

การจำแนกผลตรวจจากภาพแมมโมแกรมด้วยการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ

จุฑามาศ คุณา¹, โสภณ มงคลลักษณ์², วรพันธ์ คู่สกุลนิรันดร์³

บทคัดย่อ

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 (Cranio-caudal View : CC) จาก VinDR-Mammo ผ่านกระบวนการจัดเตรียมข้อมูลภาพด้วยการแบ่งส่วนเต้านมออกจากพื้นหลัง (Segmentation Largest Contour) แก้ปัญหาความไม่สมดุลของข้อมูล รวมถึงการเสริมข้อมูล จากนั้นใช้เทคนิคการถ่ายโอนความรู้ (Transfer Learning) จาก VGG16 และ ResNet50 เพื่อสร้างแบบจำลอง ผลการวิจัย พบว่า การสร้างแบบจำลอง 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 ได้มีประสิทธิภาพที่ดีที่สุด 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

¹ หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

² คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

³ คณะเทคโนโลยีสารสนเทศและการสื่อสาร มหาวิทยาลัยมหิดล นครปฐม 73170

* Corresponding author: Tel.: 061-1659514 E-mail address: jutamas.khu@g.swu.ac.th

BI-RADS Classification in Mammogram using Deep Convolutional Neural Network

Jutamas Khutcha^{1*}, Sophon Mongkolluksamee², Worapan Kusakunniran³

Abstract

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-RADS 5 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.

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

¹ Data Science, Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

² Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

³ Faculty of Information and Communication Technology, Mahidol University, Nakhon Pathom, 73170, Thailand

* Corresponding author: Tel.: 061-1659514 E-mail address: jutamas.khu@g.swu.ac.th


บทนำ

ปัจจุบันมะเร็งเต้านมเป็นมะเร็งที่พบบ่อยที่สุดในเพศหญิงและเป็น 1 ใน 5 อันดับแรกของสาเหตุการเสียชีวิตด้วยโรคมะเร็งของคนทั่วโลก การตรวจหามะเร็งเต้านมในระยะเริ่มต้นจะสามารถรักษาให้หายขาดและเพิ่มอัตราการรอดชีวิตได้ ซึ่งการตรวจเต้านมด้วยวิธีแมมโมแกรมเป็นวิธีตรวจคัดกรองมะเร็งเต้านมที่น่าเชื่อถือที่สุดในปัจจุบัน สามารถตรวจพบลักษณะผิดปกติในเต้านมหรือรอยโรคที่มีขนาดเล็กได้ โดยมีการรายงานผลการตรวจแมมโมแกรม ใช้ระบบ The Breast Imaging Reporting and Data system (BI-RADS) ซึ่งถูกพัฒนาขึ้นโดย The American College of Radiology to standardize mammographic reporting โดยประเมินจากความเสี่ยงต่อการเป็นมะเร็งในแต่ละกลุ่มมาช่วยในการตัดสินใจส่งตรวจชิ้นเนื้อ แม้การตรวจแมมโมแกรมจะเป็นวิธีคัดกรองมะเร็งเต้านมที่มีประสิทธิภาพสูงสุดในปัจจุบันแต่ก็มีค่าใช้จ่ายสูงค่อนข้างสูง เพราะส่วนใหญ่รังสีแพทย์มักจะทำการตรวจแมมโมแกรมร่วมกับอัลตราซาวด์ เพื่อการแปลผล BI-RADS ที่แม่นยำ ส่งผลให้ประชาชนกลุ่มเสี่ยงที่ขาดแคลนทุนทรัพย์ไม่สามารถเข้าถึงได้ การตรวจคัดกรองมะเร็งเต้านมด้วยวิธีแมมโมแกรมได้จึงเกิดการละเลยไปจนก่อนเนื้ออาจกลายเป็นมะเร็งได้ รวมถึงปัญหาการขาดแคลนรังสีแพทย์ที่มาแปลผลการตรวจแมมโมแกรมนั้นไม่เพียงพอต่อผู้รับบริการ ดังนั้นงานวิจัยนี้จึงได้ศึกษาการสร้างแบบจำลองระบบคอมพิวเตอร์ที่สามารถเรียนรู้ได้ด้วยตนเองโดยใช้ข้อมูล (Machine Learning Model) ที่สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS ด้วยภาพแมมโมแกรม โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการ (Deep Convolutional Neural Networks) และเปรียบเทียบประสิทธิภาพของแบบจำลองเพื่อนำผลลัพธ์ที่ได้มาพัฒนาต่อไป

งานวิจัยที่เกี่ยวข้อง

แม้ว่าจะมีงานวิจัยจำนวนมากไม่น้อยที่ศึกษาเกี่ยวกับการจำแนกความผิดปกติในภาพแมมโมแกรมโดยใช้ Convolutional Neural Networks (CNN) ⁽¹⁻⁵⁾ ซึ่งเป็นวิธีการที่ได้รับความนิยมมาก เนื่องจากความท้าทายของภาพแมมโมแกรมในการจำแนก BI-RADS ที่รอยโรคมีขนาดเล็กมากและมีความซับซ้อนของรูปแบบรวมถึงความหลากหลายของเนื้อเยื่อที่ปรากฏในภาพทำให้เกิดความยากลำบากในการตีความผลลัพธ์ของรังสีแพทย์ และ CNN เป็นแบบจำลองที่มีประสิทธิภาพสูงในการจำแนกภาพ โดยสามารถทำการเรียนรู้ลักษณะของรอยโรคจากข้อมูลภาพที่มีอยู่และสร้างแบบจำลองที่สามารถระบุรอยโรคที่มีขนาดเล็กได้อย่างแม่นยำ แต่ในการรวบรวมข้อมูลภาพแมมโมแกรมจากแหล่งที่มาที่เหมาะสมนั้นเป็นไปได้ยาก ทำให้การศึกษานี้จึงต้องใช้ชุดข้อมูลภาพแมมโมแกรมที่เป็นสาธารณะซึ่งมีความหลากหลายของคุณภาพข้อมูลและมีข้อมูลภาพอยู่อย่างจำกัด ผู้วิจัยจึงได้เตรียมข้อมูลภาพเพื่อทำการปรับปรุงคุณภาพของข้อมูลเพื่อให้ข้อมูลเป็นไปตามเกณฑ์ที่ต้องการและแก้ปัญหาความไม่สมดุลกันของข้อมูล รวมถึงทำการเสริมข้อมูลเพื่อสร้างข้อมูลใหม่จากข้อมูลที่มีอยู่ เพื่อให้สามารถที่จะสร้างแบบจำลอง CNN การจำแนกความเสี่ยงในการกลายเป็นมะเร็งเต้านมตามพื้นฐานหลักการ BI-RADS ได้อย่างมีความแม่นยำมากขึ้น

วิธีดำเนินการ



ภาพประกอบ 1 กระบวนการทำงาน

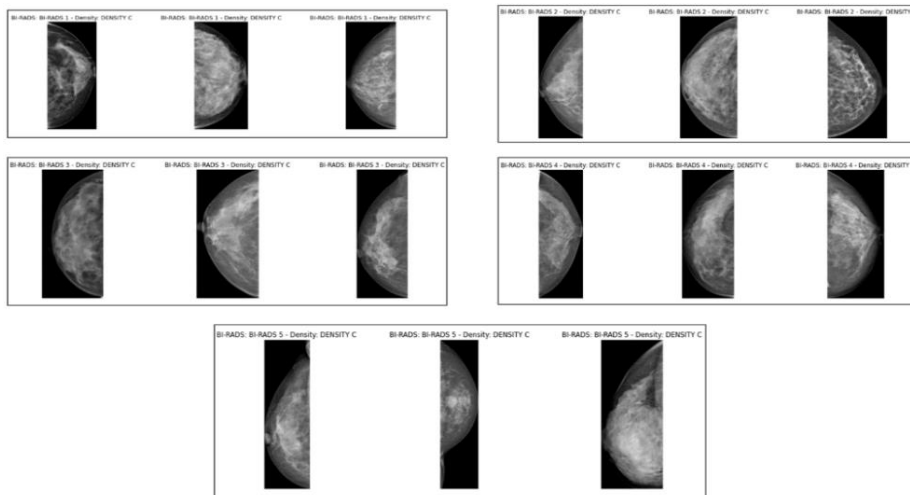
ขั้นตอนที่ 1 : แนะนำชุดข้อมูลที่ใช้ในการศึกษานี้

ผู้วิจัยใช้ข้อมูลภาพแมมโมแกรมจาก VinDr-Mammo (Vietnamese dataset of digital mammography)⁽⁶⁾ เป็นชุดข้อมูลสาธารณะขนาดใหญ่ที่เปิดเผยต่อสาธารณะ ของประชาชนชาวเวียดนามจำนวน 5,000 กรณีศึกษา ได้ภาพ Full-Field Mammogram จำนวน 20,000 ภาพ โดยแต่ละกรณีจะมีลักษณะมุมมองที่เป็นมาตรฐานของภาพแมมโมแกรม 4 แบบ ได้แก่ ด้านตรง Craniocaudal (CC) view จำนวน 2 แบบ คือ Left CC view, Right CC view และแนวเอียง Mediolateral oblique (MLO) view จำนวน 2 แบบ คือ Left MLO view, Right MLO view

ขั้นตอนที่ 2 : การนำเข้าข้อมูล ตรวจสอบข้อมูล และพิจารณาข้อมูล

นำข้อมูลภาพเข้ามาจาก Kaggle : VinDr-Mammo dataset⁽⁷⁾ ที่มีการดำเนินการแปลงไฟล์ข้อมูลภาพจาก .DICOM เป็น .png เรียบร้อยแล้ว โดยใช้รายละเอียดข้อมูลเกี่ยวกับการจำแนก BI-RADS จากนั้นเลือกเฉพาะข้อมูลภาพแมมโมแกรม CC view มาใช้ในการศึกษานี้ เพราะข้อมูลภาพแมมโมแกรม MLO view นั้นจะเป็นภาพที่ติดเงาของกล้ามเนื้อหน้าอก ซึ่งจะได้จำนวน ข้อมูลภาพ Full-Filed Mammogram CC view : BI-RADS1 6,702 ภาพ , BI-RADS2 2,337 ภาพ , BI-RADS3 465 ภาพ, BI-RADS4 378 ภาพ และ BI-RADS5 113 ภาพ


สำรวจข้อมูลภาพ Full-Filed Mammogram นอกจากการจำแนกตาม BI-RADS 1-5 แล้ว ยังพบว่า มีอีกคุณสมบัติหนึ่งที่มีความสำคัญต่อการทดลอง ก็คือ ระดับความหนาแน่นเต้านม (Density Level) และพบว่า ส่วนใหญ่เป็น BI-RADS 1 ที่มีความหนาแน่นเต้านมในระดับ Density C



ภาพประกอบ 2 ตัวอย่างภาพ Full-Filed Mammogram จำแนกตาม BI-RADS 1-5 และ Density C

ขั้นตอนที่ 3 : การเตรียมข้อมูลภาพ (Data Preprocessing)

ผู้วิจัยได้ปรับปรุงข้อมูลภาพ Full-Field Mammogram CC view ด้วยการแบ่งส่วนภาพเต้านม (Largest Contour Segmentation)



ภาพประกอบ 3 ผลลัพธ์การแบ่งส่วนภาพเต้านม (Largest Contour Segmentation)

จากนั้นแก้ปัญหาความไม่สมดุลของข้อมูลภาพ (imbalace dataset) ด้วยการสุ่มตัวอย่างลด (Random Undersampling) กลุ่มส่วนมาก ดังตาราง 1

ตาราง 1 จำนวนภาพ Full-Field Mammogram CC view การสุ่มตัวอย่างลด (Random Undersampling) ของการศึกษานี้


BI-RADS	Total CC View	Selected CC View randomly
BI-RADS 1	6,702	2,250
BI-RADS 2	2,337	2,250
BI-RADS 3	465	450
BI-RADS 4	678	375
BI-RADS 5	113	113
Total	10,295	5,438

แบ่งข้อมูลเป็นชุดข้อมูลการฝึก (train set) และชุดข้อมูลทดสอบ (test set) โดยใช้ train_test_split from sklearn.model_selection กำหนดให้เป็น Train set 80% , Test set 20 % (Test 10% , Validation 10%)

จากตาราง 1 จะเห็นว่าข้อมูลภาพก็ยังคงมีจำนวนที่แตกต่างกันอยู่มาก จึงได้เสริมด้วยการทำ Data Augmentation ได้แก่ การเลื่อนภาพ, การหมุนภาพ 30°, การพลิกภาพ, การปรับความคมชัดของภาพ ได้จำนวนภาพ ดังตาราง 2

ตาราง 2 จำนวนภาพ Full-Field Mammogram CC view การทำ Data Augmentation ของการศึกษานี้

BI-RADS	Train 80%	Test 10%	Validation 10%
BI-RADS 1	3,600	450	450
BI-RADS 2	3,600	450	450
BI-RADS 3	3,600	450	450
BI-RADS 4	3,600	444	418
BI-RADS 5	3,600	440	456
Total	18,000	2,234	2,224



ภาพประกอบ 4 ตัวอย่างผลลัพธ์จากการทำ Data Augmentation

ขั้นตอนที่ 4 : การสร้างแบบจำลองด้วยการ Transfer Learning Deep CNN สำหรับการจำแนก BI-RADS

ผู้วิจัยได้สร้างแบบจำลองการจำแนก BI-RADS ทั้งหมด 4 แบบจำลอง ด้วยการ Transfer Learning Deep Convolutional Neural Network และมีการกำหนด Hyperparameters ที่สำคัญ ได้แก่ Learning Rate = 0.0001, Batch Size = 64, Number of Epochs = 50, Optimizer = Adam, Loss Function = categorical_crossentropy และ Activation Function = softmax โดย Dense Layer = 5 นั่นคือ คลาสผลลัพธ์ BI-RADS 1-5 ดังนี้

1. แบบจำลอง VGG16 with Pretrained

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)

2. แบบจำลอง ResNet50 with Pretrained

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)

สำหรับ 3.แบบจำลอง VGG16 with tuned และ 4.แบบจำลอง ResNet50 with tuned เป็นการปรับแต่งแบบจำลองต่อจาก base_model เดิม ซึ่งผู้วิจัยทำการปรับแต่งแบบจำลองลักษณะเดียวกันใน VGG16 และ ResNet50 ด้วยการเพิ่ม GlobalAveragePooling2D layer และ Fully connected layers with BatchNormalization and Dropout 3 ชั้น

ขั้นตอนที่ 5 : การสร้างแบบจำลองด้วยการ Transfer Learning Deep CNN สำหรับการจำแนก Density

จากนั้นทดลองสร้างแบบจำลองการจำแนก Density ทั้งหมด 2 แบบจำลอง ด้วยการ 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) จะได้ 1.แบบจำลอง VGG16 with Pretrained และ 2.แบบจำลอง VGG16 with CLAHE


ผลการวิจัยและอภิปรายผลการวิจัย

1. ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram

การสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning โดยใช้ pre-trained model จำแนกความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View ทั้ง VGG16 และ ResNet50 สามารถทำนาย BI-RADS 5 ได้มีประสิทธิภาพดีที่สุด โดยมี recall เท่ากับ 59% และ 65% ตามลำดับ แสดงให้เห็นว่าการตรวจรอยโรคของเต้านม BI-RADS 5 เป็นรอยโรคที่ชัดเจนเหมาะต่อการตรวจจับลักษณะที่สำคัญได้ อีกทั้งแบบจำลองทั้ง 2 Models มีความคลาดเคลื่อนในการทำนาย BI-RADS 4 ผิดเป็น BI-RADS 3 มากที่สุดเหมือนกัน แสดงให้เห็นว่าการตรวจรอยโรคของเต้านม BI-RADS 4 และ BI-RADS 3 มีความใกล้เคียงกันและคล้ายคลึงกันมากจนทำให้แบบจำลองทำนายคลาดเคลื่อนมากที่สุด โดยผลลัพธ์ VGG16 with pretrained ดังตาราง 5, ภาพประกอบ 5 และผลลัพธ์ ResNet50 with pretrained ดังตาราง 6 ภาพประกอบ 6

ตาราง 5 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก VGG16 with pretrained

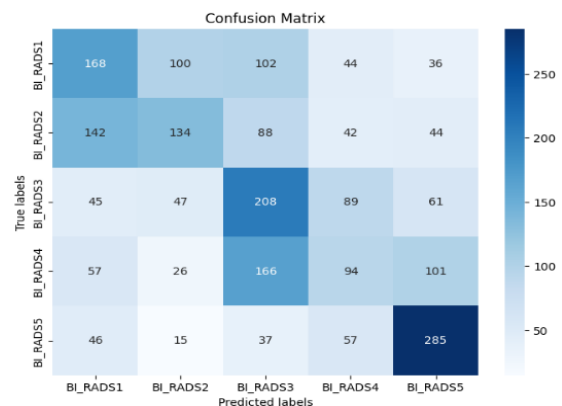
BIRADS	Precision	Recall	F1-Score	Support
1	0.34	0.34	0.34	450
2	0.36	0.26	0.30	450
3	0.31	0.37	0.34	450
4	0.31	0.31	0.31	444
5	0.55	0.59	0.57	440
Accuracy			0.37	2234
Weighted Avg	0.37	0.37	0.37	2234



ภาพประกอบ 5 Confusion Matrix การ Transfer Learning จาก VGG16 with pretrained

ตาราง 6 ผลลัพธ์ที่ได้จากการทดลองใช้การ Transfer Learning จาก ResNet50 with pretrained

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 6 Confusion Matrix การ Transfer Learning จาก ResNet50 with pretrained

2.ผลลัพธ์ของการจำแนกระดับ BI-RADS จากภาพ Full-Field Mammogram ที่มีการปรับแต่งแบบจำลอง

สำหรับผลลัพธ์ของการปรับแต่งแบบจำลองไม่ได้ทำให้ประสิทธิภาพและความแม่นยำของแบบจำลองได้รับการพัฒนาขึ้น ในส่วนนี้อาจจะต้องทดลองปรับแต่งพารามิเตอร์หลากหลายแบบให้เหมาะสมกับชุดข้อมูลที่ใช้ และการทดลองปรับปรุงค่า Hyperparameters ก็มีส่วนในการพัฒนาแบบจำลองได้ หรือทดลองใช้แบบจำลองอื่นที่อาจจะเหมาะสมกับชุดข้อมูลนี้มากกว่า โดยมีผลลัพธ์ VGG16 with tuned ดังตาราง 7 และภาพประกอบ 7 ResNet50 with tuned ดังตาราง 8 และภาพประกอบ 8

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 7 Confusion Matrix การ Transfer Learning จาก VGG16 Tuning

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 8 Confusion Matrix การ Transfer Learning จาก ResNet50 Tuning

3.เปรียบเทียบการทำงานและประเมินประสิทธิภาพของแบบจำลองการจำแนกหลายประเภท

การสร้างแบบจำลอง Deep Convolutional Neural Networks (CNN) ด้วยการ Transfer Learning จาก ResNet50 โดยใช้ pre-trained model สามารถจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS จากภาพ Full-Field Mammogram CC View ได้มีประสิทธิภาพและความแม่นยำดีที่สุดในการทดลองนี้ โดย ResNet50 มีโครงสร้างที่ซับซ้อนกว่า VGG16 โดยมีการใช้ residual connections ที่ช่วยลดปัญหาของ gradient vanishing และเพิ่มความลึกของโมเดลได้โดยไม่เสียประสิทธิภาพทำให้เรียนรู้ลักษณะที่มีความซับซ้อนของภาพแมมโมแกรมได้มากขึ้น ผลลัพธ์ดังตาราง 9

ตาราง 9 ผลลัพธ์การเปรียบเทียบการทำงานและประเมินประสิทธิภาพของแบบจำลองการจำแนกระดับ BI-RADS


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%

4.ผลลัพธ์ของการจำแนกระดับ Density จากภาพ Full-Field Mammogram

แบบจำลองสามารถทำนายการจำแนกระดับความหนาแน่นของเต้านม (Density) ได้มีประสิทธิภาพดีกว่าทำนายการจำแนกระดับความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS โดยมีผลลัพธ์ที่ได้จากการทดลอง ดังตาราง 10 ภาพประกอบ 9 และ ตาราง 11 ภาพประกอบ 10 เนื่องจากความหนาแน่นของเนื้อเต้านม (Breast Density) เป็นลักษณะที่ใกล้เคียงกันกับรอยโรคที่บ่งบอกความเสี่ยงในการกลายเป็นมะเร็งเต้านม (BI-RADS) ส่งผลทำให้โมเดลทำนายคลาดเคลื่อน จึงขอแนะนำการศึกษาในอนาคตให้มีการทำ Segmentation Region of Interest (ROI) ของรอยโรคเต้านมมาศึกษาการจำแนกระดับ BI-RADS ร่วมด้วย

ตาราง 10 ผลลัพธ์ที่ได้จากการทดลองจำแนกระดับความหนาแน่นเต้านม (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
C	0.63	0.38	0.48	200
D	0.63	0.80	0.70	200
Accuracy			0.57	800



ภาพประกอบ 9 Confusion Matrix การ Transfer Learning จาก VGG16 ในการจำแนก Density

ตาราง 11 ผลลัพธ์ที่ได้จากการทดลองจำแนกระดับความหนาแน่นเต้านม (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 10 Confusion Matrix การ Transfer Learning จาก VGG16 with CLAHE ในการจำแนก Density

สรุปผลการวิจัย

งานวิจัยนี้เป็นการศึกษาการสร้างแบบจำลองการจำแนกความเสี่ยงของรอยโรคเต้านมตามพื้นฐานหลักการ BI-RADS จากภาพแมมโมแกรมด้วยการใช้ Deep Convolutional Neural Networks ร่วมกับการทดลองสร้างแบบจำลองการจำแนกความหนาแน่นของเต้านม (Density) โดยมีการจัดเตรียมข้อมูลภาพด้วยการแบ่งส่วนเต้านมออกจากพื้นหลัง (Segmentation Largest Contour) แก้ปัญหาความไม่สมดุลของข้อมูล รวมถึงการเสริมข้อมูล ผลการทดลอง พบว่า การ Transfer Learning โดยใช้ pre-trained model จาก ResNet50 มีความแม่นยำโดยรวมดีกว่า VGG16 ในการจำแนกความเสี่ยงของรอยโรคตามพื้นฐานหลักการ BI-RADS และเมื่อพิจารณาใน BI-RADS Classes พบว่า ทั้ง ResNet50 และ VGG16 สามารถทำนาย BI-RADS 5 ได้มีประสิทธิภาพที่ดีที่สุด อีกทั้งการที่แบบจำลองสามารถจำแนก BI-RADS ได้มีความแม่นยำโดยรวมน้อยกว่าจำแนกความหนาแน่นเต้านม (Density) เพราะคุณลักษณะสำคัญของรอยโรคเต้านมใน BI-RADS มีขนาดเล็ก ดังนั้นจึงขอแนะนำการจำแนก BI-RADS กับการทำ Segmentation Region of Interest (ROI) ร่วมด้วยเพื่อพัฒนาประสิทธิภาพของแบบจำลอง

เอกสารอ้างอิง

1. Chokri F, Hayet Farida M. Mammographic mass classification according to BI-RADS lexicon. IET Computer Vision. 2017;11(3):189-98.
2. Heenaye-Mamode Khan M, Boodoo-Jahangeer N, Dullull W, Nathire S, Gao X, Sinha GR, Nagwanshi KK. Multi-class classification of breast cancer abnormalities using Deep Convolutional Neural Network (CNN). PLoS One. 2021;16(8):e0256500.
3. Abdelrahman L, Al Ghamdi M, Collado-Mesa F, Abdel-Mottaleb M. Convolutional neural networks for breast cancer detection in mammography: A survey. Comput Biol Med. 2021;131:104248.
4. Rafid AKMRH, Azam S, Montaha S, Karim A, Fahim KU, Hasan MZ. An Effective Ensemble Machine Learning Approach to Classify Breast Cancer Based on Feature Selection and Lesion Segmentation Using Preprocessed Mammograms. Biology. 2022;11(11):1654.
5. Tsai K-J, Chou M-C, Li H-M, Liu S-T, Hsu J-H, Yeh W-C, et al. A High-Performance Deep Neural Network Model for BI-RADS Classification of Screening Mammography. Sensors. 2022;22(3):1160.
6. Nguyen HT, Nguyen HQ, Pham HH, Lam K, Le LT, Dao M, Vu V. VinDr-Mammo: A large-scale benchmark dataset for computer-aided diagnosis in full-field digital mammography. Scientific Data. 2023;10(1):277.
7. Ghahroudi H. Kaggle : VinDr-Mammo dataset 2024 [Available from: <https://www.kaggle.com/datasets/hadighahroudi/vindr-mammo-dataset>.