

การเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมในการจำแนกการเป็นโรคมะเร็งตับ

โดยใช้ภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้า

กานต์พิชชา พรหมมา¹, โสภณ มงคลลักษณ์², วรพันธ์ คู่สกุลนิรันดร์³

บทคัดย่อ

โรคมะเร็งตับเป็นหนึ่งในสาเหตุการเสียชีวิตอันดับต้น ๆ ของคนทั่วโลก และเป็นมะเร็งเพียงชนิดเดียวที่สามารถวินิจฉัยโดยใช้ภาพถ่ายทางรังสีวินิจฉัยได้ ไม่จำเป็นต้องใช้การตรวจแบบตัดชิ้นเนื้อ (Biopsy) ซึ่งเทคนิคการตรวจที่ดีที่สุด คือ การตรวจคลื่นแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging) เพราะสามารถเห็นความแตกต่างของเนื้อเยื่อได้ดี แต่ทั้งนี้ก็ต้องอาศัยรังสีแพทย์ในการวินิจฉัยโรค เนื่องด้วยแพทย์มีจำนวนน้อยจึงส่งผลให้เกิดความล่าช้าในการรักษา งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อสร้างแบบจำลองการจำแนกการเป็นโรคมะเร็งตับและไม่เป็นโรคมะเร็งตับ (Binary Classification) จากภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้า โดยใช้แบบจำลองโครงข่ายประสาทเทียมคอนโวลูชัน VGG16 และ ResNet-50 โดยมีการปรับโครงข่ายแบบจำลองและค่าพารามิเตอร์ต่าง ๆ เป็นทั้งหมด 4 ชุดการทดลอง (Version) ซึ่งผู้วิจัยใช้ข้อมูลจากภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าของฐานข้อมูล The Cancer Imaging Archive (TCIA) จำนวน 2,251 รูป โดยแบบจำลอง ResNet-50 มีประสิทธิภาพมากกว่าแบบ VGG16 ในทุกผลการทดลองทั้งหมด 4 ชุด และแบบจำลอง ResNet-50 Version 2 มีค่า Accuracy มากที่สุด โดยมีค่าเท่ากับ 0.69 หากวิเคราะห์ด้วยเมตริกซ์ False Negatives (FN) แบบจำลอง VGG16 Version 2 มีค่า False Negatives น้อยกว่า ResNet-50 Version 2 โดยมีรูปที่ถูกทายเป็น False Negatives อยู่ที่ 32 รูป และ 54 รูป ตามลำดับ จากผลลัพธ์นี้แสดงให้เห็นว่าการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมคอนโวลูชันสามารถจำแนกการเป็นโรคมะเร็งตับได้ และการเลือกประเภทของแบบจำลองส่งผลกระทบต่อประสิทธิภาพของแบบจำลอง ในการศึกษาครั้งนี้โครงข่ายประสาทเทียมคอนโวลูชันแบบ ResNet-50 มีประสิทธิภาพมากกว่าแบบ VGG16 เมื่อวัดด้วยเมตริกซ์ Accuracy แต่หากเปรียบเทียบกับเมตริกซ์ False Negatives โครงข่ายประสาทเทียมคอนโวลูชันแบบ VGG16 มีประสิทธิภาพดีกว่าแบบ ResNet-50

คำสำคัญ : โรคมะเร็งตับ, การตรวจคลื่นแม่เหล็กไฟฟ้า, การจำแนกประเภท, การเรียนรู้เชิงลึก, โครงข่ายประสาทเทียมคอนโวลูชัน

¹ หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

² คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

³ คณะเทคโนโลยีสารสนเทศและการสื่อสาร มหาวิทยาลัยมหิดล นครปฐม 73170

* Corresponding author: Tel.: 098-4951549 E-mail address: kanphitcha.pro@gs.swu.ac.th

Deep Learning with Convolutional Neural Network for Classification of Hepatocellular carcinoma on Magnetic resonance imaging

Kanphitcha Promma^{1*}, Sophon Mongkolluksamee², Worapan Kusakunniran³

Abstract

Hepatocellular carcinoma is one of the leading causes of death globally. It is the only type of cancer that can be diagnosed using radiological imaging, without the need for a biopsy. The best diagnostic technique is magnetic resonance imaging (MRI), as it can visualize tissue differences effectively. However, it still relies on radiologists for diagnosis, which can cause delays in treatment due to their limited numbers. This research aims to develop a model for binary classification of hepatocellular carcinoma and non-hepatocellular carcinoma from magnetic resonance imaging (MRI) using deep learning techniques with the convolutional neural network (CNN) architectures VGG16 and ResNet-50. The four experimental setups were conducted with variations in model architectures and parameters. The researchers utilized data from MRI images from The Cancer Imaging Archive (TCIA) database, comprising 2,251 images. The ResNet-50 model outperformed VGG16 in all four experimental setups, with ResNet-50 Version 2 achieving the highest accuracy of 0.69. Analyzing False Negatives (FN) matrices revealed that VGG16 Version 2 had fewer false negatives than ResNet-50 Version 2, with 32 and 54 misclassified images, respectively. These results indicate that deep learning with convolutional neural networks can effectively classify hepatocellular carcinoma. Furthermore, the choice of model type significantly impacts model performance. In this study, the ResNet-50 CNN architecture outperformed VGG16 in terms of accuracy, but when considering False Negatives, VGG16 demonstrated a better performance than ResNet-50.

Keywords : Hepatocellular carcinoma, Magnetic resonance imaging, Binary Classification, Deep learning, Convolutional neural network

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.: 098-4951549 E-mail address: kanphitcha.pro@swu.ac.th

บทนำ

ปกติแล้วการตรวจหาโรคมะเร็งต้องใช้ผลการตรวจชิ้นเนื้ออวัยวะ (Biopsy) เท่านั้นในการวินิจฉัยโรค แต่การตรวจนี้อาจนำไปสู่ผลข้างเคียงที่ไม่พึงประสงค์อย่างหนึ่ง คือ ภาวะ Tumor seeding หรือ Needle seeding ซึ่งเป็นภาวะที่หากเซลล์ที่ตัดมาเป็นเซลล์มะเร็งก็จะสามารถแพร่กระจายเซลล์ไปสู่อวัยวะข้างเคียงเหล่านั้นได้ทันที เปรียบเสมือนการงอกของเมล็ดพันธุ์พืชที่ไปเจริญในบริเวณอื่น ๆ แต่โรคมะเร็งตับชนิด Hepatocellular carcinoma นี้ เป็นมะเร็งเพียงชนิดเดียวที่สามารถวินิจฉัยโดยใช้ภาพถ่ายทางรังสีวินิจฉัย (Diagnostic imaging) ได้ ไม่จำเป็นต้องใช้ผลการตรวจทางพยาธิวิทยาในการยืนยันคำวินิจฉัยทุกครั้ง ซึ่งเทคนิคที่ได้รับการยอมรับมากที่สุดในการใช้ยืนยันคำวินิจฉัยโรคมะเร็งตับจากข้อมูลภาพถ่ายทางรังสีวินิจฉัย คือ การตรวจคลื่นแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI) เนื่องจากสามารถตรวจหาคุณลักษณะของมะเร็งตับชนิด Hepatocellular carcinoma ได้อย่างมีความแม่นยำสูงในก้อนมะเร็งตับที่มีขนาดใหญ่ [1] เพราะภาพที่ได้สามารถบอกขอบเขตของรอยโรคได้ถูกต้องและแม่นยำ และให้ข้อมูลความแตกต่างของเนื้อเยื่ออวัยวะตับได้ดี

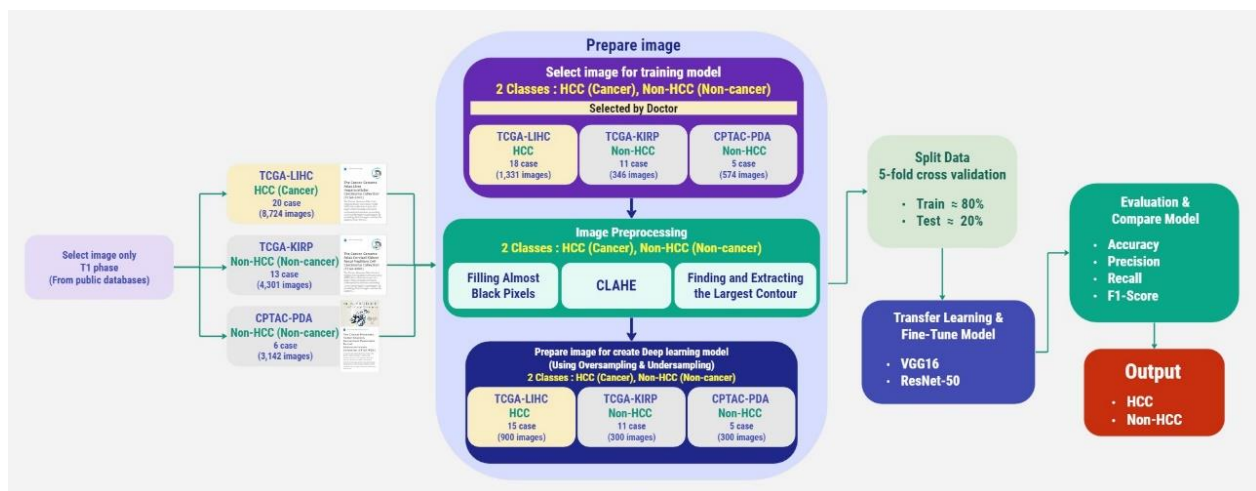
จากความก้าวหน้าทางเทคโนโลยีในปัจจุบัน พบว่า การสร้างแบบจำลองด้วยเทคนิคการเรียนรู้เชิงลึก (Deep Learning) เป็นวิธีการเรียนรู้แบบอัตโนมัติที่เหมาะสมกับข้อมูลที่ไม่มีโครงสร้าง (Unstructured Data) ซึ่งรวมถึงข้อมูลรูปภาพด้วย โดยเกิดจากการเลียนแบบการทำงานของโครงข่ายระบบประสาทของมนุษย์ (Neurons) นำระบบโครงข่ายเส้นประสาทเทียม (Neural Network) มาวางซ้อนทับกันหลาย ๆ ชั้น (Layer) โครงข่ายเส้นประสาทเทียมนี้มีความสามารถในการจดจำรูปแบบของภาพได้ ซึ่งโครงข่ายที่เป็นนิยมในปัจจุบัน คือ โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional neural network: CNN) ที่มีการใช้หลักการเดียวกันกับ Spatial Convolution เป็นการจำลองการมองเห็นของมนุษย์ที่มองเห็นพื้นที่ออกเป็นพื้นที่ย่อย ๆ และนำกลุ่มของพื้นที่ย่อย ๆ เหล่านั้น มารวมกันอีกครั้งหนึ่ง เพื่อตรวจจับว่าในภาพนั้น ๆ เป็นสิ่งใด ในงานวิจัยนี้ จึงมีวัตถุประสงค์ในการสร้างแบบจำลองจำแนกประเภท (Binary Classification) การเป็นโรคมะเร็งตับและไม่เป็นโรคมะเร็งตับจากภาพทางรังสีวินิจฉัยของข้อมูลภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าในบริเวณช่องท้อง เพื่อให้สามารถใช้เป็นข้อมูลประกอบการรักษาได้อย่างแม่นยำ รวดเร็วทันต่อการรักษา และสามารถเพิ่มอัตราการรอดชีวิตของผู้ป่วยได้

งานวิจัยที่เกี่ยวข้อง

การตรวจการเป็นโรคมะเร็งตับนั้น ยังมีอีกเทคนิคการตรวจหนึ่ง คือ การตรวจผ่านเครื่องเอกซเรย์คอมพิวเตอร์ (Computerized Tomography Scan: CT scan) ที่สามารถใช้ในการวินิจฉัยโรคได้เช่นกัน แต่เทคนิคนี้ล้วนมีผลข้างเคียงที่ไม่พึงประสงค์ คือ การได้รับรังสีวินิจฉัยจากการตรวจ จากการศึกษาบทความเทคนิคการตรวจหาโรคมะเร็งตับที่เกิดจากเซลล์ตัวเอง (Hepatocellular carcinoma) พบว่า การตรวจคลื่นแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI) มีความแม่นยำมากที่สุดในปัจจุบัน เมื่อใช้เทคนิคการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมคอนโวลูชัน (Deep Learning with Convolutional Neural Network) และมีการวัดประสิทธิภาพของแบบจำลอง (Model Evaluation) ด้วย Accuracy และ ROC (Receiver Operating Characteristic curve) มีค่า Accuracy สูงมากกว่า 90% [2] ในบทความวิจัยเรื่อง Deep learning LI-RADS grading system based on contrast enhanced multiphase MRI for differentiation between LR-3 and LR-4/LR-5 liver tumors [3] ที่ต้องการสร้างแบบจำลองการจำแนกประเภทของ LR-3 (ไม่เป็นมะเร็ง) และ LR-4/ LR-5 (เป็นมะเร็ง) และมีการเลือกใช้ข้อมูลภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าในระยะ T1 เท่านั้น จากจำนวนผู้ป่วยทั้งหมด 59 ราย มีภาพถ่าย LI-RADS ทั้งหมด 89 ภาพ ใช้โครงข่ายประสาทเทียม (Convolutional Neural Network: CNN) ที่มีโครงสร้างเป็น Alexnet และใช้ Weight เป็น “Imagenet” มีการวัดประสิทธิภาพของแบบจำลองด้วย Accuracy, Sensitivity, Precision และ AUC (Area under curve) พบว่า

การใช้ข้อมูล (Dataset) C2 นั้น ให้ประสิทธิภาพสูงสุดในการจำแนกโรคมะเร็งตับ (Hepatocellular carcinoma) โดยมีค่า Accuracy เท่ากับ 0.90, Sensitivity เท่ากับ 1.0, Precision เท่ากับ 0.84 และ AUC เท่ากับ 0.95 โดยชุดข้อมูล (Dataset) C2 เป็นการเลือกข้อมูลเพียง 3 ระยะของ T1 เท่านั้น ประกอบด้วย ระยะ Pre-contrast phase หมายถึง ไม่มีการใช้สารทึบแสง ระยะ Arterial phase หมายถึง สารทึบแสงยังคงอยู่ในหลอดเลือดแดงไม่ได้อยู่ในอวัยวะและเนื้อเยื่ออื่น ๆ และระยะ Washout phase หมายถึง ล้างสารทึบแสงออกจากช่องท้อง เมื่อเปรียบเทียบในอีกบทความวิจัยหนึ่งเรื่อง Deep convolutional neural network applied to the liver imaging reporting and data system (LI-RADS) version 2014 category classification: a pilot study [4] ที่ต้องการจำแนกประเภทของ LR-1/2 (ไม่เป็นมะเร็ง), LR-3 (มีความเสี่ยงระดับปานกลางที่จะเป็นมะเร็ง), LR-4 (มีความเสี่ยงสูงที่จะเป็นมะเร็ง) และ LR-5 (เป็นมะเร็งแน่นอนจากภาพถ่ายทางรังสีวินิจฉัย) ของโรคมะเร็งตับ (Hepatocellular carcinoma) ด้วยโครงข่ายประสาทเทียมโครงสร้างเป็น VGG16 และใช้ Weight เป็น “Imagenet” มีการใช้ภาพถ่ายการตรวจวินิจฉัยโรคด้วยเครื่องเอกซเรย์คอมพิวเตอร์ ทั้งหมดจำนวน 163 รูป และภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้า ทั้งหมดจำนวน 151 รูป ซึ่งมีการใช้ภาพถ่ายการตรวจทางรังสีวินิจฉัยแบบเดียวกับชุดข้อมูล C2 ของงานวิจัยเรื่อง Deep learning LI-RADS grading system based on contrast enhanced multiphase MRI for differentiation between LR-3 and LR-4/LR-5 liver tumors ที่ได้เลือกข้อมูลภาพถ่ายเพียง 3 ระยะของ T1 เท่านั้นจากการวัดประสิทธิภาพของแบบจำลองด้วย Accuracy และ AUROCs (The area under the receiver operating characteristic) ได้ค่า Accuracy โดยรวมทุก LI-RADS (Overall) เท่ากับ 0.64 และ AUROCs ของ LR-1/2, LR-3, LR-4 และ LR-5 เท่ากับ 0.85, 0.90, 0.63 และ 0.82 ตามลำดับ ซึ่งพบว่า ในการจำแนก LR-4 (มีความเสี่ยงสูงที่จะเป็นมะเร็ง) มีประสิทธิภาพต่ำที่สุดจากการจำแนก LI-RADS ทั้งหมด นอกจากนี้ยังพบว่าการเลือกโครงสร้างของแบบจำลองต้นแบบ (Architecture model) เพื่อให้สอดคล้องกับข้อมูลและปัญหาของงานนั้น ๆ โดยเฉพาะในงานภาพถ่ายการตรวจทางการแพทย์นั้น มีวิธีการเลือกโครงข่ายประสาทเทียมคอนโวลูชันที่แตกต่างกันตามชุดข้อมูล (Input data) [5] ซึ่งหนึ่งในนั้นมีโครงสร้างโครงข่ายประสาทเทียมที่น่าสนใจ คือ โครงข่ายประสาทเทียมที่มีโครงสร้างเป็น ResNet โดยมีการใช้กับข้อมูลการตรวจคลื่นแม่เหล็กไฟฟ้าเช่นเดียวกัน จึงได้เลือกโครงสร้างดังกล่าวมาใช้ในการศึกษาครั้งนี้ด้วย

วิธีดำเนินการ



ภาพประกอบ 1 Flowchart กระบวนการสร้างแบบจำลอง

ขั้นตอนที่ 1 : แนะนำชุดข้อมูลที่ใช้ในการศึกษานี้


ผู้วิจัยใช้ข้อมูลภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้า (MRI) จากฐานข้อมูลเปิด (Open database) ของ The Cancer Imaging Archive (TCIA) ในผู้ป่วยโรคมะเร็งตับชนิด Hepatocellular carcinoma ใช้ชุดข้อมูล The Cancer Genome Atlas Liver Hepatocellular Carcinoma Collection (TCGA-LIHC) [6] และผู้ป่วยที่ไม่เป็นโรคมะเร็งตับชนิด Hepatocellular carcinoma จะใช้ชุดข้อมูลทั้งหมด 2 ชุด คือ The Cancer Genome Atlas Cervical Kidney Renal Papillary Cell Carcinoma Collection (TCGA-KIRP) [7] เป็นข้อมูลผู้ป่วยโรคมะเร็งไต และอีกชุดข้อมูลเป็นข้อมูลผู้ป่วยโรคมะเร็งตับอ่อน The Clinical Proteomic Tumor Analysis Consortium Pancreatic Ductal Adenocarcinoma Collection (CPTAC-PDA) [8] ทั้งนี้เลือกใช้ภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าระยะ T1 (Pulse sequence) เท่านั้น มีจำนวนผู้ป่วยทั้งหมด 34 ราย จำนวน 2,251 รูป

ขั้นตอนที่ 2 : การนำเข้าข้อมูล ตรวจสอบข้อมูล และพิจารณาข้อมูล


คัดเลือกเฉพาะภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าในระยะ T1 เท่านั้น พร้อมทั้งแพทย์ทำการคัดเลือกภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าที่มีพื้นที่รอยโรคในภาพมากกว่าร้อยละ 50 เนื่องจากหากมีพื้นที่น้อยกว่านี้รอยโรคที่ปรากฏในอวัยวะของภาพจะมีขนาดเล็กมาก ทำให้สามารถวินิจฉัยโรคได้ยากและไม่ได้อยู่ในขอบเขตงานวิจัยนี้ พบว่า มีจำนวนผู้ป่วยทั้งหมด 34 ราย เป็นข้อมูลผู้ป่วยที่เป็นโรคมะเร็งตับ คือ TCGA-LIHC จำนวน 18 ราย จำนวน 1,331 รูป และเป็นข้อมูลผู้ป่วยที่ไม่เป็นโรคมะเร็งตับ คือ TCGA-KIRP และ CPTAC-PDA จำนวน 11 ราย และ 5 ราย จำนวน 346 รูป และจำนวน 574 รูป ตามลำดับ

ขั้นตอนที่ 3 : การเตรียมข้อมูลภาพ (Data Preprocessing)

ข้อมูลภาพถ่ายที่ใช้ในการสร้างแบบจำลองนั้น ต้องผ่านขั้นตอนการประมวลผลภาพ (Image Preprocessing) ก่อน โดยได้มีการปรับแต่งภาพพื้นหลังทั้งหมดให้เป็นสีดำสนิททั้งหมด พร้อมทั้งใช้เทคนิคการค้นหา Contour ที่ใหญ่ที่สุด (Find the largest contour) เพื่อเป็นการเลือกบริเวณในรูปภาพที่เราสนใจ ถัดมาทำการตัดเลือกรูปภาพนั้น (Cropping) มาจัดให้อยู่ตรงกลางในพื้นที่รูปสี่เหลี่ยม แล้วเติมขอบของภาพเพิ่มเติม (Padding) และสุดท้ายใช้การปรับภาพด้วยเทคนิค CLAHE (Contrast Limited Adaptive Histogram Equalization) เพื่อเพิ่มเติมรายละเอียดของภาพให้ชัดเจนมากขึ้น

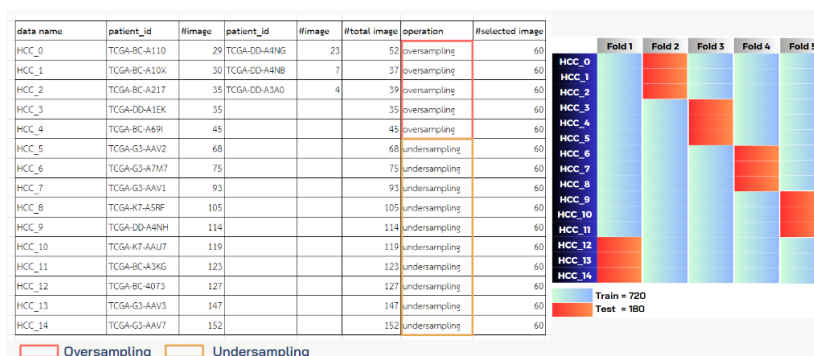


ภาพประกอบ 2 ตัวอย่างภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าที่ใช้เทคนิค The largest contour ตัดแขนที่อยู่ในภาพ

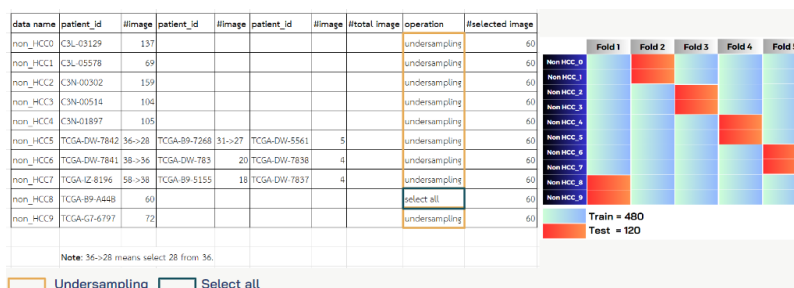


ภาพประกอบ 3 ตัวอย่างภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าที่ตัดเลือกรูปภาพช่องท้องและปรับให้เป็นสี่เหลี่ยมจัตุรัส

ขั้นตอนการแบ่งข้อมูลชุดฝึกสอน (Training set) และข้อมูลชุดทดสอบ (Validation set) ใช้หลักการของ K-Fold Cross Validation กำหนดค่า K เท่ากับ 5 (5 folds) และให้สัดส่วนของข้อมูลชุดฝึกสอน (Training set) และข้อมูลชุดทดสอบ (Validation set) ภายในแต่ละส่วน (Fold) เป็นร้อยละ 80 และร้อยละ 20 โดยประมาณ ตามลำดับ เนื่องจากผู้ป่วยที่เป็นโรคมะเร็งตับและไม่ใช่โรคมะเร็งตับนั้น มีสัดส่วนจำนวนรูปภาพที่ไม่เท่ากันในผู้ป่วยแต่ละราย จึงได้ออกแบบการจัดกลุ่มผู้ป่วยทั้ง 2 กลุ่มใหม่ โดยผู้ป่วยแต่ละรายชุดใหม่นี้ ด้วยเทคนิคการลดปริมาณข้อมูล (Undersampling) และเพิ่มปริมาณข้อมูล (Oversampling) เพื่อเป็นการปรับมีจำนวนรูปภาพเท่ากับ 60 รูปเสมอ เกิดความสมดุลกันของข้อมูลรูปภาพที่นำไปใช้ในการสร้างแบบจำลองทั้งในกลุ่มข้อมูลผู้ป่วยที่เป็นโรคมะเร็งตับและไม่ใช่โรคมะเร็งตับ และมีการใช้เทคนิคการทำ Class weight มากำหนดความสำคัญของแต่ละชนิดของข้อมูล โดยคำนึงถึงอัตราส่วนของจำนวนตัวอย่างในแต่ละชนิดข้อมูล



ภาพประกอบ 4 การจัดกลุ่มผู้ป่วยแต่ละรายในกลุ่มผู้ป่วยที่เป็นโรคมะเร็งตับ (Hepatocellular carcinoma : HCC)



ภาพประกอบ 5 การจัดกลุ่มผู้ป่วยแต่ละรายในกลุ่มผู้ป่วยที่ไม่เป็นโรคมะเร็งตับ (Non Hepatocellular carcinoma : Non HCC)

ทั้งนี้ ได้มีการผ่านกระบวนการปรับข้อมูลภาพ (Image Augmentation) ก่อนนำมาใช้ในการฝึกสอนแบบจำลอง โดยได้มีการปรับข้อมูลรูปภาพด้วยเทคนิค ตามตาราง 1

ตาราง 1 ตารางการปรับข้อมูลรูปภาพด้วยเทคนิคต่าง ๆ ก่อนนำไปใช้ในการสร้างแบบจำลอง

เทคนิค	ค่าที่ใช้
Rotation_range	มีการหมุนภาพได้ในช่วงไม่เกิน 25 องศา
Width_shift_range	มีการเลื่อนภาพซ้าย-ขวาได้ไม่เกิน 10% ของความกว้างของภาพ
Height_shift_range	มีการเลื่อนภาพบน-ล่างได้ไม่เกิน 10% ของความสูงของภาพ
Shear_range	มีการเบิดภาพได้ในช่วงไม่เกิน 10 องศา
Zoom_range	มีการซูมเข้าหรือซูมออกภาพได้ไม่เกิน 10%

ตาราง 1 (ต่อ)

เทคนิค	ค่าที่ใช้
Horizontal_flip	มีการพลิกภาพตามแนวนอน (ซ้าย-ขวา) แต่เป็นทิศทางตรงข้าม
Brightness_range	มีการปรับความสว่างของภาพในช่วง 0.5 - 1.0
Fill_mode	เติมพื้นที่ว่างในภาพหลังจากการเปลี่ยนแปลง โดยใช้วิธี 'nearest'

ขั้นตอนที่ 4 : การสร้างแบบจำลองการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมคอนโวลูชัน VGG16 และ ResNet-50

ผู้วิจัยได้มีการปรับโครงสร้างแบบจำลอง และกำหนด Hyperparameters ที่สำคัญ ได้แก่ Learning Rate = 0.0001, Batch Size = 64, Number of Epochs = 30, Optimizer = Adam, Loss Function = binary_crossentropy และ Activation Function = sigmoid โดยมี Dense Layer = 1 ในการฝึกสอนแบบจำลอง ซึ่งแบ่งออกเป็นทั้งหมด 4 ชุดการทดลอง (Version) ตามตาราง 2, 3, 4, 5, 6, 7, 8 และ 9

ตาราง 2 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง VGG16 Version 1

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
VGG16 model with Pre-train layer	
Flatten Layer	(None, 25088)
Fully connected Layer 1	(None, 4096)
Fully connected Layer 2	(None, 4096)

ตาราง 3 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง VGG16 Version 2

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
VGG16 model with Pre-train layer	
Flatten Layer	(None, 25088)
Fully connected Layer 1	(None, 256)
Fully connected Layer 2	(None, 128)

ตาราง 4 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง VGG16 Version 3

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
VGG16 model with Pre-train layer	
Flatten Layer	(None, 25088)
Fully connected Layer 1 (Trainable = True)	(None, 4096)
Fully connected Layer 2 (Trainable = True)	(None, 4096)

ตาราง 5 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง VGG16 Version 4

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
VGG16 model with Pre-train layer	
GlobalAveragePooling2D	(None, 512)
Fully connected Layer 1	(None, 256)
BatchNormalization	(None, 256)
Activation Function	ReLU
Dropout (0.5)	(None, 256)

ตาราง 6 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง ResNet50 Version 1

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
ResNet50 model with Pre-train layer	

ตาราง 7 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง ResNet50 Version 2

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
ResNet50 model with Pre-train layer	
Flatten Layer	(None, 100352)
Fully connected Layer 1	(None, 256)
Fully connected Layer 2	(None, 128)

ตาราง 8 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง ResNet50 Version 3

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
ResNet50 model with Pre-train layer	
Fully connected Layer 1 (Trainable = True)	(None, 512)
Fully connected Layer 2 (Trainable = True)	(None, 256)

ตาราง 9 ตารางแสดงค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการสร้างแบบจำลอง ResNet50 Version 4

Layer (type)	Output Shape
input_1 (Input Layer)	(None, 224, 224, 3)
ResNet50 model with Pre-train layer	
GlobalAveragePooling2D	(None, 2048)
Fully connected Layer 1	(None, 256)

ตาราง 9 (ต่อ)

Layer (type)	Output Shape
BatchNormalization	(None, 256)
Activation Function	ReLU
Dropout (0.5)	(None, 256)

ผลการวิจัยและอภิปรายผลการวิจัย

1.ผลการประเมินประสิทธิภาพแบบจำลองด้วยอัลกอริทึม VGG16

จากทั้งหมด 4 ชุดผลการทดลองด้วยอัลกอริทึม VGG16 นั้น พบว่า เมื่อพิจารณาประสิทธิภาพของแบบจำลองด้วยเมตริกซ์ Accuracy ที่มุ่งเน้นเรื่องอัตราส่วนของตัวอย่างที่แบบจำลองทำนายถูกต้องทั้งหมด เรียงค่า Accuracy จากมากไปน้อย จะได้ VGG16 Version 2 ที่ 0.63 VGG16 Version 3 ที่ 0.59 VGG16 Version 4 ที่ 0.58 และ VGG16 Version 1 ที่ 0.54 ตามตาราง 10

ตาราง 10 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลอง VGG16 แต่ละ Version

VGG16 Version	Accuracy	Precision	Recall	F1-score
1	0.54	0.53	0.53	0.53
2	0.63	0.61	0.59	0.58
3	0.59	0.59	0.59	0.57
4	0.58	0.59	0.59	0.57

เมื่อเปรียบเทียบตามการทำ Cross Validation ซึ่งในที่นี้กำหนดให้มีค่าเท่ากับ 5 (5 folds) เรียงจากมากไปน้อยมีค่า Accuracy เฉลี่ย คือ fold 2 สูงสุด ที่ 0.71



ภาพประกอบ 6 สรุปผลการประเมินประสิทธิภาพแบบจำลองด้วยอัลกอริทึม VGG16

หมายเหตุ : สีเขียว คือ ค่าเฉลี่ยความแม่นยำมากกว่า 50% และสีเทา คือ ค่าเฉลี่ยความแม่นยำน้อยกว่า 50%

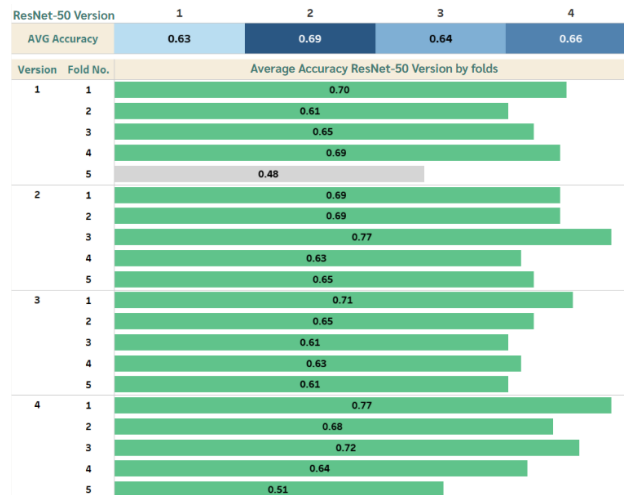
2.ผลการประเมินประสิทธิภาพแบบจำลองด้วยอัลกอริทึม ResNet-50

จากทั้งหมด 4 ชุดผลการทดลองด้วยอัลกอริทึม ResNet-50 นั้น พบว่า เมื่อพิจารณาประสิทธิภาพของแบบจำลองด้วยเมตริกซ์ Accuracy ที่มุ่งเน้นเรื่องอัตราส่วนของตัวอย่างที่แบบจำลองทำนายถูกต้องทั้งหมด เรียงค่า Accuracy จากมากไปน้อยจะได้ ResNet-50 Version 2 ที่ 0.69 ResNet-50 Version 4 ที่ 0.66 ResNet-50 Version 3 ที่ 0.64 และ ResNet-50 Version 1 ที่ 0.63 ตามตาราง 11

ตาราง 11 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลอง ResNet-50 แต่ละ Version

ResNet-50 Version	Accuracy	Precision	Recall	F1-score
1	0.63	0.62	0.62	0.61
2	0.69	0.68	0.68	0.68
3	0.64	0.63	0.63	0.62
4	0.66	0.65	0.65	0.65

เมื่อเปรียบเทียบตามการทำ Cross Validation กำหนดให้หาค่าเท่ากับ 5 (5 folds) เรียงจากมากไปน้อยมีค่า Accuracy เฉลี่ย คือ fold 1 สูงสุด ที่ 0.72

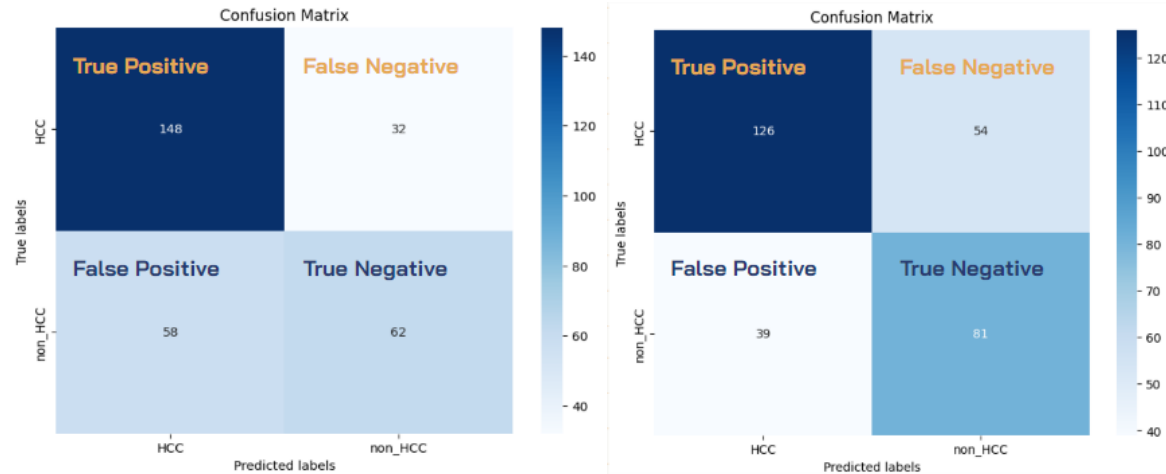


ภาพประกอบ 7 สรุปผลการประเมินประสิทธิภาพแบบจำลองด้วยอัลกอริทึม ResNet-50

หมายเหตุ : สีเขียว คือ ค่าเฉลี่ยความแม่นยำมากกว่า 50% และสีเทา คือ ค่าเฉลี่ยความแม่นยำน้อยกว่า 50%

3.การเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยเมตริกซ์ False Negatives (FN)

หากวิเคราะห์ด้วยเมตริกซ์ False Negatives (FN) ซึ่งในทางการแพทย์ เราต้องการลดค่า False Negatives (FN) ให้น้อยที่สุดเท่าที่จะเป็นไปได้ เนื่องจาก False Negatives คือ การระบุว่าผู้ป่วยไม่มีโรค ทั้งที่จริงแล้วผู้ป่วยเป็นโรค ซึ่งอาจทำให้พลาดการรักษาหรือไม่ได้รับการรักษาตามที่สมควร พบว่า VGG16 Version 2 มีค่า False Negatives (FN) น้อยกว่า ResNet-50 Version 2 โดยมีผู้ป่วยที่ถูกทนายเป็น False Negatives (FN) อยู่ที่ 32 รูป และ 54 รูป ตามลำดับ



ภาพประกอบ 8 Confusion Matrix ของ VGG16 Version 2 ภาพประกอบ 9 Confusion Matrix ของ ResNet-50 Version 2

สรุปผลการวิจัย

งานวิจัยนี้เป็นการศึกษาการสร้างแบบจำลองเพื่อจำแนกประเภท (Binary Classification) การเป็นโรคมะเร็งตับและไม่ใช่โรคมะเร็งตับจากภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้า (MRI) โดยใช้เทคนิคการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมคอนโวลูชัน (Deep Learning with Convolutional Neural Network) เลือกใช้เฉพาะภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าในระยะ T1 เท่านั้น พร้อมทั้งแพทย์ทำการคัดเลือกภาพถ่ายการตรวจคลื่นแม่เหล็กไฟฟ้าที่มีพื้นที่รอยระดับในภาพมากกว่าร้อยละ 50 ข้อมูลภาพถ่ายที่ใช้ในการสร้างแบบจำลองต้องผ่านขั้นตอนการประมวลผลภาพก่อน มีการปรับแต่งภาพพื้นหลังทั้งหมดให้เป็นสีดำสนิท พร้อมทั้งใช้เทคนิคการค้นหา Contour ที่ใหญ่ที่สุดในการเลือกบริเวณช่องท้อง ทำการตัดเลือกรูปภาพมาจัดให้อยู่ตรงกลางในพื้นที่รูปสี่เหลี่ยมแล้วเติมขอบของภาพ และใช้การปรับภาพด้วยเทคนิค CLAHE สุดท้ายการแบ่งข้อมูลชุดฝึกสอน (Training set) และข้อมูลชุดทดสอบ (Validation set) ใช้หลักการของ K-Fold Cross Validation กำหนดค่า K เท่ากับ 5 และให้สัดส่วนของข้อมูลชุดฝึกสอนและข้อมูลชุดทดสอบภายในแต่ละส่วน (Fold) เป็นร้อยละ 80 และร้อยละ 20 โดยประมาณ ทั้งนี้มีการแก้ปัญหาความไม่สมดุลของข้อมูล และการเสริมข้อมูลมาด้วย ผลการทดลอง พบว่า แบบจำลอง ResNet-50 มีประสิทธิภาพมากกว่าแบบ VGG16 ในทุกผลการทดลองทั้งหมด 4 ชุด และแบบจำลอง ResNet-50 Version 2 มีค่า Accuracy มากที่สุด และหากวิเคราะห์ด้วยเมตริกซ์ False Negatives (FN) แบบจำลอง VGG16 Version 2 มีค่า False Negatives น้อยกว่า ResNet-50 จากผลลัพธ์นี้แสดงให้เห็นว่าการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมคอนโวลูชันสามารถจำแนกการเป็นโรคมะเร็งตับได้ ทั้งนี้ ในแบบจำลองทั้ง VGG16 Version 2 และ ResNet-50 Version 2 นั้น มีจุดร่วมที่เหมือนกันอย่างหนึ่ง คือ มีการเพิ่มชั้นเชื่อมต่อแบบสมบูรณ์ชั้นที่ 1 (Fully connected Layer 1) และชั้นที่ 2 (Fully connected Layer 2) เช่นเดียวกัน ตรงนี้เองอาจเป็นปัจจัยสำคัญส่วนหนึ่งที่ทำให้แบบจำลองที่ได้ในครั้งนี้นี้มีความแม่นยำมากขึ้นในการจำแนกการเป็นโรคมะเร็งตับ ดังนั้นในการศึกษาครั้งถัดไปสามารถนำโครงสร้างแบบจำลองในลักษณะนี้ไปประยุกต์ใช้ได้เช่นกัน

เอกสารอ้างอิง

- [1] Taouli, B., Losada, M., Holland, A., และ Krinsky, G. (2004). Magnetic resonance imaging of hepatocellular carcinoma. *Gastroenterology*, 127(5), S144-S152
- [2] Castaldo, A., De Lucia, D. R., Pontillo, G., Gatti, M., Coccozza, S., Uggla, L., และ Cuocolo, R. (2021). State of the Art in Artificial Intelligence and Radiomics in Hepatocellular Carcinoma. *Diagnostics*, 11(7), 1194.
- [3] Wu, Y., White, G. M., Cornelius, T., Gowdar, I., Ansari, M. H., Supanich, M. P., และ Deng, J. (2020). Deep learning LI-RADS grading system based on contrast enhanced multiphase MRI for differentiation between LR-3 and LR-4/LR-5 liver tumors. *Annals of Translational Medicine*, 8(11)
- [4] Yamashita, R., Mittendorf, A., Zhu, Z., Fowler, K. J., Santillan, C. S., Sirlin, C. B., . . . Do, R. K. (2020). Deep convolutional neural network applied to the liver imaging reporting and data system (LI-RADS) version 2014 category classification: a pilot study. *Abdominal Radiology*, 45(1), 24-35.
- [5] Davila, A., Colan, J., และ Hasegawa, Y. (2024). Comparison of fine-tuning strategies for transfer learning in medical image classification. *Image and Vision Computing*, 146, 105012.
- [6] Erickson, B. J., Kirk, S., Lee, Y., Bathe, O., Kearns, M., Gerdes, C., Rieger-Christ, K., & Lemmerman, J. (2016). The Cancer Genome Atlas Liver Hepatocellular Carcinoma Collection (TCGA-LIHC) (Version 5) [Data set]. Retrieved from: <https://doi.org/10.7937/K9/TCIA.2016.IMMQW8UQ>
- [7] Linehan, M., Gautam, R., Kirk, S., Lee, Y., Roche, C., Bonaccio, E., Filippini, J., Rieger-Christ, K., Lemmerman, J., & Jarosz, R. . (2016). The Cancer Genome Atlas Cervical Kidney Renal Papillary Cell Carcinoma Collection (TCGA-KIRP) (Version 4) [Data set]. Retrieved from: <https://doi.org/10.7937/K9/TCIA.2016.ACWOGBEF>
- [8] (CPTAC), N. C. I. C. P. T. A. C. (2018). The Clinical Proteomic Tumor Analysis Consortium Pancreatic Ductal Adenocarcinoma Collection (CPTAC-PDA) (Version 14) [Data set]. Retrieved from: <https://doi.org/10.7937/K9/TCIA.2018.SC20FO18>