอบเป็นดังนี้ 97.22%, 98.61% และ 100.00% สำหรับ VGG-16, MobileNetV2 และ ResNet50 ตามลำดับ

จากงานวิจัยที่เกี่ยวข้องที่ได้กล่าวมาข้างต้นนี้ทำให้ผู้วิจัยมีความสนใจจะศึกษาเรื่องการจำแนกผลตรวจจากภาพแมมโมแกรม(BI-RADS) เพราะว่า เห็นความสำคัญในเรื่องของการตรวจคัดกรองมะเร็งเต้านมเป็นประจำซึ่งจะช่วยเพิ่มโอกาสในการตรวจพบมะเร็งตั้งแต่ระยะเริ่มต้นและสามารถรักษาให้หายขาดได้ ซึ่งถ้าสามารถสร้าง ระบบจำแนก BI-RADS แบบอัตโนมัติได้ จะทำให้ประชาชนกลุ่มเสี่ยงเข้าถึงการรักษาได้รวดเร็วขึ้น รวมถึงเทคนิควิธีการจัดการปัญหาเกี่ยวกับข้อมูลภาพ Mammogram สำหรับใช้ฝึกฝนและทดสอบแบบจำลองอย่างมีประสิทธิภาพ


บทที่ 3

การดำเนินงานวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการตามขั้นตอนดังนี้

- 3.1 กระบวนการทำงานของแบบจำลอง
- 3.2 ชุดข้อมูล (Dataset)
- 3.3 การสำรวจข้อมูล (Exploratory Data Analysis: EDA)
- 3.4 การเตรียมข้อมูล
- 3.5 การสร้างแบบจำลอง
- 3.6 การวัดประสิทธิภาพของแบบจำลอง

3.1 กระบวนการทำงานของแบบจำลอง



ภาพประกอบ 12 Flow diagram of BI-RADS Classification in Mammogram using Deep Convolutional Neural Network

กระบวนการในการพัฒนาแบบจำลองเพื่อจำแนกระดับความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS ด้วยภาพ Mammogram ซึ่งงานวิจัยนี้จะใช้เป็นภาพ Full Mammogram ทำการนำเข้าข้อมูลภาพ Mammogram ตามกลุ่มเป้าหมายระดับความเสี่ยงของรอยโรคเต้านม (BI-RADS) ประกอบไปด้วย Target Output คือ BI-RADS 1, BI-RADS 2, BI-RADS 3, BI-RADS 4 และ BI-RADS 5 และปรับขนาดรูปภาพให้เท่ากับ input ของโมเดล คือ 224 x 224 pixel หลังจากนั้นทำการสำรวจข้อมูลในมุมมองต่าง ๆ (Exploratory Data Analysis : EDA) พบว่า มีปัญหาความไม่สมดุลกันของข้อมูล (Imbalance Data) จึงได้แก้ไขปัญหาดังกล่าวในขั้นตอนการเตรียมข้อมูล (Image Pre-processing) ด้วยการใช้เทคนิค Under-Sampling

หลังจากนั้นทำการเสริมข้อมูล (Data Augmentation) และด้วยความที่เป็นปัญหาแบบ Multi-Class Classification กับรอยโรคขนาดเล็กที่อาจจะต่างกันเพียงเล็กน้อยนั้นเป็นความท้าทายอย่างมากที่โมเดลจะสามารถ Classify ได้อย่างถูกต้อง ในการทำการเสริมข้อมูล (Data Augmentation) นั้น จะใช้ไลบรารีที่มีความสามารถในการปรับแต่งภาพและการเพิ่มความหลากหลายให้กับชุดข้อมูลภาพ โดยมีการสนับสนุนคุณลักษณะที่หลากหลาย เช่น การเพิ่ม CLAHE (Contrast Limited Adaptive Histogram Equalization) เพื่อช่วยเน้นคุณลักษณะข้อมูลที่สำคัญของภาพให้เด่นชัดขึ้น จากนั้นแบ่งชุดข้อมูลเป็น Training Data 80 % และ Testing Data 20 % (Test 10% , Validation 10%) เพื่อนำ Training Data ไปสร้างโมเดล Deep CNN ด้วยการ Transfer Learning โครงสร้างบางส่วน ของ ResNet50 และ VGG16 มาปรับใช้กับการศึกษา จากนั้นประเมินประสิทธิภาพของแบบจำลองจากค่า Accuracy, F1-Score และ Recall

3.2 ชุดข้อมูล (Dataset)


VinDr-Mammo (Vietnamese dataset of digital mammography)(Nguyen et al., 2023) เป็นชุดข้อมูลสาธารณะขนาดใหญ่ที่เปิดเผยต่อสาธารณะ สำหรับการวินิจฉัยโรคโดยใช้คอมพิวเตอร์ช่วยในการตรวจแมมโมแกรมดิจิทัลแบบเต็มฟิลด์ (full-field digital mammography) ของประชาชนชาวเวียดนามจำนวน 5,000 กรณีศึกษา ได้ภาพ Full-Field Mammogram จำนวน 20,000 ภาพ โดยแต่ละกรณีจะมีลักษณะมุมมองที่เป็นมาตรฐานของภาพแมมโมแกรม 4 แบบ ได้แก่ ด้านตรง Craniocaudal view หรือ CC view จำนวน 2 แบบ คือ Left Craniocaudal view, Right Craniocaudal view และแนวเอียง Mediolateral oblique view หรือ MLO view จำนวน 2 แบบ คือ Left Mediolateral oblique view, Right Mediolateral oblique view โดยจุดเด่นของข้อมูลนี้ คือ มีวัตถุประสงค์หลักเพื่อประเมินการรายงานและระบบข้อมูลการถ่ายภาพ Mammogram (BI-RADS) ซึ่งสอดคล้องกับการศึกษาวิจัยนี้

3.3 การสำรวจข้อมูล (Exploratory Data Analysis : EDA)

3.3.1 จากการทำการสำรวจข้อมูล (Exploratory Data Analysis : EDA) พบว่าจำนวนภาพ Full-Field Mammogram จำแนกตาม BI-RADS 1-5 ซึ่งเป็นกลุ่มเป้าหมายที่ผู้วิจัยต้องการจะศึกษาในการวิจัยครั้งนี้พบว่า ข้อมูลภาพ Full-Field Mammogram และพบปัญหา Imbalanced BI-RADS Classes ส่วนใหญ่เป็นข้อมูล BI-RADS 1 มากที่สุด โดยที่แต่ละ View ของภาพ Mammogram มีจำนวนไม่ต่างกันมากนัก โดยมีรายละเอียดจำนวนภาพจำแนกตาม BI-RADS และ VIEW ดังนี้

ตาราง 1 จำนวนภาพ Full-Field Mammogram จำแนกตาม BI-RADS 1-5


BI-RADS	CC View	MLO View
BI-RADS 1	6,703	6,703
BI-RADS 2	2,339	2,337
BI-RADS 3	465	465
BI-RADS 4	381	381
BI-RADS 5	113	113



ภาพประกอบ 13 จำนวนภาพ Full-Field Mammogram จำแนกตาม BI-RADS 1-5


3.3.2 เนื่องจากจำนวนภาพ Full-Field Mammogram แต่ละ View มีจำนวนเท่ากัน โดยภาพ Full-Field Mammogram แนวเฉียง Mediolateral oblique view หรือ MLO view นั้นจะเป็นภาพที่เห็นเงาของกล้ามเนื้อหน้าอก (pectoralis muscle) ที่ค่อนข้างชัดเจน และกล้ามเนื้อหน้าอกนั้นเป็นบริเวณที่ไม่เกี่ยวข้องกับการจำแนกผลตรวจ BI-RADS

ทำให้สำหรับการศึกษานี้ผู้วิจัยจึงได้เลือกศึกษาเฉพาะภาพ Full-Field Mammogram ด้านตรง Craniocaudal view หรือ CC view




ภาพประกอบ 14 ตัวอย่างภาพ Full-Field Mammogram CC View และ MLO View


3.3.3 เมื่อทำการสำรวจข้อมูลภาพ Full-Field Mammogram เฉพาะที่เป็นด้านตรง Craniocaudal view (CC View) ทำให้พบว่ามี ข้อมูลภาพ Full-Field Mammogram ที่ไฟล์ข้อมูล ผิดปกติซึ่งเป็นไฟล์ภาพว่างเปล่า (blank image) จำนวน 6 ภาพ ทำให้มีข้อมูลภาพ Full-Field Mammogram ที่เป็น CC View สำหรับการศึกษานี้ครั้งนี้ ตามรายละเอียดดังนี้




ภาพประกอบ 15 จำนวนภาพ Full-Field Mammogram CC View




ภาพประกอบ 16 ตัวอย่างภาพ Mammogram CC View BI-RADS 1




ภาพประกอบ 17 ตัวอย่างภาพ Mammogram CC View BI-RADS 2



ภาพประกอบ 18 ตัวอย่างภาพ Mammogram CC View BI-RADS 3




ภาพประกอบ 19 ตัวอย่างภาพ Mammogram CC View BI-RADS 4




ภาพประกอบ 20 ตัวอย่างภาพ Mammogram CC View BI-RADS 5

3.3.4 สำหรับการสำรวจข้อมูลภาพ Full-Filed Mammogram นอกจากการจำแนกตาม BI-RADS 1, BI-RADS 2, BI-RADS 3, BI-RADS 4 และ BI-RADS 5 แล้ว ยังพบว่าข้อมูลภาพ Full-Filed Mammogram มีอีกคุณสมบัติหนึ่งที่มีความสำคัญต่อการทดลอง ก็คือ ระดับความหนาแน่นเต้านม (Density Level) และพบว่า ข้อมูลภาพ Full-Filed Mammogram ส่วนใหญ่เป็น BI-RADS 1 ที่มีความหนาแน่นเต้านมในระดับ Density C โดยมีรายละเอียดของการจำแนกตาม BI-RADS 1, BI-RADS 2, BI-RADS 3, BI-RADS 4 และ BI-RADS 5 และ Density Level ดังภาพต่อไปนี้




ภาพประกอบ 21 จำนวนภาพ Full-Field Mammogram
จำแนกตาม BI-RADS 1-5 และ Density Level




ภาพประกอบ 22 Mammogram CC View BI-RADS 1 Density C


BI-RADS: BI-RADS 2 - Density: DENSITY C



BI-RADS: BI-RADS 2 - Density: DENSITY C




BI-RADS: BI-RADS 2 - Density: DENSITY C




ภาพประกอบ 23 Mammogram CC View BI-RADS 2 Density C


BI-RADS: BI-RADS 3 - Density: DENSITY C



BI-RADS: BI-RADS 3 - Density: DENSITY C




BI-RADS: BI-RADS 3 - Density: DENSITY C




ภาพประกอบ 24 Mammogram CC View BI-RADS 3 Density C


BI-RADS: BI-RADS 4 - Density: DENSITY C




BI-RADS: BI-RADS 4 - Density: DENSITY C



BI-RADS: BI-RADS 4 - Density: DENSITY C




ภาพประกอบ 25 Mammogram CC View BI-RADS 4 Density C



ภาพประกอบ 26 Mammogram CC View BI-RADS 5 Density C

3.4 การเตรียมข้อมูล

ในขั้นตอนการเตรียมข้อมูลนี้ ผู้วิจัยได้ใช้ข้อมูลภาพ Full-Field Mammogram จาก VinDr-Mammo โดยนำข้อมูลภาพเข้ามาจาก Kaggle : VinDr-Mammo dataset (Ghahroudi, 2024) เนื่องจากมีการดำเนินการแปลงไฟล์ข้อมูลภาพจาก .DICOM เป็น .png เรียบร้อยแล้ว ทำให้สะดวกและเหมาะสมสำหรับการนำมาใช้ในการศึกษานี้ โดยใช้รายละเอียดข้อมูลเกี่ยวกับการจำแนก BI-RADS ในไฟล์ที่มีชื่อว่า finding_annotations.csv และนำเข้าข้อมูลภาพแมมโมแกรม จากโฟลเดอร์ Processed_Images ดังภาพประกอบ 27



ภาพประกอบ 27 Data Explorer Kaggle : VinDr-Mammo dataset

จากโฟลเดอร์ Processed_Images จะมีโครงสร้างในการจัดเก็บข้อมูลภาพแมมโมแกรม study_id ละ 4 ภาพ หมายถึง 4 มุมมาตรฐานในการตรวจแมมโมแกรม นั่นคือ LMLO, RMLO, LCC, RCC ดังภาพประกอบ 28

```

Processed_Images
---->study_id
----->image_id.png (R-CC)
----->image_id.png (R-MLO)
----->image_id.png (L-CC)
----->image_id.png (R-MLO)
---->study_id

```

ภาพประกอบ 28 Processed_Images folder structure

จากนั้นเลือกเฉพาะข้อมูลภาพแมมโมแกรมด้านตรง (Craniocaudal view - CC) มาใช้ในการศึกษาวิจัยครั้งนี้

เมื่อนำเข้าข้อมูลภาพแมมโมแกรมและเตรียมข้อมูลเบื้องต้นแล้ว ผู้วิจัยได้ศึกษาหาวิธีการปรับปรุงข้อมูล โดยมีรายละเอียดในขั้นตอนการเตรียมข้อมูล ดังนี้

3.4.1 การครอบตัดรูปภาพต้นฉบับ (Cropping the Original Image) โดยทำการครอบตัดจุดภาพ (Pixel) เฉพาะจากด้าน บน ล่าง ซ้าย และขวาของรูปภาพต้นฉบับ เพื่อลบขอบเขตที่ไม่ต้องการ

3.4.2 การใช้ตัวกรองค่ามัธยฐานเพื่อบลจุดรบกวน (Applying Median Filter to Remove Noise) ในการลบจุดรบกวนออกจากภาพที่ครอบตัด จะใช้ตัวกรองค่ามัธยฐานที่มีขนาดเคอร์เนล 5x5 พิกเซล ซึ่งจะช่วยให้ภาพเรียบและลบจุดรบกวน (Noise) ในขณะที่ยังคงรักษาขอบและรายละเอียดไว้


3.4.3 การทำมาสก์เต้านม (Obtaining the Breast Mask) มาสก์จะเน้นเฉพาะบริเวณเต้านมในภาพ Full-Field Mammogram และใช้เพื่อแบ่งเนื้อเยื่อเต้านมออกจากพื้นหลัง

3.4.4 การใช้มาสก์เต้านมกับภาพต้นฉบับ (Applying the Breast Mask to the Original Image) โดยการดำเนินการนี้จะแยกเนื้อเยื่อเต้านมออกจากพื้นหลัง ทำให้ภาพเต้านมถูกแบ่งส่วน

3.4.5 การครอบตัดตามขนาดรูปร่างที่ใหญ่ที่สุด (Cropping Based on Largest Contour Size) สำหรับขั้นตอนนี้จะช่วยในการลบจุดภาพพื้นหลังที่เหลืออยู่และเน้นเฉพาะที่บริเวณเต้านมเพียงอย่างเดียว

3.4.6 การสร้างภาพสี่เหลี่ยมจัตุรัส (Creating a square image) ในขั้นตอนนี้ต้องการสร้างภาพสี่เหลี่ยมจัตุรัสโดยให้ภาพต้นฉบับอยู่ตรงกลาง โดยมีเส้นขอบสีดำล้อมรอบ จากนั้นปรับขนาดให้เป็นตามที่ต้องการและเหมาะสมสำหรับใช้ออกแบบการทดลอง (256, 256)

ตัวอย่างผลลัพธ์ของการปรับปรุงข้อมูลภาพ Full-Field Mammogram แต่ละขั้นตอนที่ได้กล่าวมาข้างต้น มีดังนี้




ภาพประกอบ 29 ตัวอย่างผลลัพธ์ของการปรับปรุงข้อมูลภาพ Full-Field Mammogram
สำหรับขั้นตอน 3.4.1-3.4.6

3.4.7 การจัดการความไม่สมดุลของข้อมูลภาพ (imbalance dataset) ในงานวิจัยนี้จะทดลองทำการสุ่มตัวอย่างลด (Random Undersampling) กลุ่มส่วนมาก เพื่อแก้ปัญหา Class imbalanced ที่มีจำนวนภาพใน Class BI-RADS 1, BI-RADS 2 มากกว่า Class BI-RADS 3, BI-RADS 4 และ BI-RADS 5 โดยมีรายละเอียด ดังนี้

Total CC View image		Selected CC view images randomly	
view_position	CC	view_position	CC
breast_birads		breast_birads	
BI-RADS 1	6702	BI-RADS 1	2250
BI-RADS 2	2337	BI-RADS 2	2250
BI-RADS 3	465	BI-RADS 3	450
BI-RADS 4	378	BI-RADS 4	375
BI-RADS 5	113	BI-RADS 5	113

ภาพประกอบ 30 จำนวนข้อมูลที่ผ่านการทำ Random Undersampling

3.4.8 การแบ่งชุดข้อมูล โดยการแบ่งข้อมูลเป็นชุดข้อมูลการฝึก (train set) และชุดข้อมูลทดสอบ (test set) โดยใช้ train_test_split from sklearn.model_selection กำหนดให้เป็น Train set 80% , Test set 20 % (Test 10% , Validation 10%) จะได้จำนวนข้อมูล ดังนี้



ภาพประกอบ 31 การแบ่งชุดข้อมูล

โดยมีโครงสร้างการจัดเก็บข้อมูลเป็น ไดเรกทอรีหลักชื่อ "large_set" ซึ่งอยู่ภายใต้ไดเรกทอรี "./VinDr-Mammo" โดยภายในไดเรกทอรี "large_set" มีไดเรกทอรีย่อย 3 รายการ: "train", "test" และ "validation" และแต่ละไดเรกทอรีย่อยเหล่านี้ประกอบด้วย 5 ไดเรกทอรีย่อยที่สอดคล้องกับคลาส "BI_RADS1", "BI_RADS2", "BI_RADS3", "BI_RADS4" และ "BI_RADS5" แสดงถึงคลาสของข้อมูลภายในแต่ละชุดข้อมูล ดังภาพประกอบ 32

```

./VinDr-Mammo/large_set
├── train
│   ├── BI_RADS1
│   ├── BI_RADS2
│   ├── BI_RADS3
│   ├── BI_RADS4
│   └── BI_RADS5
├── test
│   ├── BI_RADS1
│   ├── BI_RADS2
│   ├── BI_RADS3
│   ├── BI_RADS4
│   └── BI_RADS5
└── validation
    ├── BI_RADS1
    ├── BI_RADS2
    ├── BI_RADS3
    ├── BI_RADS4
    └── BI_RADS5
  
```

ภาพประกอบ 32 Dataset folder structure

3.4.9 การเสริมข้อมูล (Data Augmentation) จากการทำ Random Undersampling ไปในข้างต้นนั้น จะเห็นว่าข้อมูลก็ยังคงมีจำนวนที่แตกต่างกันอยู่มาก จึงได้เสริมด้วยการทำ Data Augmentation เพิ่ม ด้วยการใช้ Albumentations ซึ่งเป็นไลบรารี (library) สำหรับการปรับแต่งภาพที่ใช้งานง่ายและสามารถประมวลผลได้เร็วในการเตรียมข้อมูล Training Set สำหรับฝึกฝน Machine Learning Model โดยส่วนใหญ่จะใช้ในงาน Computer Vision และ Deep Learning ด้วยการปรับแต่งคุณลักษณะ ที่กำหนดให้ albumentations as A ดังนี้

A.RandomCrop(224, 224)

A.ShiftScaleRotate

(shift_limit=0.0625,scale_limit=0.2, rotate_limit=30, p=0.8)


A.OneOf([...], p=0.8)

A.CLAHE(clip_limit=3)

A.VerticalFlip(p=0.7)


A.HorizontalFlip(p=0.7)

จะได้จำนวนข้อมูล ดังรายละเอียดต่อไปนี้



	train	# augmented versions per an input image.	Total images
Bi-RADS1	1800	2	3600
Bi-RADS2	1800	2	3600
Bi-RADS3	360	10	3600
Bi-RADS4	300	12	3600
Bi-RADS5	90	40	3600
	test	# augmented versions per an input image.	Total images
Bi-RADS1	225	2	450
Bi-RADS2	225	2	450
Bi-RADS3	45	10	450
Bi-RADS4	37	12	444
Bi-RADS5	11	40	440
	validation	# augmented versions per an input image.	Total images
Bi-RADS1	225	2	450
Bi-RADS2	225	2	450
Bi-RADS3	45	10	450
Bi-RADS4	38	11	418
Bi-RADS5	12	38	456

ภาพประกอบ 33 การเสริมข้อมูล (Data Augmentation)



ภาพประกอบ 34 ตัวอย่างข้อมูลภาพจากการทำ Data Augmentation

3.5 การสร้างแบบจำลอง

ในการการสร้างแบบจำลองผู้วิจัยได้ใช้การ Transfer Learning จาก VGG16 และ ResNet50 โดยใช้ pre-trained model เป็นตัวจัดแบ่งหมวดหมู่ (classifier) ซึ่งเป็นกระบวนการที่นำโมเดลที่เทรนไว้ก่อนแล้วในโดเมนหนึ่งมาใช้งานหรือโดเมนอื่น ๆ โดยการปรับแต่งหรือเพิ่มชั้นบางชั้นเพื่อให้โมเดลสามารถทำงานกับงานใหม่ได้ โดยในการทดลองนี้นั้นได้ปรับ Fully Connected / Dense Layers ซึ่งเป็น Layer ที่ Neurons เชื่อมต่อกับ Neurons ทุกตัวใน Layer ก่อนหน้า Output Layer โดยใช้ Activation Function = SOFTMAX และ Output = 5 นั่นคือ Target Classes BI-RADS 5 Classes (BI-RADS 1, BI-RADS 2, BI-RADS 3, BI-RADS 4 และ BI-RADS 5) ที่เป็นกลุ่มเป้าหมายที่ผู้วิจัยต้องการจะศึกษา โดยมีการกำหนด Hyperparameters ที่สำคัญ ดังนี้

ตาราง 2 Hyperparameters ที่สำคัญในการการสร้างแบบจำลอง

Hyperparameters	Value
Learning Rate	0.0001
Batch Size	64
Number of Epochs	50
Optimizer	Adam
Loss Function	categorical_crossentropy
Activation Function	softmax

สำหรับการใช้ Transfer learning ช่วยลดเวลาการฝึกโมเดล Deep learning ด้วยการนำบางส่วน of โมเดลที่ฝึกฝนเรียบร้อยแล้วกับงานที่ใกล้เคียงกันมาใช้เป็นส่วนหนึ่งของโมเดลใหม่ สำหรับโมเดลที่นำมาใช้ในงานวิจัยนี้คือ ResNet50 และ VGG16 ซึ่งเป็น 2 โมเดลที่มีประสิทธิภาพสูงและได้รับการยอมรับอย่างแพร่หลายในการจำแนกประเภทภาพ ดังนั้นการนำเอาส่วนหนึ่งของโมเดลที่ถูกฝึกไว้แล้วจาก ResNet50 หรือ VGG16 มาใช้ในงานวิจัยจะช่วยให้สามารถลดเวลาในการฝึกโมเดลใหม่และมีโมเดลที่มีประสิทธิภาพในเวลาสั้นๆได้ การ Transfer Learning จาก VGG16 และ ResNet50 โดยใช้ pre-trained model มีโครงสร้าง ดังนี้

ตาราง 3 โครงสร้าง VGG16 with pre-trained Model

Layers(Type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
VGG16 model with pre-trained layers	
Flatten Layer	(None, 25088)
Fully connected Layer 1	(None, 4096)
Fully connected Layer 2	(None, 4096)
Dense Layer	(None, 5)
Activation Function	Softmax
Optimizers	Adam

ตาราง 4 โครงสร้าง ResNet50 with pre-trained Model

Layers (Type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
ResNet50 model with pre-trained layers	
Dense Layer	(None, 5)
Activation Function	Softmax
Optimizers	Adam

จากนั้นทดลองปรับแต่งโมเดลเพื่อทำการ Tuning ด้วยการปรับแต่งโมเดลต่อจาก base_model เดิม โดยทดลองทำการ Tuning ลักษณะเดียวกันใน VGG16 และ ResNet50 ด้วยการเพิ่ม GlobalAveragePooling2D layer และ Fully connected layers with BatchNormalization and Dropout และทำการทดลองฝึกฝนโมเดลใหม่ จากนั้นประเมินประสิทธิภาพของโมเดล โดยมีรายละเอียดในการปรับแต่งโมเดล ดังนี้

```
# Create a new model and add the pre-trained base_model
model = tf.keras.Sequential()
model.add(base_model)

# GlobalAveragePooling2D layer
model.add(tf.keras.layers.GlobalAveragePooling2D())

# Fully connected layers with BatchNormalization and Dropout
model.add(tf.keras.layers.Dense(256, activation='relu'))
model.add(tf.keras.layers.BatchNormalization())
model.add(tf.keras.layers.Dropout(0.5))


model.add(tf.keras.layers.Dense(128, activation='relu'))
model.add(tf.keras.layers.BatchNormalization())
model.add(tf.keras.layers.Dropout(0.5))

model.add(tf.keras.layers.Dense(64, activation='relu'))
model.add(tf.keras.layers.BatchNormalization())
model.add(tf.keras.layers.Dropout(0.5))

# Output layer for multi-class classification with softmax activation
model.add(tf.keras.layers.Dense(5, activation='softmax'))
```

ภาพประกอบ 35 ตัวอย่าง Source Code ทำการ Tuning Model

จากนั้นทดลองสร้างแบบจำลองด้วยการ Transfer Learning โดยใช้ pre-trained model จาก VGG16 เหมือนกับที่ใช้ในการจำแนกระดับ BI-RADS แต่เปลี่ยน Target Classes เป้าหมายให้เป็นเรื่องของ Density โดย Output = 4 ใน Dense Layer สุดท้าย นั่นคือ Density 4 Classes (Density A, Density B, Density C และ Density D) โดยใช้ Small Data Set ด้วยการ Random Undersampling จาก Dataset เดิม (Training 800 image/class , Testing 200 image/class) โดยมีรายละเอียดดังภาพต่อไปนี้



ภาพประกอบ 36 Small Data Set for Classify Density

3.6 การวัดประสิทธิภาพของแบบจำลอง

นำข้อมูลชุดทดสอบ (Test Data) ที่ได้จากขั้นตอนการเตรียมข้อมูลมาทดสอบกับแบบจำลองด้วยการ Transfer Learning จาก VGG16 และ ResNet50 โดยใช้ pre-trained model เป็นตัวจัดแบ่งหมวดหมู่ (classifier) และทดลองทำการ Fine-tuning เพื่อเปรียบเทียบประเมิณประสิทธิภาพของแบบจำลองโดยใช้ Classification report , Confusion Matrix เพื่อดำหนดค่า Accuracy, Recall และ F1-Score

บทที่ 4

ผลการดำเนินงานวิจัย

ในการวิจัยเพื่อศึกษาการสร้างแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) ที่สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม โดยใช้เทคนิค Deep Convolutional Neural Networks (CNN) รวมถึงเปรียบเทียบการทำงานของแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) และประเมินประสิทธิภาพของแบบจำลองแต่ละชนิด โดยใช้ข้อมูลข้อมูลภาพแมมโมแกรม (Mammogram) จาก Open Dataset VinDr-Mammo (Vietnamese dataset of digital mammography)) ที่เป็นภาพ Full-Field Mammogram CC View ผู้วิจัยได้ดำเนินการวิจัยโดยการศึกษามากกว่าการและขั้นตอนการวิจัยต่าง ๆ ตลอดจนการวัดประสิทธิภาพเพื่อให้บรรลุวัตถุประสงค์ของการวิจัยที่ได้กำหนดไว้ ดังนี้

4.1 ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram

4.2 ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram ที่มีการปรับแต่งแบบจำลอง (Tuning)

4.3 ผลลัพธ์ของการจำแนกระดับ Density จากภาพ Full-Field Mammogram


4.4 เปรียบเทียบการทำงานของแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) และประเมินประสิทธิภาพของแบบจำลองแต่ละชนิด

4.1 ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram

ในการทดลองสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning โดยใช้ pre-trained model เป็นตัวจัดแบ่งหมวดหมู่ (Classifier) ระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View ที่ผ่านกระบวนการปรับปรุงข้อมูลภาพ Image Preprocessing เรียบร้อยแล้ว ผู้วิจัยได้ทำการทดลองใช้ Deep Convolutional Neural Networks (CNN) ทั้งหมด 2 Models คือ VGG16 และ ResNet50 ซึ่งเป็นโมเดล CNN ที่มีประสิทธิภาพสูงและได้รับความนิยมในวงการ Computer Vision มาใช้ทดลองในการศึกษาวิจัยนี้ โดยมีผลลัพธ์ที่ได้จากการทดลอง ดังตาราง 5 และภาพประกอบที่ 24


ตาราง 5 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก VGG16

BIRADS	Precision	Recall	F1-Score	Support
1	0.34	0.34	0.34	450
2	0.36	0.26	0.30	450
3	0.31	0.37	0.34	450
4	0.31	0.31	0.31	444
5	0.55	0.59	0.57	440
Accuracy			0.37	2234
Weighted Avg	0.37	0.37	0.37	2234



ภาพประกอบ 37 Confusion Matrix ด้วยการใช้การ Transfer Learning จาก VGG16

ในการจำแนกระดับ BI-RADS




ภาพประกอบ 38 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก VGG16
ในการจำแนกระดับ BI-RADS


จากตาราง 5 ผลลัพธ์การสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning จาก VGG16 โดยใช้ pre-trained model จำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View พบว่า แบบจำลองมีประสิทธิภาพและความแม่นยำในการทำนาย โดยที่ค่า Accuracy = 0.37 และเมื่อพิจารณา ค่า Recall ในแต่ละ BI-RADS Classes พบว่า แบบจำลองสามารถทำนาย BI-RADS 5 ได้มีประสิทธิภาพดีที่สุด รองลงมาคือ BI-RADS 3 , BI-RADS 1, BI-RADS 4 และ BI-RADS 2 ตามลำดับ จากภาพประกอบ 24 จะเห็นได้ว่า แบบจำลองมีความคลาดเคลื่อนในการทำนาย BI-RADS 4 ผิดเป็น BI-RADS 3 มากที่สุด รองลงมา คือ BI-RADS 2 ผิดเป็น BI-RADS 1

ตาราง 6 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก ResNet50

BIRADS	Precision	Recall	F1-Score	Support
1	0.37	0.37	0.37	450
2	0.42	0.30	0.35	450
3	0.35	0.46	0.40	450
4	0.29	0.21	0.24	444
5	0.54	0.65	0.59	440
Accuracy			0.40	2234
Weighted Avg	0.39	0.40	0.39	2234



ภาพประกอบ 39 Confusion Matrix ด้วยการ Transfer Learning จาก ResNet50
ในการจำแนกระดับ BI-RADS



ภาพประกอบ 40 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก ResNet50
ในการจำแนกระดับ BI-RADS

จากตาราง 6 ผลลัพธ์การสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning จาก ResNet50 โดยใช้ pre-trained model เป็นตัวจัดแบ่งหมวดหมู่ (Classifier) ระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View นั้น พบว่า แบบจำลองมีประสิทธิภาพและความแม่นยำในการทำนาย โดยที่ค่า Accuracy = 0.40 และเมื่อพิจารณา ค่า Recall ในแต่ละ BI-RADS Classes พบว่า แบบจำลองสามารถทำนาย BI-RADS 5 ได้มีประสิทธิภาพดีที่สุด รองลงมาคือ BI-RADS 3 , BI-RADS 1, BI-RADS 2 และ BI-RADS 4 ตามลำดับ


จากภาพประกอบ 26 จะเห็นได้ว่า แบบจำลองมีความคลาดเคลื่อนในการทำนาย BI-RADS 4 ผิดเป็น BI-RADS 3 มากที่สุด รองลงมา คือ BI-RADS 2 ผิดเป็น BI-RADS 1

4.2 ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram ที่มีกรปรับแต่งแบบจำลอง (Tuning)


จากผลทดลองในข้อ 4.1 นั้น แสดงให้เห็นว่าแบบจำลองยังมีความคลาดเคลื่อนอยู่มากทำให้ผู้วิจัยได้ทดลองปรับแต่งโมเดล (Tuning) เพื่อเป็นการพัฒนาประสิทธิภาพของแบบจำลองด้วยการการเพิ่ม GlobalAveragePooling2D layer , ชั้น Fully connected layers , BatchNormalization และ Dropout โดยมีผลลัพธ์ที่ได้จากการทดลอง VGG16 Tuning ดังตาราง 7 และภาพประกอบ 28 ResNet50 Tuning ดังตาราง 8 และภาพประกอบ 30

ตาราง 7 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก VGG16 Tuning

BIRADS	Precision	Recall	F1-Score	Support
1	0.30	0.60	0.40	450
2	0.30	0.06	0.10	450
3	0.30	0.11	0.16	450
4	0.30	0.50	0.38	444
5	0.58	0.45	0.51	440
Accuracy			0.34	2234
Weighted Avg	0.36	0.34	0.31	2234




ภาพประกอบ 41 Confusion Matrix ด้วยการ Transfer Learning
จาก VGG16 Tuning ในการจำแนกระดับ BI-RADS




ภาพประกอบ 42 กราฟอัตราการเรียนรู้ของการ Transfer Learning
จาก VGG16 Tuning ในการจำแนกระดับ BI-RADS

ตาราง 8 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก ResNet50 Tuning

BIRADS	Precision	Recall	F1-Score	Support
1	0.41	0.33	0.36	450
2	0.43	0.26	0.32	450
3	0.32	0.43	0.37	450
4	0.29	0.34	0.32	444
5	0.50	0.54	0.52	440
Accuracy			0.38	2234
Weighted Avg	0.39	0.38	0.38	2234



ภาพประกอบ 43 Confusion Matrix ด้วยการ Transfer Learning
จาก ResNet50 Tuning ในการจำแนกระดับ BI-RADS



ภาพประกอบ 44 กราฟอัตราการเรียนรู้ของการ Transfer Learning
จาก ResNet50 Tuning ในการจำแนกระดับ BI-RADS

จากการปรับแต่งแบบจำลอง VGG16 Tuning ดังตาราง 7 และภาพประกอบ 28 และ ResNet50 Tuning ดังตาราง 8 และภาพประกอบ 30 พบว่า ทั้ง 2 แบบจำลองที่ใช้ในการทดลองนี้ เมื่อทำการปรับแต่งแบบจำลองแล้วทำนายระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ได้มีประสิทธิภาพและความแม่นยำที่ไม่ดีขึ้น นั่นคือ การพัฒนาโมเดลไม่สำเร็จ

4.3 เปรียบเทียบการทำงานของแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) และประเมินประสิทธิภาพของแบบจำลองแต่ละชนิด

จากผลการทดลองสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning ทั้ง 2 Models คือ VGG16 และ ResNet50 จำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View ที่ผ่านกระบวนการปรับปรุงข้อมูลภาพ Image Preprocessing เรียบร้อยแล้ว ผู้วิจัยได้นำผลการทดลองแต่ละแบบจำลองมาเปรียบเทียบประสิทธิภาพการจำแนกหลายประเภท (Multi-Class Classification) ของแบบจำลอง เพื่อให้เห็นว่าแบบจำลองใดเหมาะสมที่จะพัฒนาต่อยอดและปรับปรุงประสิทธิภาพต่อไป โดยมีรายละเอียดดังตาราง 9

ตาราง 9 ผลลัพธ์การเปรียบเทียบการทำงานของแบบจำลองการจำแนกระดับ BI-RADS และประเมินประสิทธิภาพของแบบจำลอง

Model		Accuracy	Recall	F1-Score
VGG16	pre-trained	37%	37%	37%
ResNet50	pre-trained	40%	40%	39%
VGG16	tuned	34%	34%	31%
ResNet50	tuned	38%	38%	38%

จากตาราง 9 พบว่า การสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning จาก ResNet50 โดยใช้ pre-trained model สามารถจำแนก ระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View ได้มีประสิทธิภาพและความแม่นยำดีที่สุดในการทดลองนี้ โดยมีค่า Accuracy 40% , Recall 40% และ F1-Score 39%

4.4 ผลลัพธ์ของการจำแนกระดับ Density จากภาพ Full-Field Mammogram


ในการทดลองโดยสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning โดยใช้ pre-trained model เป็นตัวจัดแบ่งหมวดหมู่ (Classifier) นอกจากการจำแนก ระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS แล้ว ผู้วิจัยได้ทำการทดลองจำแนก ระดับความหนาแน่นของเต้านม (Density) โดยใช้ Small Dataset ที่ได้ทำการ Random Undersampling มาจากชุด Dataset ที่ใช้ในการทดลองจำแนก ระดับ BI-RADS ในข้อ 4.1 โดยใช้แบบจำลองเดียวกันกับที่ใช้ในการจำแนก ระดับ BI-RADS โดยมีผลลัพธ์ที่ได้จากการทดลอง ดังตาราง 10 และภาพประกอบ 32

ตาราง 10 ผลลัพธ์ที่ได้จากการทดลองจำแนก ระดับความหนาแน่นเต้านม (Density) ด้วยการ Transfer Learning จาก VGG16


Density	Precision	Recall	F1-Score	Support
A	0.62	0.42	0.50	200
B	0.46	0.68	0.55	200

ตาราง 10 (ต่อ)

Density	Precision	Recall	F1-Score	Support
C	0.63	0.38	0.48	200
D	0.63	0.80	0.70	200
Accuracy			0.57	800



ภาพประกอบ 45 Confusion Matrix ด้วยการ Transfer Learning จาก VGG16
ในการจำแนกระดับ Density




ภาพประกอบ 46 กราฟอัตราการเรียนรู้ของการ Transfer Learning จาก VGG16
ในการจำแนกระดับ Density

จากตาราง 10 ผลการทดลองการสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning จาก VGG16 โดยใช้ pre-trained model จำแนกระดับความหนาแน่นของเต้านม (Density) จากภาพ Full-Field Mammogram CC View นั้น พบว่า แบบจำลองมีประสิทธิภาพและความแม่นยำในการทำนาย โดยที่ค่า Accuracy = 0.57 และเมื่อพิจารณา ค่า Recall ในแต่ละ Density Classes พบว่า แบบจำลองสามารถทำนาย Density D ได้มีประสิทธิภาพดีที่สุด รองลงมาคือ Density B, Density A และ Density C ตามลำดับ


เนื่องจากผู้วิจัยเห็นว่าผลการทดลองจำแนกระดับความหนาแน่นของเต้านม (Density) ด้วยการ Transfer Learning จาก VGG16 นั้น มีประสิทธิภาพและความแม่นยำในการทำนายที่น่าสนใจในการลองพัฒนาต่อ จึงได้ทำการทดลองเพิ่มในการประยุกต์ใช้เทคนิค CLAHE (Contrast Limited Adaptive Histogram Equalization) เพื่อปรับปรุงความคมชัดและความชัดของภาพโดยเฉพาะในพื้นที่ที่มีความเข้มข้นต่างกันอย่างมาก โดยมีผลลัพธ์ที่ได้จากการทดลอง ดังตาราง 11 และภาพประกอบ 34

ตาราง 11 ผลลัพธ์ที่ได้จากการทดลองจำแนกระดับความหนาแน่นต่ำนม (Density) ด้วยการ Transfer Learning จาก VGG16 with CLAHE

Density	Precision	Recall	F1-Score	Support
A	0.80	0.28	0.42	200
B	0.46	0.84	0.59	200
C	0.66	0.62	0.64	200
D	0.83	0.73	0.78	200
Accuracy			0.62	800



ภาพประกอบ 47 Confusion Matrix ด้วยการ Transfer Learning จาก VGG16 with CLAHE ในการจำแนกระดับ Density



ภาพประกอบ 48 กราฟอัตราการเรียนรู้ของการ Transfer Learning
จาก VGG16 with CLAHE ในการจำแนกระดับ Density

จากตาราง 11 ผลการทดลองจากการสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการใช้ Transfer Learning จาก VGG16 with CLAHE โดยใช้ pre-trained model จำแนกระดับความหนาแน่นของเต้านม (Density) จากภาพ Full-Field Mammogram CC View นั้น พบว่า แบบจำลองมีประสิทธิภาพและความแม่นยำในการทำนาย โดยที่ค่า Accuracy = 0.62 และเมื่อพิจารณา ค่า Recall ในแต่ละ Density Classes พบว่า แบบจำลองสามารถทำนาย Density B ได้มีประสิทธิภาพดีที่สุด รองลงมาคือ Density D, Density C และ Density A ตามลำดับ

ตาราง 12 ผลลัพธ์การเปรียบเทียบการทำงานของแบบจำลองการจำแนกระดับ Density และประเมินประสิทธิภาพของแบบจำลอง

Model	Accuracy	Recall	F1-Score
VGG16	57%	57%	56%
VGG16 with CLAHE	62%	62%	61%

จากตาราง 12 พบว่า สำหรับการทดลองสร้างแบบจำลอง Deep CNN ด้วยการ Transfer Learning จาก VGG16 เพื่อจำแนกระดับความหนาแน่นของเต้านม (Density) ในข้อมูลชุดเดียวกันกับที่ใช้จำแนกระดับ BI-RADS นั้น แบบจำลอง VGG16 with CLAHE ที่มีการปรับปรุงข้อมูลเพิ่มโดยการประยุกต์ใช้เทคนิค CLAHE (Contrast Limited Adaptive Histogram Equalization) มีประสิทธิภาพมากกว่าแบบจำลอง VGG16 ปกติ โดยมีประสิทธิภาพและความแม่นยำในการทำนาย Accuracy = 62% , Recall = 62% และ F1-Score = 61%

จากตาราง 9 และตาราง 12 พบว่า ในชุดข้อมูลเดียวกันที่ใช้ในการทดลองสร้างแบบจำลอง Deep CNN ด้วยการ Transfer Learning เพื่อจำแนกระดับ BI-RADS และทดลองเพิ่มในการจำแนกระดับ Density นั้น แบบจำลองมีประสิทธิภาพและความแม่นยำในการทำนายการจำแนกระดับ Density ได้ดีกว่าการจำแนกระดับ BI-RADS



บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

ในการวิจัยเพื่อศึกษาการสร้างแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) ที่สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม โดยใช้เทคนิค Deep Convolutional Neural Networks (CNN) ผู้วิจัยได้ประเมินประสิทธิภาพของแบบจำลองแต่ละชนิด เพื่อนำมาเปรียบเทียบและสรุปผลการวิจัย โดยสามารถแบ่งหัวข้อการสรุปผล ได้ดังนี้

5.1 สรุปผลการวิจัยและอภิปรายผล

5.2 ข้อเสนอแนะ

5.1 สรุปผลการวิจัยและอภิปรายผล

ในการวิจัยครั้งนี้เป็นการวิจัยเพื่อศึกษาการสร้างแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) ที่สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม โดยใช้เทคนิค Deep Convolutional Neural Networks (CNN) และเปรียบเทียบการทำงานของแบบจำลองการจำแนกหลายประเภท (Multi-Class Classification) และประเมินประสิทธิภาพของแบบจำลองแต่ละชนิด

จากผลการวิจัยในหัวข้อ 4.1 จะเห็นได้ว่าการสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning โดยใช้ pre-trained model เป็นตัวจัดแบ่งหมวดหมู่ (Classifier) ระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View นั้น ทั้ง VGG16 และ ResNet50 สามารถทำนาย BI-RADS 5 ได้มีประสิทธิภาพดีที่สุด สอดคล้องกับบทความวิจัยของ Tsai และคณะ (K. J. Tsai et al., 2022) ที่ได้ศึกษาเกี่ยวกับ A High-Performance Deep Neural Network Model for BI-RADS Classification of Screening Mammography พบว่า แบบจำลองสามารถทำนาย BI-RADS 5 ได้มีประสิทธิภาพดีที่สุด ได้ค่า Sensitivity (Recall) เท่ากับ 99.39% แสดงให้เห็นว่า การตรวจรอยโรคของเต้านมระดับ BI-RADS 5 นั้น เป็นรอยโรคที่ชัดเจนเหมาะต่อการตรวจจับลักษณะที่สำคัญ เพราะการตรวจรอยโรคของเต้านมแบบ BI-RADS 5 อาจเกิดจากมะเร็งหรือเนื้องอกที่มีลักษณะที่มักจะเป็นมะเร็งได้ในขั้นต้น โดยเป็นระดับการประเมินความเสี่ยงของมะเร็งเต้านมที่มีความเสี่ยงสูงมากกว่า 95% รวมถึงการเสริมข้อมูลภาพ (augmentation) ด้วยการหมุนภาพ 30 องศา

ซึ่งไม่ได้ทำให้แตกต่างไปจากภาพเดิมมากนัก มีประโยชน์ในการเพิ่มความหลากหลายให้กับข้อมูล ลดการเกิด overfitting ทำให้โมเดลจะมีโอกาสเจอสถานการณ์และการแปรผันในข้อมูลที่มากขึ้น อีกทั้งยังช่วยให้โมเดลเรียนรู้ลักษณะทั่วไปของภาพ Mammogram และลักษณะของเนื้อเยื่อในเต้านมได้มากขึ้น โดยทำให้โมเดลสามารถทำนายภาพ Mammogram ที่มีลักษณะเดียวกันแต่มาจากสภาพแวดล้อมหรือสภาพการเปลี่ยนแปลงที่ต่างกันซึ่งช่วยเพิ่มความแม่นยำและความเชื่อถือของโมเดลในการทำงานจริงได้ อีกทั้งแบบจำลองทั้ง 2 Models มีความคลาดเคลื่อนในการทำนาย BI-RADS 4 ผิดเป็น BI-RADS 3 มากที่สุดเหมือนกัน แสดงให้เห็นว่าข้อมูลภาพ Full-Field Mammogram BI-RADS 4 และ BI-RADS 3 มีความใกล้เคียงกันและคล้ายคลึงกันมากจนทำให้แบบจำลองทำนายคลาดเคลื่อนมากที่สุด

จากผลการวิจัยในหัวข้อ 4.2 จะเห็นได้ว่าการปรับแต่งแบบจำลอง (Tuning) VGG16 และ ResNet50 ตามรายละเอียดในหัวข้อ 3.5 โดยการเพิ่มชั้น Fully connected layers หลายชั้นช่วยให้โมเดลมีความซับซ้อนมากขึ้นและเรียนรู้ลักษณะเฉพาะของข้อมูลจากชุดข้อมูลที่ใช้ ในขณะเดียวกัน BatchNormalization และ Dropout ช่วยลดความเสี่ยงในการเกิด Overfitting อีกด้วย แต่ผลลัพธ์ของการปรับแต่งแบบจำลองลักษณะดังกล่าวไม่ได้ทำให้ประสิทธิภาพและความแม่นยำของแบบจำลองได้รับการพัฒนาขึ้น ในส่วนนี้อาจจะต้องทดลองปรับแต่งพารามิเตอร์หลากหลายแบบให้เหมาะสมกับชุดข้อมูลที่ใช้ และการทดลองปรับปรุงค่า Hyperparameters ก็มีส่วนในการพัฒนาแบบจำลองได้ หรือทดลองใช้แบบจำลองอื่นที่อาจจะเหมาะสมกับชุดข้อมูลนี้มากกว่า รวมถึงเลือกใช้แบบจำลองที่มีความซับซ้อนน้อยลงอาจช่วยเพิ่มประสิทธิภาพของแบบจำลองได้ในบางกรณีด้วย แต่สำหรับการทดลองนี้ผู้วิจัยมีข้อจำกัดในเรื่องของทรัพยากรคอมพิวเตอร์ที่ใช้ในการฝึกฝนแบบจำลอง ทำให้ไม่สามารถทดลองหรือฝึกฝนแบบจำลองให้มีความซับซ้อนได้ตามที่ควร

จากผลการวิจัยในหัวข้อ 4.3 จะเห็นได้ว่าการสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning จาก ResNet50 โดยใช้ pre-trained model สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View ได้มีประสิทธิภาพและความแม่นยำดีที่สุดในการทดลองนี้ สอดคล้องกับบทความวิจัยของ Dash และคณะ (Dash et al., 2022) ที่ได้ศึกษาเกี่ยวกับ Deep Learning Based Framework for Breast Cancer Mammography Classification Using Resnet50 เป็นการศึกษา Convolutional Neural Network (CNN) Model เพื่อดึงคุณลักษณะความหนาแน่นของเต้านม (Breast Density) ที่ต่างกัน รวมถึงแยกความแตกต่างระหว่างบริเวณ

ปกติและบริเวณที่ผิดปกติในภาพ Mammogram โดยทำการเปรียบเทียบประสิทธิภาพของแบบจำลองในการทำนาย ได้แก่ VGG-16, MobileNetV2 และ ResNet50 พบว่า ResNet50 มีประสิทธิภาพในการทำนายได้ดีกว่าแบบจำลองอื่น ๆ โดย ResNet50 มีโครงสร้างที่ซับซ้อนกว่า VGG16 โดยมีการใช้ residual connections ที่ช่วยในการฝึกและให้ประสิทธิภาพของโมเดลดีขึ้น โครงสร้างนี้ช่วยลดปัญหาของ gradient vanishing และเพิ่มความลึกของโมเดลได้โดยไม่เสียประสิทธิภาพทำให้เรียนรู้ลักษณะที่มีความซับซ้อนของภาพแมมโมแกรมได้มากขึ้นและมีประสิทธิภาพในการแยกแยะคุณลักษณะของภาพได้ดี สำหรับ VGG16 มีโครงสร้างที่เรียบง่ายและน้อยกว่า ResNet50 แต่มีจำนวนชั้นที่มากกว่าทำให้มีการคำนวณที่สูงขึ้น โดยอาจทำให้เกิดปัญหาการเกิด overfitting ได้ง่าย ส่งผลให้มีความละเอียดในการจำแนกภาพได้น้อยกว่า

จากผลการวิจัยในหัวข้อ 4.4 จะเห็นได้ว่าแบบจำลองสามารถทำนายการจำแนกระดับความหนาแน่นของเต้านม (Density) ได้มีประสิทธิภาพดีกว่าทำนายการจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS โดย BIRADS เป็นการจำแนกระดับความเสี่ยงของการกลายเป็นมะเร็งเต้านม และหนึ่งในปัจจัยที่ใช้ในการประเมิน BIRADS คือ ความหนาแน่นของเนื้อเต้านม (Breast Density) ซึ่งมีความสัมพันธ์กับการค้นพบมะเร็งเต้านมได้ สอดคล้องกับบทความวิจัยของ Chokri and Hayet Farida (2017) ที่ได้ศึกษาเกี่ยวกับ Mammographic mass classification according to Bi-RADS lexicon จากผลการทดลอง พบว่า ความหนาแน่นของเนื้อเยื่อเต้านม (Breast Density) บนภาพ Mammogram เป็นหนึ่งในปัจจัยสำคัญในการจำแนกระดับ BI-RADS โดยความหนาแน่นของเนื้อเต้านมสามารถมองเห็นได้จากภาพ Mammogram โดยมีการจำแนกเป็นหลายระดับ (Density A,B,C,D) และมีผลต่อการประเมินระดับ BI-RADS ได้ ทำให้แบบจำลองมีความคลาดเคลื่อนในการจำแนกเนื่องจากในภาพ Mammogram นั้น ความหนาแน่นของเนื้อเยื่อมักจะแสดงอยู่ในรูปของพื้นที่สีขาวหรือพื้นผิวที่เป็นพื้นฐานของภาพ ซึ่งมักจะมีลักษณะที่เต็มไปด้วยเส้นเล็ก ๆ หรือหยดน้ำเหนือพื้นฐาน ทำให้มีความสว่างมากกว่าบริเวณที่ไม่มีเนื้อเยื่อหนาแน่น โดยเป็นลักษณะที่ใกล้เคียงกันกับรอยโรคที่บ่งบอกความเสี่ยงในการกลายเป็นมะเร็งเต้านม (BI-RADS) จึงขอแนะนำการศึกษาในอนาคตให้มีการทำ Segmentation Region of Interest (ROI) ของรอยโรคเต้านมมาศึกษาการจำแนกระดับ BI-RADS ร่วมด้วย

5.2 ข้อเสนอแนะ

จากปัญหาที่ผู้วิจัยพบในการดำเนินการวิจัยครั้งนี้ทั้งหมด สามารถสรุปได้ ดังนี้

1. ปัญหาหลักและปัญหาใหญ่ที่สุดสำหรับการวิจัยนี้ คือ การรวบรวมข้อมูลภาพ Mammogram จากแหล่งที่มาที่เหมาะสม เช่น โรงพยาบาล เป็นเรื่องที่ทำหายมากเนื่องจากต้องมีการเข้าถึงและการอนุญาตจากหน่วยงานหรือสถาบันที่เก็บรักษาข้อมูลเหล่านั้น และอาจไม่ได้รับความร่วมมือในการให้ข้อมูลอีกด้วย แต่ก็มีวิธีแก้ปัญหาดังกล่าว คือ การใช้ Open Dataset รวมถึงต้องมีความหลากหลายของข้อมูลและมีจำนวนข้อมูลมากพอให้เหมาะสมกับวัตถุประสงค์ของการศึกษา

2. ลักษณะของข้อมูลภาพ Mammogram ไม่ได้อยู่ภายใต้หลักเกณฑ์เดียวกัน เช่น ความคมชัด ความสว่างของภาพ มุมการถ่ายต่าง ๆ และจำนวนจุดสี (Pixel) ของภาพที่ไม่เท่ากัน หรือการมีสิ่งปะปนอื่นบนภาพ โดยจำเป็นต้องมีการทำ Image preprocessing ให้ดีเพื่อที่จะช่วยให้แบบจำลอง CNN ทำนายผลได้อย่างแม่นยำและมีประสิทธิภาพ และช่วยให้ผลลัพธ์ที่ได้มีความเชื่อถือสูงในการใช้ในประชาชน

3. เนื่องจากรอยโรคที่ใช้ในการจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS มีขนาดเล็ก ประกอบกับหนึ่งในปัจจัยที่ใช้ในการประเมิน BIRADS คือ ความหนาแน่นของเนื้อเต้านม (Breast Density) ที่ทำให้แบบจำลองทำนายคลาดเคลื่อน ผู้วิจัยขอแนะนำการปรับปรุงการศึกษาในอนาคตให้มีการทำ Segmentation Region of Interest (ROI) ของรอยโรคเต้านม รวมถึงการปรับปรุงข้อมูลภาพด้วยเทคนิค Image Enhancement เพื่อเน้นรอยโรคในภาพ Full-Field Mammogram ให้มีความชัดเจนขึ้น นำมาใช้ในการจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS

3.การสร้าง Convolutional Neural Network (CNN) Model แนะนำการเปรียบเทียบแบบจำลอง Deep CNN ให้มีความหลากหลายมากขึ้น และทดลองปรับแต่งพารามิเตอร์ให้เหมาะสมเพื่อพัฒนาแบบจำลองให้มีประสิทธิภาพมากขึ้น

4.การฝึกฝนแบบจำลอง (Train Model) Deep Convolutional Neural Network (CNN) ที่มีประสิทธิภาพจำเป็นต้องใช้ทรัพยากรสูง เพราะเป็นการฝึกฝนแบบจำลองด้วยชุดข้อมูลขนาดใหญ่และมีความซับซ้อนที่ต้องใช้เวลาและความแม่นยำสูงในกระบวนการฝึกฝน โดยเฉพาะ GPU ซึ่งเป็นทรัพยากรที่สำคัญในการฝึกฝนแบบจำลอง CNN เพราะสามารถประมวลผลข้อมูลได้อย่างรวดเร็วและมีประสิทธิภาพสูง เมื่อเปรียบเทียบกับ CPU

บรรณานุกรม

- Abdelrahman, L., Al Ghamdi, M., Collado-Mesa, F., and Abdel-Mottaleb, M. (2021). Convolutional neural networks for breast cancer detection in mammography: A survey. *Comput Biol Med*, 131, 104248. <https://doi.org/10.1016/j.compbiomed.2021.104248>
- American College of Radiology. (2013). *BI-RADS Atlas — Reporting System*. Retrieved March 14, 2024 from <https://www.acr.org/-/media/ACR/Files/RADS/BI-RADS/Mammography-Reporting.pdf>
- Analyticsvidhya. (2024). *10 Techniques to Solve Imbalanced Classes in Machine Learning (Updated 2024)*. Retrieved 17 March, 2024 from <https://www.analyticsvidhya.com/blog/2020/07/10-techniques-to-deal-with-class-imbalance-in-machine-learning/>
- Bendjillali, R. I., Beladgham, M., Merit, K., and Taleb-Ahmed, A. (2020). Illumination-robust face recognition based on deep convolutional neural networks architectures. *Indonesian Journal of Electrical Engineering and Computer Science*, 18, 1015-1027. Retrieved form <https://www.semanticscholar.org/paper/Illumination-robust-face-recognition-based-on-deep-Bendjillali-Beladgham/618fa61ec662812bb8d5c54860b0808f4e9422ed>
- Chokri, F., and Hayet Farida, M. (2017). Mammographic mass classification according to Bi-RADS lexicon. *IET Computer Vision*, 11(3), 189-198. <https://doi.org/10.1049/iet-cvi.2016.0244>
- Dash, P. B., Behera, H. S., and Senapati, M. R. (2022). Deep Learning Based Framework for Breast Cancer Mammography Classification Using Resnet50. *Computational Intelligence in Pattern Recognition*, Singapore.
- Ferkous, C., and Merouani, H. F. (2017). Mammographic mass classification according to Bi-RADS lexicon. *IET Comput. Vis.*, 11, 189-198. Retrieved form <https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/iet-cvi.2016.0244>

Ghahroudi, H. (2024). *Kaggle : VinDr-Mammo dataset*. Retrieved January 30, 2024 from

<https://www.kaggle.com/datasets/hadighahroudi/vindr-mammo-dataset>

Heenaye-Mamode Khan, M., Boodoo-Jahangeer, N., Dullull, W., Nathire, S., Gao, X., Sinha, G. R., and Nagwanshi, K. K. (2021). Multi- class classification of breast cancer abnormalities using Deep Convolutional Neural Network (CNN). *PLOS ONE*, 16(8), e0256500. Retrieved from

<https://journals.plos.org/plosone/article/comments?id=10.1371/journal.pone.0256500>

Khan, M. M. R., Sakib, S., Siddique, M. A. B., Chowdhury, M., Hossain, Z., Aziz, A., and Yasmin, N. (2020). Automatic Detection of COVID-19 Disease in Chest X-Ray Images using Deep Neural Networks. 2020 IEEE 8th R10 Humanitarian Technology Conference (R10-HTC),

National Cancer Institute. (2023). *Breast Cancer Screening*. Retrieved 11 March from

<https://www.cancer.gov/types/breast/patient/breast-screening-pdq>

Nguyen, H. T., Nguyen, H. Q., Pham, H. H., Lam, K., Le, L. T., Dao, M., and Vu, V. (2023). VinDr-Mammo: A large-scale benchmark dataset for computer-aided diagnosis in full-field digital mammography. *Scientific Data*, 10(1), 277.

<https://doi.org/10.1038/s41597-023-02100-7>

Pisano, E. D., Yaffe, M. J., and Kuzmiak, C. M. (2004). *Digital mammography*. Lippincott Williams and Wilkins.

Rafid, A. K. M. R. H., Azam, S., Montaha, S., Karim, A., Fahim, K. U., and Hasan, M. Z.

(2022). An Effective Ensemble Machine Learning Approach to Classify Breast

Cancer Based on Feature Selection and Lesion Segmentation Using Preprocessed Mammograms. *Biology*, 11(11), 1654. [https://www.mdpi.com/2079-](https://www.mdpi.com/2079-7737/11/11/1654)

[7737/11/11/1654](https://www.mdpi.com/2079-7737/11/11/1654)

Schönenberger, C., Hejduk, P., Ciritsis, A., Marcon, M., Rossi, C., and Boss, A. (2021).

Classification of Mammographic Breast Microcalcifications Using a Deep Convolutional Neural Network: A BI-RADS–Based Approach. *Investigative*

Radiology, 56(4), 224-231. <https://doi.org/10.1097/rli.0000000000000729>

- Tsai, K.-J., Chou, M.-C., Li, H.-M., Liu, S.-T., Hsu, J.-H., Yeh, W.-C., Hung, C.-M., Yeh, C.-Y., and Hwang, S.-H. (2022). A High-Performance Deep Neural Network Model for BI-RADS Classification of Screening Mammography. *Sensors*, 22(3), 1160.
<https://www.mdpi.com/1424-8220/22/3/1160>
- Tsai, K. J., Chou, M. C., Li, H. M., Liu, S. T., Hsu, J. H., Yeh, W. C., Hung, C. M., Yeh, C. Y., and Hwang, S. H. (2022). A High-Performance Deep Neural Network Model for BI-RADS Classification of Screening Mammography. *Sensors (Basel)*, 22(3).
<https://doi.org/10.3390/s22031160>
- Walsh, J., O' Mahony, N., Campbell, S., Carvalho, A., Krpalkova, L., Velasco-Hernandez, G., Harapanahalli, S., and Riordan, D. (2019). *Deep Learning vs. Traditional Computer Vision*. https://doi.org/10.1007/978-3-030-17795-9_10
- Xi, P., Shu, C., and Goubran, R. (2018). Abnormality Detection in Mammography using Deep Convolutional Neural Networks. *2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, 1-6. Retrieved 11 June, 2018, from Retrieve from <https://ieeexplore.ieee.org/document/8438639>

ประวัติผู้เขียน

ชื่อ-สกุล

จุฑามาศ คุณา

วุฒิการศึกษา

วิทยาศาสตรบัณฑิต สาขาเกษตรกรรม

มหาวิทยาลัยมหิดล

