

การแบ่งส่วนดับและเนื้องอกในภาพสเปกซีทีของเทคนิคซีเอ็ม-99เอ็ม เอ็มเอเอ สำหรับการวางแผนการ
รักษาด้วยการนำสารกัมมันตรังสีเข้าสู่ร่างกายเฉพาะจุดด้วยโครงข่ายประสาทเชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2565
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Liver and Tumor Segmentation in ^{99m}Tc -MAA SPECT/CT Images for Selective Internal
Radiation Therapy Treatment Planning using Deep Neural Networks



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

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การแบ่งส่วนตับและเนื้องอกในภาพสเปคซีทีของ เทคนิคซีเอ็ม-99เอ็ม เอ็มเอเอ สำหรับการวางแผนการรักษา ด้วยการนำสารกัมมันตรังสีเข้าสู่ร่างกายเฉพาะจุดด้วย โครงข่ายประสาทเชิงลึก
โดย	น.ส.สุกัญญา แซ่คู
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	อาจารย์ ดร.พรพรรณราย ศิริเจริญ
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ผู้ช่วยศาสตราจารย์ ดร.กิติวัฒน์ คำวัน

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัยเป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(ศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(อาจารย์ ดร.พรพรรณราย ศิริเจริญ)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม
(ผู้ช่วยศาสตราจารย์ ดร.กิติวัฒน์ คำวัน)

..... กรรมการภายนอกมหาวิทยาลัย
(ผู้ช่วยศาสตราจารย์ ดร.ยุทธพงษ์ จิรรัชโสภาคกุล)

สฤัญญา แซ่คู : การแบ่งส่วนตับและเนื้องอกในภาพสเปคซีทีของเทคนิคซีเอ็ม-99เอ็ม เอ็ม เอเอ สำหรับการวางแผนการรักษาด้วยการนำสารกัมมันตรังสีเข้าสู่ร่างกายเฉพาะจุดด้วย
 โคร่งข่ายประสาทเชิงลึก. (Liver and Tumor Segmentation in ^{99m}Tc -MAA
 SPECT/CT Images for Selective Internal Radiation Therapy Treatment
 Planning using Deep Neural Networks) อ.ที่ปรึกษาหลัก : อ. ดร.พรรณราย ศิริ
 เจริญ, อ.ที่ปรึกษาร่วม : ผศ. ดร.กิติวัฒน์ คำวัน

การบำบัดด้วยรังสีเฉพาะจุดเป็นวิธีการสลายลิมเลือดด้วยรังสีที่ใช้ในการรักษาเนื้องอก
 ร้ายในตับ อัตราส่วนเนื้องอกต่อนอตับเป็นพารามิเตอร์ที่สำคัญสำหรับการวางแผนการรักษาด้วย
 การนำสารกัมมันตรังสีเข้าสู่ร่างกายเฉพาะจุดด้วยอนุภาคเรซินไมโครสเฟียร์เคลือบสารกัมมันตรังสี
 อิตเทรียม-90 (^{90}Y) เพื่อใช้ประเมินปริมาณสารกัมมันตรังสีอิตเทรียม-90 จากปริมาตรของเนื้องอก
 และเนื้องอกตับของคนไข้ด้วยสารเภสัชรังสีการปล่อยโฟตอนเดี่ยวเทคนิคซีเอ็ม-99เอ็ม เอ็มเอเอ ใน
 การศึกษานี้เสนอ Multi-Scale Attention U-Net (MA-Net) ที่รวมคุณสมบัติที่หลากหลายของ
 รูปภาพที่มีการตัดเฉพาะส่วนช่องท้อง และใช้ฮิสโตแกรมจัดการรูปภาพสเปค-ซีที ที่มีการกระจาย
 ค่าแสงแบบปกติและผิดปกติ โดยใช้โมเดลที่ผ่านการฝึกอบรมล่วงหน้า Noisy student และการ
 เพิ่มความหลากหลายของภาพ งานวิจัยนี้แนะนำโมเดลที่แยกแยะการแบ่งส่วนเนื้องอกจากภาพ
 ซีทีและการแบ่งส่วนเนื้องอกตับจากภาพสเปค-ซีที และโมเดลรวมการแบ่งส่วนเนื้องอก
 ตับจากการฟิวชั่นภาพซีทีและภาพสเปค-ซีที ในงานวิจัยนี้ใช้ชุดข้อมูลสาธารณะ 3DIRCADb-01
 ร่วมกับชุดข้อมูลภาพเทคนิคซีเอ็ม-99เอ็ม เอ็มเอเอ ซีที สำหรับการแบ่งส่วนเนื้องอกตับและชุด
 ข้อมูลภาพเทคนิคซีเอ็ม-99เอ็ม เอ็มเอเอ สเปค-ซีที สำหรับเนื้องอกตับที่รวบรวมจากหน่วยเวช
 ศาสตร์นิวเคลียร์โรงพยาบาลจุฬาลงกรณ์สภากาชาดไทย วิธีการที่แนะนำโมเดลแยกการแบ่งเนื้อ
 ตับ และเนื้องอกตับ มีค่า Dice Similarity Coefficient (DSC) เท่ากับ 0.90, 0.66 และ
 Intersection over Union (IoU) เท่ากับ 0.84 และ 0.55 ตามลำดับ ซึ่งมีประสิทธิภาพการแบ่ง
 ส่วนที่แม่นยำกว่าโมเดลการเรียนรู้เดียวกันโดยใช้รูปภาพฟิวชั่นภาพ ซีที และสเปค-ซีที การแบ่ง
 ส่วนเนื้องอกตับและเนื้องอกตับ มีค่า DSC เท่ากับ 0.83, 0.62 และ IoU เท่ากับ 0.74 และ 0.51
 ตามลำดับ การแบ่งส่วนที่แม่นยำจะทำให้การบำบัดด้วยรังสีเฉพาะจุดมีประสิทธิภาพที่ดี

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์

ปีการศึกษา 2565

ลายมือชื่อนิสิต

ลายมือชื่อ อ.ที่ปรึกษาหลัก

ลายมือชื่อ อ.ที่ปรึกษาร่วม

6370303121 : MAJOR COMPUTER SCIENCE

KEYWORD: LIVER, TUMOR, CT, ^{99m}Tc -MAA SPECT/CT, Medical imaging,
Segmentation, Deep learning model

Sukanya Saeku : Liver and Tumor Segmentation in ^{99m}Tc -MAA SPECT/CT Images for Selective Internal Radiation Therapy Treatment Planning using Deep Neural Networks. Advisor: PUNNARAI SIRICHAROEN, Ph.D. Co-advisor: Asst. Prof. KITIWAT KHAMWAN, Ph.D.

The Tumor-Liver ratio (TLR) is an important dosimetric parameter for Selective Internal Radiation Therapy (SIRT) treatment using ^{90}Y -microspheres. TLR can be calculated by performing liver and tumor segmentation using Technetium- 99m Macroaggregated Albumin (^{99m}Tc -MAA). We propose Multi-Scale Attention U-Net (MA-Net) to learn and fuse various semantic features from different scales of abdominal cropped images and histogram adjustment are used for handling normal and abnormal histogram distribution. Noisy student pre-trained weights which were learned from noisy image dataset using data augmentation are initially used in our work. In this work comparing identify model framework of the liver from CT images and another model of tumor from SPECT/CT images and a combined liver-tumor segmentation model from fused images. 3DIRCADb-01 public dataset is also included along with our MAA CT images collected from King Chulalongkorn Memorial Hospital for liver segmentation, and MAA SPECT/CT dataset is used for tumor segmentation. Our proposed method can accurately identify liver and tumor regions with Dice Similarity Coefficient (DSC) of 0.90 and 0.66, and Intersection over Union (IoU) of 0.84 and 0.55, respectively. The model of liver-tumor regions from fused images with DSC of 0.83, 0.62, and IoU of 0.74 and 0.51, respectively. Accurate segmentation leads to improved SIRT efficacy.

Field of Study: Computer Science

Student's Signature

Academic Year: 2022

Advisor's Signature

Co-advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความอนุเคราะห์อย่างยิ่งของ อาจารย์ ดร. พรรณราย ศิริเจริญ อาจารย์ที่ปรึกษาวิทยานิพนธ์ซึ่งท่านได้กรุณาสละเวลาให้ความรู้ให้คำปรึกษาคำแนะนำแนวทางการวิจัยด้วยความเอาใจใส่อย่างดี ตลอดจนแก้ไขข้อบกพร่องต่าง ๆ เพื่อให้งานวิจัยนี้เสร็จสมบูรณ์ และสนับสนุนจนทำให้การวิจัยในครั้งนี้สำเร็จลุล่วงด้วยดีข้าพเจ้าจึงขอกราบระลึกพระคุณ อาจารย์ ดร. พรรณราย ศิริเจริญ ไว้ ณ ที่นี้

ข้าพเจ้าขอกราบขอบพระคุณ ศาสตราจารย์ ดร. บุญเสริม กิจศิริกุล และ ผู้ช่วยศาสตราจารย์ ดร. ยุทธพงษ์ จิรรัชโสภากุล กรรมการสอบวิทยานิพนธ์ที่ได้กรุณาสละเวลา ให้คำแนะนำ ตรวจสอบ และแก้ไขวิทยานิพนธ์ฉบับนี้ให้ถูกต้องสมบูรณ์ยิ่งขึ้น

ข้าพเจ้าขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. กิติวัฒน์ คำวัน อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม และ คุณนัท น้อยพินิจ นักรังสีผู้เชี่ยวชาญหน่วยเวชศาสตร์นิวเคลียร์ โรงพยาบาลจุฬาลงกรณ์สภากาชาดไทย ที่ให้คำแนะนำทางวิชาการ คำปรึกษาทางการแพทย์ และแหล่งข้อมูลที่สำคัญในการวิจัยครั้งนี้

ท้ายนี้ข้าพเจ้าขอกราบขอบพระคุณ คุณพ่อ คุณแม่ และครอบครัวสำหรับกำลังใจที่มีค่ายิ่ง เพื่อนร่วมงาน และมิตรสหาย ที่คอยติดตามให้กำลังใจให้การสนับสนุนและความช่วยเหลือในด้านต่าง ๆ และตัวข้าพเจ้าเอง ที่ส่งเสริมข้าพเจ้าจนมาถึงจุดนี้

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สุกัญญา แซ่คู

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญรูปภาพ.....	ญ
บทที่1 บทนำ.....	12
1.1 ที่มาและความสำคัญ.....	12
1.2 วัตถุประสงค์ของงานวิจัย.....	13
1.3 ขอบเขตงานวิจัย.....	13
1.4 ขั้นตอนและวิธีการดำเนินงานวิจัย.....	13
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	14
บทที่2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	15
2.1 ทฤษฎีที่เกี่ยวข้อง.....	15
2.1.1 U-Net.....	15
2.1.2 UNet++.....	16
2.1.3 MA-NET.....	16
2.1.4 Backbone.....	17
2.1.5 pre-trained.....	19
2.1.6 การปรับปรุงภาพ.....	20
2.1.7 การตัดส่วนของภาพ.....	20

2.1.8 การฟิวชั่น.....	21
2.1.9 การวัดดัชนีความคล้ายคลึงกันของโครงสร้าง	21
2.2 งานวิจัยที่เกี่ยวข้อง.....	22
บทที่ 3 วิธีการดำเนินงานวิจัย	29
3.1 ชุดข้อมูลสำหรับการฝึกและทดสอบเนื้อตับ	29
3.2 ชุดข้อมูลสำหรับการฝึกและทดสอบเนื้องอกในตับ	30
3.3 ชุดข้อมูลสำหรับการฝึกและทดสอบการฟิวชั่นอินพุตก่อนเข้าโมเดล.....	31
3.3 การเตรียมข้อมูล	31
3.3.1 การทำผลเฉลยข้อมูล	31
3.3.2 การปรับระดับสีของข้อมูลภาพ CT สแกน	32
3.3.3 การตัดเฉพาะส่วนช่องท้อง.....	33
3.3.4 การแบ่งข้อมูลชุดการฝึกฝนและทดสอบ	34
3.4 การฟิวชั่น	35
3.4.1 การวัดดัชนีความคล้ายคลึงกันของโครงสร้าง	35
3.4.2 การฟิวชั่น.....	37
3.5 การสร้างแบบจำลองการแบ่งส่วน	38
3.5.1 การแบ่งส่วนเนื้อตับ	38
3.5.2 การแบ่งส่วนเนื้องอก	39
3.5.3 การแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพฟิวชั่น	43
3.5.4 พารามิเตอร์ที่เกี่ยวข้องกับแบบจำลอง.....	44
3.6 การตรวจสอบความถูกต้องของแบบจำลอง เภณท์การประเมินผลการวิจัย	44
3.6.1 Dice Similarity Coefficient (DSC).....	44
3.6.2 Intersection over Union (IoU).....	44
บทที่ 4 การประเมินผลการวิจัย	45



4.1	เปรียบเทียบประสิทธิภาพการแบ่งส่วนเนื้อตับ	45
4.1.1	ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ Backbone.....	45
4.1.2	ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ EfficientNet และ pre-trained	45
4.1.3	ผลการแบ่งส่วนเนื้อตับที่มีประสิทธิภาพต่ำสุด	47
4.2	เปรียบเทียบประสิทธิภาพการแบ่งส่วนเนื้ออกตับ.....	48
4.2.1	ผลลัพธ์การแบ่งส่วนเนื้ออกตับของแต่ละ Model	48
4.2.2	ผลลัพธ์การแบ่งส่วนเนื้ออกตับในแต่ละวิธีการปรับปรุงค่าสี	48
4.2.3	ผลการแบ่งส่วนเนื้ออกตับที่มีประสิทธิภาพต่ำสุด	50
4.3	เปรียบเทียบประสิทธิภาพการแบ่งส่วนเนื้อตับและเนื้ออกตับจากภาพฟิวชั่น.....	51
4.4	เปรียบเทียบผลลัพธ์การแบ่งส่วนในชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ	53
4.5	เปรียบเทียบระยะเวลาในการทดสอบ	54
บทที่ 5	บทสรุป	55
5.1	สรุปผลการวิจัย	55
5.2	ปัญหาและข้อจำกัดที่พบจากการวิจัย.....	56
5.3	ข้อเสนอแนะ	56
บรรณานุกรม	57
ประวัติผู้เขียน	60

สารบัญตาราง

	หน้า
ตารางที่ 1 ขั้นตอนและระยะเวลาดำเนินการวิจัย	14
ตารางที่ 2 เปรียบเทียบงานวิจัยการแบ่งส่วนเนื้อตับและเนื้อ	28
ตารางที่ 3 ชุดข้อมูลการแบ่งส่วนเนื้อตับ	30
ตารางที่ 4 ชุดข้อมูลการแบ่งส่วนเนื้ออกตับ	31
ตารางที่ 5 ชุดข้อมูลการแบ่งส่วนเนื้อตับและเนื้ออกตับจากภาพฟิวชั่น	31
ตารางที่ 6 ชุดข้อมูลคนไข้	35
ตารางที่ 7 ค่าความเข้มสีเฉลี่ยน้อยสุดและมากที่สุดของชุดข้อมูลปกติและผิดปกติ	41
ตารางที่ 8 พารามิเตอร์ที่เกี่ยวข้องกับแบบจำลอง	44
ตารางที่ 9 ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ Backbone	45
ตารางที่ 10 ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ EfficientNet และ pre-trained	46
ตารางที่ 11 ผลลัพธ์การแบ่งส่วนเนื้ออกตับของแต่ละ Backbone และ Model	48
ตารางที่ 12 ผลลัพธ์การแบ่งส่วนเนื้ออกตับในการปรับปรุงค่าสี	49
ตารางที่ 13 ผลลัพธ์การแบ่งส่วนเนื้ออกตับในคนไข้ที่มีการกระจายความเข้มแสงปกติ	50
ตารางที่ 14 ผลลัพธ์การแบ่งส่วนโมเดลเนื้อตับและเนื้ออกตับ	51
ตารางที่ 15 ผลลัพธ์การแบ่งส่วนโมเดลภาพ SPECT/CT ตรวจสอบความคล้ายคลึงกับภาพ CT	52
ตารางที่ 16 เปรียบเทียบผลลัพธ์การแบ่งส่วนในแต่ละชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ	53
ตารางที่ 17 ระยะเวลาในการทดสอบโมเดล	54

สารบัญรูปภาพ

	หน้า
รูปที่ 1 สถาปัตยกรรม U-Net	15
รูปที่ 2 สถาปัตยกรรม UNet++	16
รูปที่ 3 สถาปัตยกรรม MA-NET	17
รูปที่ 4 สถาปัตยกรรม ResNet	17
รูปที่ 5 สถาปัตยกรรม VGG	18
รูปที่ 6 สถาปัตยกรรม EfficientNet	19
รูปที่ 7 โครงสร้าง Noisy Student	20
รูปที่ 8 อัลกอริทึม The Attention Hybrid Connection Net ที่นำเสนอในการวิจัย	23
รูปที่ 9 การแสดงแผนผังของสถาปัตยกรรมโมเดล MA-Net ที่นำเสนอในงานวิจัย	24
รูปที่ 10 การแสดงแผนผังของสถาปัตยกรรมโมเดล ที่นำเสนอในงานวิจัย	25
รูปที่ 11 การจัดหมวดหมู่ของวิธีการในการหลอมรวมรูปภาพทางการแพทย์	26
รูปที่ 12 กลยุทธ์พีวชั้นระดับอินพุต	26
รูปที่ 13 กลยุทธ์พีวชั้นระดับระดับเลเยอร์	27
รูปที่ 14 พีวชั้นระดับการตัดสินใจ	27
รูปที่ 15 ตัวอย่างรูป CT สแกน ของชุดข้อมูล 3DIRCADb-01	29
รูปที่ 16 ตัวอย่างรูป CT สแกนหลังการปรับ HU ชุดข้อมูลโรงพยาบาลจุฬาลงกรณ์	30
รูปที่ 17 การทำผลเฉลี่ยเนื้อตับ จากโปรแกรม MIM	32
รูปที่ 18 การทำผลเฉลี่ยเนื้ออกตับ จากโปรแกรม MIM	32
รูปที่ 19 ค่าหน่วย HU	32
รูปที่ 20 รูป CT สแกน ข้อมูล 3DIRCADb-01 ก่อนปรับและหลังปรับค่าหน่วย HU	33
รูปที่ 21 รูป CT สแกน ข้อมูลโรงพยาบาลจุฬาลงกรณ์ ก่อนปรับและหลังปรับค่าหน่วย HU	33

รูปที่ 22 ขนาดของชุดข้อมูลภาพ CT ก่อนการตัดเฉพาะส่วนของช่องท้อง	34
รูปที่ 23 ขนาดของชุดข้อมูลภาพ CT หลังการตัดเฉพาะส่วนของช่องท้อง	34
รูปที่ 24 ขนาดของชุดข้อมูลภาพ SPECT/CT ก่อนการตัดเฉพาะส่วนของช่องท้อง	34
รูปที่ 25 ขนาดของชุดข้อมูลภาพ SPECT/CT หลังการตัดเฉพาะส่วนของช่องท้อง	34
รูปที่ 26 จำนวนรูปภาพ CT และ SPECT/CT ในแต่ละคนไข้	35
รูปที่ 27 การจับคู่ภาพ CT และ SPECT/CT	37
รูปที่ 28 ภาพ CT ภาพ SPECT/CT และภาพการฟิวชั่น CT กับ SPECT/CT	38
รูปที่ 29 กระบวนการโมเดลแยกการแบ่งส่วนเนื้อตับ	38
รูปที่ 30 ภาพ SPECT สแกน ภาพ CT สแกน และภาพ SPECT/CT สแกน	39
รูปที่ 31 รูป SPECT/CT สแกน ลาเบล และลักษณะการกระจายตัวความเข้มแสงภาพปกติ	40
รูปที่ 32 รูป SPECT/CT สแกน ลาเบล และลักษณะการกระจายตัวความเข้มแสงภาพผิดปกติ	40
รูปที่ 33 การกระจายความเข้มในแต่ละช่องสี RGB ของข้อมูลกลุ่มปกติและผิดปกติ	41
รูปที่ 34 การแปลงค่าความเข้มสีผิดปกติให้อยู่ในระดับปกติ	42
รูปที่ 35 รูปภาพ SPECT/CT ที่มีการปรับปรุงค่าสี	42
รูปที่ 36 กระบวนการโมเดลแยกการแบ่งส่วนเนื้ออกตับ	43
รูปที่ 37 กระบวนการฟิวชั่นและโมเดลรวมแบ่งส่วนเนื้อตับและเนื้ออกตับ	43
รูปที่ 38 รูปภาพ CT สแกนที่มีซีสตีโนตีและผลการทดสอบ	46
รูปที่ 39 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้อตับ	47
รูปที่ 40 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้อตับในคนไข้ที่มีสิ่งแปลกปลอมในร่างกาย	47
รูปที่ 41 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้อตับในคนไข้ที่มีการใช้เคมีบำบัด	48
รูปที่ 42 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้ออกตับ	49
รูปที่ 43 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้ออกตับในคนไข้ที่มีเนื้ออกขนาดเล็ก	50
รูปที่ 44 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้ออกตับที่มีการกระจายความเข้มแสงผิดปกติ ...	50
รูปที่ 45 ผลการทดสอบโมเดลการแบ่งส่วนเนื้อตับและเนื้ออกตับจากภาพฟิวชั่น	53

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

โรคมะเร็งเป็นกลุ่มของโรคที่เกิดจากเซลล์ของร่างกายที่มีการเจริญเติบโต หรือมีการแบ่งตัวเพิ่มจำนวนอย่างรวดเร็วจนเกิดเป็นก้อนเนื้อผิดปกติ ทำให้ขาดเลือดไปหล่อเลี้ยงจนเกิดการตายของเซลล์ในก้อนเนื้อ ในปัจจุบันพบชนิดของมะเร็งมากกว่า 100 ชนิด [1] ซึ่งโรคมะเร็งเป็นสาเหตุการเสียชีวิตอันดับต้นๆ ของคนทั่วโลกจากข้อมูลผู้ป่วยโรคมะเร็งขององค์การอนามัยโลก (World Health Organization: WHO) ได้เปิดเผยจำนวนประชาชนที่ถูกวินิจฉัยเป็นผู้ป่วยโรคมะเร็งในปีพุทธศักราช 2563 ประมาณ 19.3 ล้านราย สถิติของโรคมะเร็งที่พบ 5 อันดับแรกในโลก ได้แก่ มะเร็งปอด มะเร็งลำไส้ มะเร็งตับ มะเร็งกระเพาะอาหาร และมะเร็งเต้านม ในส่วนของมะเร็งตับมีการตายสูงถึง 8.3 แสนคน หรือร้อยละ 8.3 ของการเสียชีวิตด้วยโรคมะเร็งทั้งหมด [1] ข้อมูลสถิติโรคมะเร็งในประเทศไทย โรคมะเร็งเป็นสาเหตุการเสียชีวิตอันดับ 1 ของประชากรไทยมาตั้งแต่ปีพุทธศักราช 2542 ในส่วนของอัตราการเกิดโรคมะเร็งตับประเทศไทยอยู่ในอันดับที่ 6 ของโลก [2]

ตับเป็นอวัยวะที่ใหญ่ที่สุดและเป็นต่อมที่ใหญ่ที่สุดในร่างกายมนุษย์ ตับเป็นรูปสามเหลี่ยมโดยประมาณและประกอบด้วยสองแฉกที่แยกจากกันกลีบขวาจะมีขนาดใหญ่และกลีบซ้ายที่เล็กกว่า การตรวจเอกซเรย์คอมพิวเตอร์ (CT) คือการตรวจวินิจฉัยด้วยภาพทางการแพทย์ที่ใช้เพื่อช่วยตรวจหาโรคอวัยวะภายในอื่นๆ และมักใช้เพื่อระบุสาเหตุของอาการปวดโดยไม่ทราบสาเหตุ การทำ CT สแกนนั้นรวดเร็ว ไม่เจ็บปวด และมีคุณสมบัติความละเอียดเชิงพื้นที่สูง การแบ่งส่วนของเนื้องอกในตับมีความหลากหลายของลักษณะ ขนาด รูปร่าง และตำแหน่งของเนื้องอกที่แตกต่างกัน ทำให้การแบ่งส่วนเนื้องอกในตับกลายเป็นงานที่ท้าทาย การวิจัยเกี่ยวกับอัลกอริทึมการแบ่งส่วนเนื้องอกมีความสำคัญในการวินิจฉัยและการรักษาทางคลินิกสามารถลดปริมาณงานการแบ่งส่วนด้วยนักรังสีแพทย์ เพิ่มความเร็ว และสามารถปรับปรุงความแม่นยำในการแบ่งส่วนเนื้องอก ซึ่งช่วยเพิ่มอัตราความสำเร็จของการรักษาเนื้องอกตับ [3]

การรักษาด้วยการนำสารกัมมันตรังสีเข้าสู่ร่างกายเฉพาะจุด (Selective Internal Radiation Therapy: SIRT) เป็นหนึ่งในวิธีการรักษาแบบไม่ต้องผ่าตัดสำหรับเนื้องอกที่ตับด้วยอนุภาคเรซินไมโครสเฟียร์เคลือบสารกัมมันตรังสีไอทริียม 90 (Yttrium-90: 90Y) ไปยังเนื้องอกที่ตับโดยตรงเพื่อไปอุดตันเส้นเลือดที่จะไปหล่อเลี้ยงก้อนมะเร็ง เมื่อเส้นเลือดแดงถูกทำให้อุดตันก้อนมะเร็งก็จะขาดออกซิเจนและสารอาหารโดยไม่ทำลายเนื้อตับที่ดี [2] ก่อนการรักษาด้วย 90Y จะต้องมีการประเมินการดูดซับสารรังสีของคนไข้เพื่อใช้ประเมินปริมาณสารกัมมันตรังสี 90Y จากปริมาตรของเนื้อ

ดับและเนื้องอกตับของคนไข้ โดยใช้สารเภสัชรังสีได้การปล่อยโฟตอนเดี่ยว $^{99m}\text{Tc-Macro}$ Aggregated Albumin ($^{99m}\text{Tc-MAA}$) [3]

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อแบ่งส่วนของเนื้องอกสำหรับภาพเอกซเรย์คอมพิวเตอร์ Computed Tomography (CT) และเนื้องอกในตับสำหรับภาพ Single-Photon Emission Computed Tomography/Computed Tomography (SPECT/CT) ด้วยรูปภาพที่ได้รับสารเภสัชรังสี $^{99m}\text{Tc-Macro}$ Aggregated Albumin ($^{99m}\text{Tc-MAA}$) อย่างแม่นยำ

1.3 ขอบเขตงานวิจัย

1.3.1 ชุดข้อมูลการฝึกรูปภาพแบ่งพื้นที่เนื้องอกด้วยภาพ CT สแกนจากชุดข้อมูลสาธารณะ 3DIRCADb-01

1.3.2 ชุดข้อมูลที่ใช้สำหรับการเรียนรู้ และทดสอบโมเดลจากผู้ป่วยที่ทำการฉายแสง โดยได้รับสารเภสัชรังสี $^{99m}\text{Tc-MAA}$ จากคนไข้ที่โรงพยาบาลจุฬาลงกรณ์ ในปีพุทธศักราช 2559 ถึงปีพุทธศักราช 2564 ช่วงอายุ 36 ปี ถึง 85 ปี

1.3.3 การแบ่งส่วนเนื้องอกด้วยภาพ CT สแกน และการแบ่งส่วนเนื้องอกด้วยภาพ SPECT/CT สแกน

1.3.4 ผู้เชี่ยวชาญที่ทำผลเฉลยข้อมูลมีมากกว่า 1 คน โดยนักรังสีการแพทย์ และแพทย์เวชศาสตร์นิวเคลียร์

1.4 ขั้นตอนและวิธีการดำเนินงานวิจัย

1.4.1 ศึกษาทฤษฎีที่เกี่ยวข้องกับการแบ่งส่วนของรูปภาพ

1.4.2 ศึกษางานวิจัยที่เกี่ยวข้องกับการแบ่งเนื้องอกในภาพ CT สแกน และ SPECT/CT สแกน

1.4.3 ทำผลเฉลยข้อมูลลาเบลของชุดข้อมูลโรงพยาบาลจุฬาลงกรณ์

1.4.4 ออกแบบแบบจำลองในการแบ่งส่วนรูปภาพ

1.4.5 สร้างแบบจำลองในการแบ่งส่วนรูปภาพและฝึกแบบจำลอง

1.4.6 วิเคราะห์ผลและวัดประสิทธิภาพของแบบจำลองในการแบ่งส่วน

1.4.7 ปรับปรุงประสิทธิภาพของแบบจำลองโมเดลในการแบ่งส่วน

1.4.7 วิเคราะห์และสรุปผลการทดสอบชุดข้อมูลการทดสอบ

1.4.8 การเขียนงานวิจัย

ตารางที่ 1 ขั้นตอนและระยะเวลาดำเนินการวิจัย

ขั้นตอน	ระยะเวลาดำเนินการ
1.4.1 ศึกษาทฤษฎีที่เกี่ยวข้องกับการแบ่งส่วนของรูปภาพ	กุมภาพันธ์ 2564 ถึง เมษายน 2566
1.4.2 ศึกษางานวิจัยที่เกี่ยวข้องกับการแบ่งเนื้อตับในภาพ CT สแกน และ SPECT/CT สแกน	กุมภาพันธ์ 2564 ถึง เมษายน 2566
1.4.3 ทำผลเฉลยข้อมูลลาเบลของชุดข้อมูลโรงพยาบาลจุฬาลงกรณ์	ตุลาคม 2564 ถึง พฤษภาคม 2565
1.4.4 ออกแบบแบบจำลองในการแบ่งส่วนรูปภาพ	ธันวาคม 2564 ถึง มีนาคม 2565
1.4.5 สร้างแบบจำลองในการแบ่งส่วนรูปภาพและฝึกแบบจำลอง	มีนาคม 2565 ถึง พฤษภาคม 2565
1.4.6 วิเคราะห์ผลและวัดประสิทธิภาพของแบบจำลองในการแบ่งส่วน	พฤษภาคม 2565 ถึง ตุลาคม 2565 ถึง
1.4.7 ปรับปรุงประสิทธิภาพของแบบจำลองโมเดลในการแบ่งส่วน	ตุลาคม 2565 ถึง เมษายน 2566
1.4.8 วิเคราะห์และสรุปผลการทดสอบชุดข้อมูลการทดสอบ	พฤศจิกายน 2565 ถึง พฤษภาคม 2566
1.4.9 การเขียนงานวิจัย	พฤษภาคม 2565 ถึง พฤษภาคม 2566

1.5 ประโยชน์ที่คาดว่าจะได้รับ

- 1.5.1 แบบจำลองสามารถแบ่งพื้นที่เนื้อตับและเนื้ออกในตับได้
- 1.5.2 ช่วยให้ผู้เชี่ยวชาญสามารถแบ่งเนื้อตับและเนื้ออกในตับได้โดยอัตโนมัติ
- 1.5.3 ช่วยให้เป็นมาตรฐานเดียวกันในการแบ่งส่วนเนื้อตับและเนื้ออกตับ


บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 U-Net


U-Net เป็นสถาปัตยกรรมเครือข่ายแบบคอนโวลูชัน (Convolutional) เพื่อการแบ่งส่วนภาพที่รวดเร็วและแม่นยำจนถึงปัจจุบันได้มีประสิทธิภาพเหนือกว่าวิธีก่อนหน้านี้ เช่น เครือข่ายการบิดหน้าต่างบานเลื่อน เกี่ยวกับความท้าทาย ISBI สำหรับการแบ่งส่วนโครงสร้างของเซลล์ประสาทในกล้องจุลทรรศน์อิเล็กตรอน ได้รับรางวัล Grand Challenge for Computer-Automated Detection of Caries in Bitewing Radiography ที่ ISBI 2015 และได้รับรางวัล Cell Tracking Challenge ที่ ISBI 2015 สถาปัตยกรรมตัวอย่างสำหรับ 32x32 พิกเซลในความละเอียดต่ำสุด คุณลักษณะแบบหลายช่องสัญญาณ [4] U-Net มีรูปแบบ CNN โดยมีตัวเข้ารหัส (Encode) จะลดความละเอียดขนาดข้อมูลลงเป็นลำดับ และตัวถอดรหัส (Decode) จะขยายความละเอียดข้อมูลให้กลับมาเป็นขนาดเท่าเดิม ในแต่ละชั้นลักษณะคล้ายรูปตัว U และยังสามารถรักษาความละเอียดของภาพได้โดยการใช้ skip connection ในระดับความละเอียดเดียวกัน



รูปที่ 1 สถาปัตยกรรม U-Net

2.1.2 UNet++


UNet++ ซึ่งเป็นสถาปัตยกรรมพื้นฐานจาก U-Net สำหรับการแบ่งส่วนภาพเป็นเครือข่ายด้วยเครือข่ายย่อยตัวเข้ารหัสหรือแกนหลักตามด้วยเครือข่ายย่อยตัวถอดรหัสเพื่อปรับปรุงความแม่นยำในการแบ่งส่วนมีเส้นทางของ skip ที่ออกแบบใหม่เส้นสีเขียวและสีน้ำเงิน ในรูปที่ 2 โดย skip connection จะผ่านการทำ dense convolution block ที่เชื่อมต่อเครือข่ายย่อยทั้งสองเครือข่ายที่ซ้อนกันและการใช้ deep supervision [5]



รูปที่ 2 สถาปัตยกรรม UNet++

2.1.3 MA-NET

A Multi Scale Attention Module (MA-NET) เป็นสถาปัตยกรรมใหม่พื้นฐานจาก U-Net สำหรับการแบ่งส่วน โดยมีการเพิ่มในส่วนของ attention gates ในแต่ละ scales ความแตกต่างของ Convolutional Neural Networks (CNN) มีการเพิ่ม Position-wise Attention Block (PAB) เพื่อจับภาพความสัมพันธ์การพึ่งพาเชิงพื้นที่ระหว่างแผนที่คุณลักษณะ (Feature maps) ตำแหน่งสองตำแหน่ง PAB สามารถสร้างแบบจำลองข้อมูลเชิงบริบทเชิงพื้นที่ที่หลากหลายกว่าแผนที่คุณลักษณะเฉพาะที่ PAB พิจารณาการพึ่งพาเชิงพื้นที่ระหว่างพิกเซล และเพิ่ม Multi-scale Fusion Attention Block (MFAB) เพื่อแยกการพึ่งพาระหว่างกันระหว่างช่องสัญญาณคุณลักษณะต่างๆ เรียนรู้ถึงความสำคัญของช่องคุณลักษณะแต่ละช่อง ซึ่งมาจากแผนที่คุณลักษณะหลายระดับโดยไม่มีมิติเชิงพื้นที่เพิ่มเติม ผ่านการรวมแผนที่คุณลักษณะระดับสูงและระดับต่ำคุณสมบัตินี้ระดับสูงมีข้อมูลความหมายของภาพมากมาย และคุณสมบัตินี้ระดับต่ำจากการเชื่อมต่อแบบข้าม (skip) มีข้อมูลขอบเพิ่มเติม คุณสมบัตินี้ระดับต่ำใช้เพื่อกู้คืนรายละเอียดของภาพกลไกความสนใจสำหรับคุณสมบัตินี้ระดับสูงและระดับต่ำเพื่อเพิ่มน้ำหนักของข้อมูลสำคัญสำหรับแต่ละช่องพีเจอร์ในงานแบ่งส่วนและข้อมูลพีเจอร์ที่ไม่มีประโยชน์จะถูกตัดออก [6]

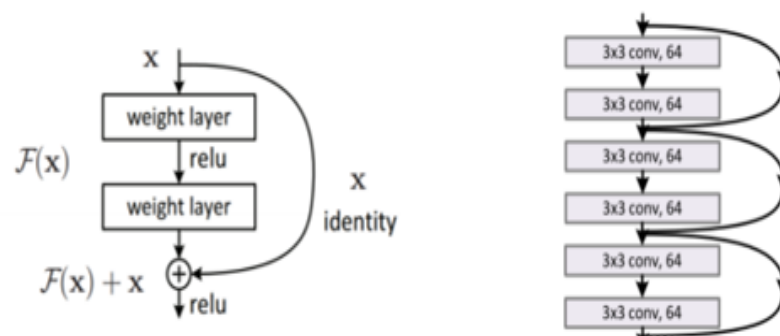


รูปที่ 3 สถาปัตยกรรม MA-NET

2.1.4 Backbone

2.1.4.1 ResNet


โครงข่ายประสาทเทียมแบบลึกที่เรียกว่า ResNet50 คือแบบจำลองที่มีจำนวน 50 ชั้น ซึ่งสถาปัตยกรรมประกอบด้วย 4 Block ในแต่ละ Block จะมี Convolutional Layer ประกอบด้วย 3, 4, 6 และ 3 ตามลำดับ ซึ่งรวม Convolutional Layer ชั้นที่ติดกับข้อมูลนำเข้าและชั้นที่ติดกับข้อมูลทำนายจากสถาปัตยกรรมใช้สำหรับการดึงคุณลักษณะจากภาพออกมาทำให้มีมิติมากขึ้น [7]



รูปที่ 4 สถาปัตยกรรม ResNet

2.1.4.2 VGG


สถาปัตยกรรมนี้ถูกพัฒนาขึ้นมาโดย K. Simonyan และ A. Zisserman นักวิจัยจากมหาวิทยาลัย Oxford ผ่านเอกสารตีพิมพ์ชื่อว่า “Very Deep Convolutional Networks for Large-Scale Image Recognition” สถาปัตยกรรม VGG มีจุดเด่นคือการแทนที่ hyperparameter จำนวนมากด้วยการออกแบบเลเยอร์ conv2D 3x3 pixels, 1 stride และการใช้ same padding และ maxpooling 2x2 pixels, 2 stride แบบเดียวกันตลอดทั้งโครงสร้างเลเยอร์ 16 ชั้น จึงถูกเรียกว่า VGG 16 [8]



รูปที่ 5 สถาปัตยกรรม VGG

2.1.4.3 EfficientNet

EfficientNet เป็นโครงข่ายประสาทแบบคอนโวลูชันซึ่งถูกพัฒนาโดยทีมงานกูเกิลจุดกำเนิดของโครงข่ายประสาทแบบคอนโวลูชันนี้คือความท้าทายในการเพิ่มประสิทธิภาพ และความแม่นยำของโมเดล ซึ่งจากงานวิจัยส่วนใหญ่มีการเพิ่มมิติของโครงข่ายเพียงอย่างเดียวทั้งด้านความกว้าง ด้านความลึก หรือด้านความละเอียดของรูปภาพเพื่อช่วยเพิ่มความแม่นยำของโมเดล EfficientNet ได้ค้นพบวิธีการที่จะช่วยเพิ่มประสิทธิภาพและความแม่นยำของโมเดลอย่างมีประสิทธิภาพ ซึ่งเรียกวิธีนี้ว่าการปรับขนาดแบบผสม ซึ่งการปรับขนาดทั้งด้านความกว้างการเพิ่มความกว้างของเครือข่ายช่วยให้ได้คุณภาพสมบัติที่ปรับแต่งได้อย่างละเอียดมากขึ้น ด้านความลึกเมื่อจำนวนเลเยอร์เพิ่มขึ้นพีเจอร์จะมีความซับซ้อนมากขึ้น และด้านความละเอียดของรูปภาพของเครือข่ายจะช่วยให้โมเดลเรียนรู้คุณลักษณะต่างๆ ได้ดีขึ้น ซึ่งจะช่วยให้โมเดลนั้นสามารถสกัดคุณลักษณะ (Feature Extraction) ได้แม่นยำมากขึ้น EfficientNet จะมีตั้งแต่ B0 ถึง B7 โดย B0 จะเป็นการปรับมิติด้านความกว้างและด้านความลึกน้อย และ B7 จะเป็นการปรับมิติด้านความกว้างและด้านความลึกมาก [9]



รูปที่ 6 สถาปัตยกรรม EfficientNet

2.1.5 pre-trained

การประมวลผลรูปภาพในการเริ่มต้นฝึกโมเดลการเรียนรู้เชิงลึกที่ซับซ้อนต้องใช้ทั้งข้อมูลขนาดใหญ่ และใช้ระยะเวลาหลายวันในการฝึกจึงมีการนำแบบจำลองที่ได้รับการฝึกกับชุดข้อมูลขนาดใหญ่แล้วนำมาใช้ฝึกต่อด้วยชุดข้อมูลใหม่ที่ใกล้เคียงกันมาใช้เป็นส่วนหนึ่งของโมเดลใหม่เพื่อช่วยลดเวลาการฝึกของโมเดลและเพิ่มประสิทธิภาพการเรียนรู้ของโมเดลในชุดข้อมูลใหม่


2.1.5.1 ImageNet

ในช่วงปีคริสต์ศักราช 2009 ถึง 2010 กลุ่มนักวิจัยจากมหาวิทยาลัยพรินซ์ตัน และมหาวิทยาลัยสแตมฟอร์ด ได้รวบรวมภาพที่มีภาพความละเอียดสูงไว้มากกว่า 15,000,000 มีจำนวน 22,000 หมวดหมู่ ในรูปมีตั้งแต่วัตถุขนาดเล็กจวบจนถึงวัตถุขนาดใหญ่จนเกือบเต็มรูปหรือมีวัตถุรูปทรงแตกต่างกันมากมายหลากหลายสีและลวดลายในชุดข้อมูล ตั้งแต่ปีคริสต์ศักราช 2010 โครงการ ImageNet จัดให้มีการประกวดซอฟต์แวร์ประจำปี ซึ่งก็คือ ImageNet Large Scale Visual Recognition Challenge (ILSVRC) การแข่งขันกันในการจำแนกประเภทวัตถุและการตรวจจับหมวดหมู่วัตถุหลายร้อยประเภทและรูปภาพนับล้านรูป [9]

2.1.5.2 Noisy Student

Noisy Student คือ pre-train model เป็นแนวทางการเรียนรู้แบบกึ่งมีผู้สอน (semi-supervised learning) ที่ใช้ชุดข้อมูล ImageNet ถูกพัฒนาโดยกลุ่มนักวิจัยจากกูเกิลเพื่อปรับปรุงการจัดประเภทของ ImageNet ที่มีความแม่นยำสูงสุด 88.4% ด้วยชุดข้อมูล ImageNet จุดเด่นคือการเรียนรู้แบบด้วยตนเองและเพิ่มแบบจำลองในขณะที่เรียนรู้ใน ImageNet โดยเพิ่มการรบกวนขณะทำการเรียนรู้โมเดลในโมเดลฝึกสอนจะทำการทดสอบโมเดลในภาพที่มีชุดข้อมูลผลเฉลยจริง จากนั้นจะนำโมเดลที่ได้มาสร้างภาพผลเฉลยหลอก และฝึกโมเดลการเรียนรู้จากภาพที่มีผลเฉลยจริง

และภาพผลเฉลยหลอกอัลกอริทึมจะมีการทำซ้ำสองสามครั้ง โดยเปลี่ยนจากการเรียนรู้เป็นการฝึกสอนโดยให้โมเดลการเรียนรู้จะสร้างชุดข้อมูลผลเฉลยหลอกแบบโมเดลฝึกฝน และนำชุดข้อมูลภาพที่มีผลเฉลยจริง และภาพผลเฉลยหลอกมาทดสอบโมเดลการเรียนรู้ในขณะเรียนรู้โมเดลจะทำการสุ่มถอดบางโหนดออก (dropout) การเพิ่มปริมาณข้อมูลภาพและความลึกสุ่ม (stochastic depth) ระหว่างการเรียนรู้ขณะฝึกสอน [10] ดังรูปที่ 7



รูปที่ 7 โครงสร้าง Noisy Student

2.1.6 การปรับปรุงภาพ

การแก้ไขคอนทราสต์ในรูปภาพเป็นกระบวนการที่เกี่ยวข้องกับการบวก การลบ การคูณ หรือการหาร ของค่าคงที่ที่เหมือนกันกับทุกพิกเซลในภาพ การยืดเปอร์เซ็นต์เชิงเส้น โดยระบุช่องสี R, G, B โดยที่ช่องสี RGB (Red, Green, Blue) เป็นระบบสีตามหลักการแสดงสีของเครื่องคอมพิวเตอร์ การยืดคอนทราสต์เป็นการกระจายค่าพิกเซลของฮิสโตแกรมจากค่าความเข้มหนึ่งไปยังอีกช่วงความเข้มที่ต้องการ เทคนิคนี้เป็นการเพิ่มคอนทราสต์ของรูปภาพด้วยค่าพิกเซลที่เข้มข้นในบริเวณหนึ่งไปยังอีกบริเวณเพื่อปรับปรุงคุณสมบัติของรูปภาพให้ดีขึ้น

2.1.7 การตัดส่วนของภาพ

การตัดส่วน (cropping) เป็นการตัดส่วนของรูปภาพโดยนำส่วนของพื้นที่ที่ไม่ต้องการ นำออกจากรูปภาพ หรือการลดขนาดของพื้นที่ที่ไม่ต้องการนำไปใช้ เพื่อให้ข้อมูลรูปภาพที่นำไปใช้มีข้อมูลที่ที่ต้องการ

2.1.8 การพิวชัน

การพิวชันเป็นการหลอมข้อมูลภาพเป็นหนึ่งในเครื่องมือในการเอาข้อมูลจากแหล่งกำเนิดที่ต่างกันของข้อมูลสองภาพหรือมากกว่ามารวมกัน โดยภาพใหม่ที่ได้นี้จะเป็นการรวมตัวกันของข้อมูลหรือรายละเอียดในแต่ละภาพที่นำมาผสมกัน มีวัตถุประสงค์เพื่อให้ได้ภาพที่มีรายละเอียดและข้อมูลที่เพียงพอสำหรับการนำไปใช้และลักษณะที่หลากหลายมารวมกันเพื่อให้ได้เป็นข้อมูลตัวแทนใหม่ที่มีคุณภาพดีขึ้น ซึ่งมีหลากหลายเครื่องมือ เช่น การบวกรูปภาพ (addWeighted), การทำเวฟเล็ต (wavelet)

2.1.9 การวัดดัชนีความคล้ายคลึงกันของโครงสร้าง

การวัดดัชนีความคล้ายคลึงกันของโครงสร้าง Structural Similarity Index (SSIM) ในการพิวชันภาพทั้งสองรูปภาพ ก่อนที่จะทำการรวมนั้นจะต้องมีการปรับขนาดให้มีขนาดเท่ากันก่อนนำไปการหลวมรวมภาพ โดยการวัดดัชนีความคล้ายคลึงกันของโครงสร้าง Structural Similarity Index (SSIM) ในการตรวจวัดความคล้ายคลึงกันของภาพ CT สแกนและ SPECT/CT สแกนที่ใช้ในการพิวชันของชุดข้อมูลคนไข้แต่ละคน การวัดเปรียบเทียบของคุณสมบัติสามแบบระหว่างตัวอย่างของภาพ x และ y ความสว่าง (l) คอนทราสต์ (c) และโครงสร้าง (s) ซึ่งผลลัพธ์มีค่าระหว่าง -1 ถึง $+1$ [11] โดยค่า $+1$ หมายถึงรูปภาพ 2 รูปนั้นคล้ายกันมากหรือเหมือนกัน ในขณะที่ค่า -1 หมายถึงรูปภาพ 2 รูปนั้นแตกต่างกันมาก ดังสมการที่ 1

$$SSIM(x, y) = [l(x, y)^\alpha \cdot (c(x, y)^\beta \cdot (s(x, y)^\gamma)] \quad \dots (1)$$

โดยที่

l คือ ความสว่าง

c คือ คอนทราสต์

s คือ โครงสร้าง

x คือ รูปภาพที่ 1

y คือ รูปภาพที่ 2

α, β, γ คือ การตั้งค่าน้ำหนักโดยกำหนดเป็น 1

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 U-Net: Convolutional Networks for Biomedical Image Segmentation

U-Net เป็นสถาปัตยกรรม โครงข่ายประสาทแบบคอนโวลูชันเพื่อการแบ่งส่วนภาพที่รวดเร็ว และแม่นยำ ในการแข่งขันสำหรับการแบ่งส่วนโครงสร้างของเซลล์ประสาท ในกล้องจุลทรรศน์อิเล็กตรอน ได้รับรางวัล Grand Challenge for Computer-Automated Detection of Caries in Bitewing Radiography [4]

2.2.2 UNet++: A Nested U-Net Architecture for Medical Image Segmentation

UNet++ ซึ่งเป็นสถาปัตยกรรมพื้นฐานจาก U-Net สำหรับการแบ่งส่วนภาพ เป็นเครือข่ายด้วยเครือข่ายย่อยตัวเข้ารหัสหรือแกนหลักตามด้วยเครือข่ายย่อยตัวถอดรหัส เพื่อปรับปรุงความแม่นยำในการแบ่งส่วน มี skip ที่ออกแบบใหม่เพื่อลดช่องว่างระหว่างแผนผังคุณลักษณะของเครือข่ายย่อยตัวเข้ารหัสและตัวถอดรหัส โดย skip connection จะผ่านการทำ dense convolution block ที่เชื่อมต่อเครือข่ายย่อยทั้งสองเครือข่ายที่ซ้อนกัน และเพิ่มเครือข่ายตัวเข้ารหัสและตัวถอดรหัส deeply-supervised โดยที่เครือข่ายย่อยเชื่อมต่อกันผ่านทาง dense skip ในงานวิจัยมีการแบ่งส่วนเฉพาะเนื้อตับ โดยใช้ชุดข้อมูล Liver Tumor Segmentation Benchmark (LiTS) ในการฝึกฝนชุดจำนวน 131 คนไข้ ข้อมูล LiTs เป็นชุดข้อมูลสาธารณะของภาพ CT สแกนช่องท้องที่ปรับปรุงคอนทราสต์ที่มีการแบ่งส่วนเนื้อตับและเนื้องอกตับจากโรงพยาบาลและการวิจัย 7 แห่ง จำนวน 131 คนไข้ [12] และใช้ชุดข้อมูล 3DIRCADb-01 ในการทดสอบ 20 คนไข้ โดยชุดข้อมูล 3DIRCADb-01 เป็นชุดข้อมูลการแบ่งส่วนเนื้อตับและเนื้องอกตับที่เสนอต่อสาธารณะโดยสถาบันวิจัย Institute for Research into Cancer of the Digestive System (IRCAD) ชุดข้อมูลนี้ประกอบด้วยการทำ CT สแกนของช่องท้องผู้หญิง 10 คน และผู้ชาย 10 คน ข้อมูลภาพ CT สแกนแบบคอนทราสต์ต่ำทั้งหมด 2,025 ภาพ [13] ผลการทดสอบการแบ่งส่วนเนื้อตับค่า Dice Similarity Coefficient (DSC) ในชุดทดสอบเป็น 83%

2.2.3 H-Dense U-Net

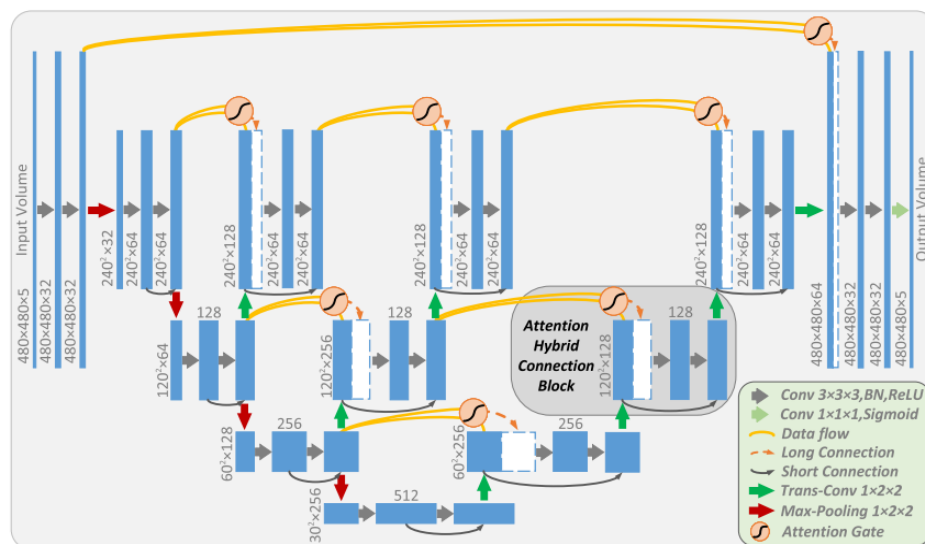
U-Net ที่เชื่อมต่อหนาแน่นแบบไฮบริดสำหรับการแบ่งส่วนของตับและเนื้องอกตับจากภาพ CT สแกน ในปีคริสต์ศักราช 2018 การใช้สถาปัตยกรรม U-net ที่มีการผสมกับการใช้สถาปัตยกรรม DenseNet ซึ่งเป็นการนำ block ของ layer ไปเชื่อมกับ block อื่นๆ ที่มีอยู่ ทำให้ข้อมูลแต่ละ layer ได้รับหลากหลายมากขึ้น ในงานวิจัยนี้ใช้ชุดข้อมูล LiTS ในการฝึกฝนและชุดข้อมูล 3DIRCADb-01 ในการทดสอบ ในงานวิจัยนี้ผลการทดสอบการแบ่งส่วนเนื้อตับและเนื้องอกตับค่า DSC ในชุดทดสอบเป็น 98.2% และ 93.7% ตามลำดับ [14]

2.2.4 RA-UNet

RA-UNet เป็นโครงข่ายประสาทแบบ attention-aware แบบลึกที่มีการผสมผสานใช้ในการตัดแบ่งส่วนเนื้อตับและเนื้องอกตับในภาพ CT สแกน ในปีคริสต์ศักราช 2018 มีการนำ residual attention ในการทำโมเดลการตัดแบ่งในภาพ 3 มิติที่มีโมเดลหลักคือ U-Net ใช้ชุดข้อมูล LiTs ในการฝึกฝน และชุดข้อมูล 3DIRCADb-01 ในการทดสอบค่า DSC ของเนื้อตับและเนื้องอกตับ ในชุดทดสอบเป็น 97.7% และ 83% ตามลำดับ [15]

2.2.5 AHCNet:

งานวิจัยนี้นำเสนอการประยุกต์ใช้กลไก Attention และการเชื่อมต่อแบบผสมผสานสำหรับการแบ่งส่วนเนื้องอกตับในภาพ CT สแกน ซึ่งมีพื้นฐานจาก 3D Fully Convolutional Network (FCN) ที่มีหลาย Attention Hybrid Connection Blocks (AHCBlocks) อัลกอริทึมที่มีการรวม soft attention และ hard attention เทคนิคเข้าด้วยกันกับ เทคนิค short skip และ long skip connections โมเดลฝึกฝนโดยใช้ชุดข้อมูล LiTs จำนวน 110 คนไข้ และใช้ชุดข้อมูล 3DIRCADb-01 ในการทดสอบ 20 คนไข้ และตัดขนาดภาพข้อมูลนำเข้าจาก 512×512 เป็น 480×480 เพื่อลดปริมาณการคำนวณโมเดล ใช้ชุดข้อมูล LiTs ในการฝึกฝน และชุดข้อมูล 3DIRCADb-01 ในการทดสอบการแบ่งส่วนเนื้อตับและเนื้องอกตับค่า DSC ในชุดทดสอบเป็น 95.9% และ 73.4% ตามลำดับ [16]




รูปที่ 8 อัลกอริทึม The Attention Hybrid Connection Net ที่นำเสนอในการวิจัย

2.2.6 Automatic Segmentation of Liver Tumor on CNN

ในปี 2019 มีการนำเสนอโมเดลที่ใช้ linknet34 ในการแบ่งส่วนเนื้องอกและเนื้อตับ โดยใช้ pre-train imagenet และ restnet34 มีการใช้ augmentation ในการปรับปรุงภาพก่อนนำไปฝึก ใช้ 3x3 filter และ stride 2 มีการใช้ SoftMax และข้อมูลนำเข้าจาก 3 channel เปลี่ยนเป็น 1 channel [17]

2.2.7 MA-Net

การศึกษาในงานวิจัยนี้ได้นำเสนอโมเดล U-Net ที่มีการเพิ่ม Position-wise Attention Block (PAB) และ Multi-scale Fusion Attention Block (MFAB) PAB เพื่อรวม High and Low-level ฝังคุณลักษณะ (Feature map) ในงานวิจัยนี้ได้มีการเปรียบเทียบโมเดล U-Net ที่มีการเพิ่ม PAB ซึ่ง PAB จะพิจารณาการพึ่งพาเชิงพื้นที่ระหว่างพิกเซล และเพิ่ม MFAB เพื่อแยกการพึ่งพาระหว่างกัน ระหว่างช่องสัญญาณคุณลักษณะต่างๆ ซึ่งผลการเปรียบเทียบโมเดล U-Net ที่มี PAB และ MFAB ให้ผลการทดลองที่ดีกว่า U-Net, UNet+, PAB และ U-Net + MFAB ชุดข้อมูลฝึกฝน LiTS จำนวน 131 คนไข้และใช้ชุดข้อมูล LiTS สำหรับทดสอบ 70 คนไข้ ขนาดภาพข้อมูลในโมเดล 512 × 512 เป็น 256 × 256 เพื่อลดปริมาณการคำนวณโมเดล [6]




รูปที่ 9 การแสดงแผนผังของสถาปัตยกรรมโมเดล MA-Net ที่นำเสนอในงานวิจัย

2.2.8 Automated segmentation from ^{99m}Tc -MAA SPECT/CT images

การศึกษาในงานวิจัยนี้ได้ทำการแบ่งส่วนเนื้อตับด้วยภาพ CT สแกน และแบ่งส่วนเนื้องอกตับด้วยภาพ SPECT สแกน ชุดข้อมูลฝึกฝนจำนวน 36 คนไข้ และชุดข้อมูลทดสอบ 20 คนไข้ ชุดข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลคนไข้ที่ได้รับการประเมิน 90Y SIRT ที่โรงพยาบาลศิริราช ระหว่างปี 2559 และ 2562 ชุดข้อมูลแต่ละชุดประกอบด้วยรูปภาพ

^{99m}Tc - MAA SPECT และภาพ CT สแกน งานวิจัยนี้นำเสนออัลกอริทึม 3D CNN เพื่อแบ่งส่วนปอด, ตับ และเนื้ออกตับ จากภาพ ^{99m}Tc -MAA เปรียบเทียบเครือข่ายที่ใช้ V-Net ที่ได้รับการฝึกอบรม จากตัวอย่างการฝึกอบรมเดียวกันในงานวิจัยนี้นำเสนอโมเดลที่ไม่ใช้ pooling layers หรือ strided convolution และมี dense block ชุดข้อมูลนำเข้าเป็นแบบสามมิติ kernel ที่ใช้ $3 \times 3 \times 3$ stride เป็น 1 และไม่มี padding ในส่วน downsampling และในเส้นทางการถอดรหัส ใช้เฉพาะชั้น deconvolution แทนการใช้ bilinear upsampling ใน DenseVnet [18]




รูปที่ 10 การแสดงแผนผังของสถาปัตยกรรมโมเดล ที่นำเสนอในงานวิจัย

2.2.9 3D SPECT/CT Images for SIRT of Liver Cancer

งานวิจัยนี้เสนอการประเมินวิธีการอัตโนมัติสำหรับวัดปริมาณเศษส่วนของตับและปอด เพื่อหลีกเลี่ยงปอดอักเสบจากรังสีในการรักษามะเร็งตับ ด้วยชุดข้อมูล 2 มิติ ^{99m}Tc -MAA และ 3D SPECT/CT จำนวน 60 คนไข้ ชุดข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลคนไข้ที่ได้รับการประเมิน 90Y SIRT ที่โรงพยาบาล 108 กลางทหาร เมืองฮานอย ประเทศเวียดนาม การศึกษาในงานวิจัยนี้ได้ทำการแบ่งส่วนเนื้อตับและปอด โดยใช้ภาพ 3 มิติของภาพ SPECT/CT สแกน และการแบ่งส่วนตับในภาพ CT สแกน ด้วย nnU-Net และการแบ่งส่วนปอดโดยใช้ 2D ResUNet [19] ในการทดสอบค่า DSC ของเนื้อตับในชุดทดสอบเป็น 93%

2.2.10 Fusion


การศึกษาในงานวิจัยก่อนหน้านี้ ได้มีการรวบรวมวิธีการหลอมรวมภาพฟิวชัน ซึ่งมีหลายรูปแบบที่ถูกนำมาใช้ในภาพทางการแพทย์ที่หลากหลาย เช่น ภาพ MRI, CT, SPECT, X-ray, PET และ Ultrasound การหลอมรวมรูปภาพสามารถให้ข้อมูลที่หลากหลายเกี่ยวกับเป้าหมาย เนื้องอก, อวัยวะหรือเนื้อเยื่อ ในงานวิจัยนี้แบ่งวิธีการหลอมรวมภาพสำหรับการเรียนรู้เชิงลึกเป็น 3 ประเภทคือ กลยุทธ์ฟิวชันระดับอินพุต (Input-level), กลยุทธ์ฟิวชันระดับระดับเลเยอร์ (Layer-level) และฟิวชันระดับการตัดสินใจ (Decision-level) [20]



รูปที่ 11 การจัดหมวดหมู่ของวิธีการในการหลอมรวมรูปภาพทางการแพทย์

2.2.10.1 กลยุทธ์ฟิวชันระดับอินพุต

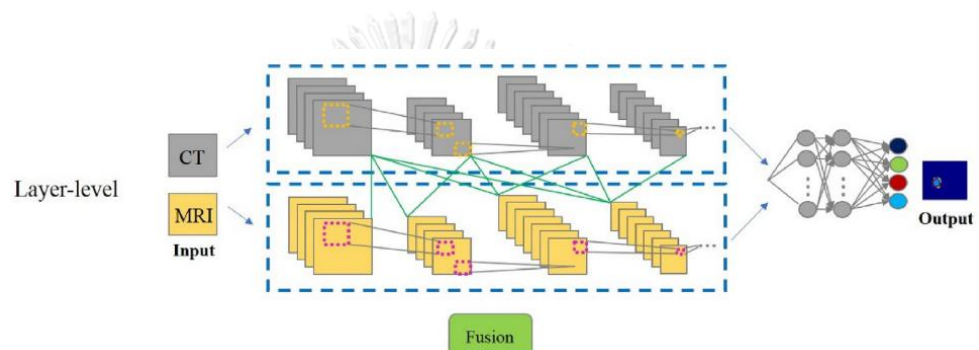
กลยุทธ์ฟิวชันระดับอินพุตเป็นการรวมข้อมูลที่แตกต่างกันของภาพเพื่อให้ข้อมูลที่รวมกันมีประสิทธิภาพสูงและความสมบูรณ์มากยิ่งขึ้นก่อนนำเข้าโมเดลฝึกฝนหรือทดสอบ กลยุทธ์ฟิวชันระดับอินพุต เช่น การบวกหรือเชื่อมต่อข้อมูลจากแหล่งหรือรูปแบบที่ต่างกัน การต่อเติมเป็นการรวมกันของภาพที่มีขนาดหรือลักษณะที่แตกต่างกันเพื่อให้เหมาะสมกับการรวมข้อมูล, การสกัดคุณลักษณะเป็นการสกัดคุณลักษณะที่สำคัญจากแต่ละรูปก่อนที่จะรวมข้อมูลเข้าด้วยกัน, การผสมแบบควบคุมใช้เพื่อปรับน้ำหนักหรือความสำคัญของข้อมูลในขณะที่รวมกัน และการใช้โมเดลหรืออัลกอริทึมในการรวมกันของชุดข้อมูลที่แตกต่างกัน [20]



รูปที่ 12 กลยุทธ์ฟิวชันระดับอินพุต

2.2.10.2 กลยุทธ์ฟิวชันระดับระดับเลเยอร์


กลยุทธ์ฟิวชันระดับเลเยอร์เป็นเครื่องมือที่มีประสิทธิภาพในการรวมข้อมูล หรือ ฟีเจอร์ที่ได้จากแต่ละเลเยอร์ของโครงข่ายเข้าด้วยกันเพื่อให้ได้ข้อมูลหรือฟีเจอร์ที่มี ประสิทธิภาพมากขึ้น ในการฟิวชันระดับเลเยอร์ข้อมูลหรือฟีเจอร์ที่ได้รับจากแต่ละเลเยอร์ ของแบบจำลองหรือโครงข่ายประสานลำดับจะถูกรวมกันในขั้นตอนหนึ่งของกระบวนการ ทำงาน เช่น การรวมข้อมูลด้วยเทคนิคการเชื่อมต่อ (concatenation), การเรียนรู้เชิงลึก ของเลเยอร์แต่ละเลเยอร์ และการประมวลผลโครงข่ายประสานลำดับเลเยอร์เดียวกันพร้อม กันได้เพื่อเพิ่มประสิทธิภาพในการทำงาน [20]



รูปที่ 13 กลยุทธ์ฟิวชันระดับระดับเลเยอร์

2.2.10.3 ฟิวชันระดับการตัดสินใจ

กระบวนการรวมผลลัพธ์หรือการตัดสินใจจากหลายๆ แบบจำลองหรือแหล่งข้อมูล ต่างๆ เพื่อให้ได้ผลลัพธ์หรือการตัดสินใจที่มีประสิทธิภาพมากที่สุด ในการฟิวชันระดับการ ตัดสินใจ ผลลัพธ์หรือการตัดสินใจจากแต่ละแบบจำลองหรือแหล่งข้อมูลจะถูกรวมกัน โดยใช้ เทคนิค เช่น ผลลัพธ์จากแต่ละแบบจำลองหรือแหล่งข้อมูลจะถูกรวมกันด้วยการบวกผลรวม หรือผลลัพธ์รวมที่ผ่านการคูณ [20]



รูปที่ 14 ฟิวชันระดับการตัดสินใจ

ตารางที่ 2 เปรียบเทียบงานวิจัยการแบ่งส่วนเนื้อตับและเนื้อ

ปี	งานวิจัย	โมเดล	มิติ	ข้อมูลฝึก	ข้อมูลทดสอบ	Liver DSC	Liver IoU	Tumor DSC	Tumor IoU
2018	2.2.2 [4]	UNet++	2	LiTS2017 131 คนไข้	3DIRCADb-01 20 คนไข้	0.83	-	-	-
2018	2.2.3 [5]	H-Dense U-Net	2	LiTS2017 131 คนไข้	3DIRCADb-01 20 คนไข้	0.98	-	0.93	-
2018	2.2.4 [13]	RA-UNet	3	LiTS2017 131 คนไข้	3DIRCADb-01 20 คนไข้	0.97	-	0.83	-
2019	2.2.5 [14]	AHCNet (FCN)	3	LiTS2017 130 คนไข้	3DIRCADb-01 20 คนไข้	0.95	-	0.73	-
2019	2.2.6 [15]	U-Net linknet34	2.5	LiTS2017 131 คนไข้	3DIRCADb-01 20 คนไข้	0.96	-	0.79	-
2020	2.2.7 [6]	MA-Net	2	LiTS2017 131 คนไข้	LiTS2017 70 คนไข้	0.96	0.92	0.75	0.79
2021	2.2.8 [16]	CNN	3	โรงพยาบาล ศิริราช 36 คนไข้	โรงพยาบาล ศิริราช 20 คนไข้	0.91	-	0.85	-
2022	2.2.9 [18]	nnU-Net	2	โรงพยาบาล 108 กลางทหาร 60 คนไข้	โรงพยาบาล 108 กลางทหาร 20 คนไข้	0.93	-	-	-


บทที่ 3 วิธีการดำเนินงานวิจัย

ภาพที่ให้ข้อมูลในเชิงกายวิภาค (anatomical imaging) เช่น ซีทีสแกน และเอ็มอาร์ไอสแกน ในการดูแลรักษาผู้ป่วยโรคมะเร็งทั้งในการประเมินระยะโรคและประเมินการตอบสนองต่อการรักษา แต่การเปลี่ยนแปลงลักษณะทางกายวิภาคในโรคมะเร็งนั้นซ้ากว่าความเปลี่ยนแปลงทางเมแทบอลิซึม และการทำงานในระดับเซลล์ จึงได้มีการพัฒนาความสามารถในการตรวจผสมผสานการใช้ คอมพิวเตอร์ เครื่องตรวจวัด และสารกัมมันตรังสีเข้าด้วยกัน เพื่อให้ได้ข้อมูลทางกายภาพและข้อมูล ด้านเมแทบอลิซึมและการทำงานในระดับเซลล์ในการตรวจเพียงครั้งเดียว เทคนิคเหล่านี้ได้แก่ สเปค-ซีที (SPECT/CT), เพท-ซีที (PET/CT) และเพท-เอ็มอาร์ (PET/MR) โดยใช้มาตรฐานภาพแบบ Digital Imaging and Communications in Medicine (DICOM) เป็นมาตรฐานที่กำหนดโดย National Electrical Manufacturers Association (NEMA) โดยมีจุดประสงค์เพื่อการเผยแพร่ภาพ ทางการแพทย์ เช่น เครื่องการตรวจเอกซเรย์คอมพิวเตอร์ (CT) สแกน การตรวจคลื่นแม่เหล็กไฟฟ้า หรือการตรวจอัลตราซาวด์ให้เป็นมาตรฐานเดียวกันเพื่อจะสามารถอ่านข้อมูลของคนไข้ระหว่าง เครื่องมือทางการแพทย์หรือซอฟต์แวร์ทางการแพทย์ที่มาจากเครื่องมือต่างชนิดหรือต่างบริษัทได้ [3]

3.1 ชุดข้อมูลสำหรับการฝึกและทดสอบเนื้องอก

3.1.1 ชุดข้อมูลสำหรับการฝึก 3DIRCADb-01


ชุดข้อมูลสำหรับการฝึก 3DIRCADb-01 ที่เสนอต่อสาธารณะโดยสถาบันวิจัย Institute for Research into Cancer of the Digestive System (IRCAD) [13] ชุดข้อมูลนี้ประกอบด้วยการทำ CT สแกน ของช่องท้องผู้หญิง 10 คน และผู้ชาย 10 คน ข้อมูลภาพ CT สแกน ทั้งหมด 2,025 ภาพ โดยมีจำนวนข้อมูลภาพ CT สแกน ช่องท้องของคนไข้มีจำนวนแตกต่างกันตั้งแต่จำนวนภาพ CT สแกน 74 ถึง 260 ภาพ และจำนวนรูปภาพของเนื้องอกที่แตกต่างกันตั้งแต่ 41 ภาพ ถึง 239 ภาพ โดยมีภาพเนื้องอกของคนไข้เฉลี่ย 103 ภาพ



รูปที่ 15 ตัวอย่างรูป CT สแกน ของชุดข้อมูล 3DIRCADb-01

3.1.2 ในการแบ่งส่วนเนื้อตับสำหรับการทดสอบ

ใช้ชุดข้อมูลย้อนหลังจากผู้ป่วยที่ทำการฉายแสงด้วยเครื่องการตรวจเอกซเรย์คอมพิวเตอร์ (CT) และการได้รับสารเภสัชรังสี ^{99m}Tc -MAA ที่โรงพยาบาลจุฬาลงกรณ์ ในปีพุทธศักราช 2559 ถึงปี พุทธศักราช 2564 จำนวน 43 คนไข้ ผู้หญิง 14 คนและผู้ชาย 28 คนช่วงอายุ 36 - 85 ปี ข้อมูลภาพ CT สแกน ทั้งหมด 7,085 ภาพ ขนาดภาพ CT สแกนช่องท้องของผู้ป่วยแต่ละรายจะแตกต่างกันมี พื้นที่ภาพขนาดใหญ่และขนาดเล็กตามการปรับมาตราส่วนภาพ CT สแกนของนักรังสีวิทยา ดังรูปที่ 16 ภาพ CT สแกนของคนไข้ 3 รายที่มีขนาดของช่องท้องแตกต่างกัน โดยมีจำนวนข้อมูลภาพ CT สแกนช่องท้องของคนไข้มีจำนวนแตกต่างกันตั้งแต่จำนวนภาพ CT สแกน 40 ถึง 261 ภาพ และ จำนวนรูปภาพของเนื้อตับที่แตกต่างกันตั้งแต่ 7 ภาพ ถึง 134 ภาพ โดยมีภาพเนื้อตับเฉลี่ย 62 ภาพ ต่อคนไข้



รูปที่ 16 ตัวอย่างรูป CT สแกนหลังการปรับ HU ชุดข้อมูลโรงพยาบาลจุฬาลงกรณ์

ตารางที่ 3 ชุดข้อมูลการแบ่งส่วนเนื้อตับ

ภาพ	ชุดข้อมูล	แหล่งข้อมูล	จำนวนภาพ	จำนวนคนไข้
CT สแกน	ชุดข้อมูลฝึก	3DIRCADb-01	2,025	20
CT สแกน	ชุดข้อมูลฝึก	โรงพยาบาลจุฬาลงกรณ์	5,840	29
CT สแกน	ชุดข้อมูลทดสอบ	โรงพยาบาลจุฬาลงกรณ์	1,245	14

3.2 ชุดข้อมูลสำหรับการฝึกและทดสอบเนื้องอกในตับ

ชุดข้อมูลคนไข้ที่ทำการฉายแสงด้วยเครื่องการตรวจเอกซเรย์คอมพิวเตอร์ SPECT/CT และจากการให้สารกัมมันตรังสี ^{99m}Tc -MAA ที่โรงพยาบาลจุฬาลงกรณ์ ในปีพุทธศักราช 2559 ถึงปี พุทธศักราช 2564 จำนวน 43 คนไข้ ผู้หญิง 14 คนและผู้ชาย 28 คนช่วงอายุ 36 - 85 ปี ข้อมูลภาพ SPECT/CT สแกนทั้งหมด 3,836 ภาพ จำนวนข้อมูลภาพ SPECT/CT สแกน ของคนไข้แต่ละคนไข้ มี

จำนวนรูปภาพที่แตกต่างกันตั้งแต่จำนวน 21 ภาพ ถึง 160 ภาพ และจำนวนรูปภาพของเนื้องอกตับ ตั้งแต่ 8 ภาพ ถึง 56 ภาพ โดยมีภาพเนื้องอกตับเฉลี่ย 25 ภาพ ต่อคนไข้

ตารางที่ 4 ชุดข้อมูลการแบ่งส่วนเนื้องอกตับ

ภาพ	ชุดข้อมูล	แหล่งข้อมูล	จำนวนภาพ	จำนวนคนไข้
SPECT/CT	ชุดข้อมูลฝึก	โรงพยาบาลจุฬาลงกรณ์	3,131	34
SPECT/CT	ชุดข้อมูลทดสอบ	โรงพยาบาลจุฬาลงกรณ์	705	9

3.3 ชุดข้อมูลสำหรับการฝึกและทดสอบการพิวซ์อินพุตก่อนเข้าโมเดล

การพิวซ์ที่กระบวนการอินพุตใช้ชุดข้อมูลคนไข้ที่ทำการฉายแสงด้วยเครื่องการตรวจเอกซเรย์คอมพิวเตอร์ CT สแกนและ SPECT/CT สแกนจากการให้สารกัมมันตรังสี $^{99m}\text{Tc-MAA}$ ที่โรงพยาบาลจุฬาลงกรณ์ จำนวนคนไข้ที่ใช้ฝึก 34 คนไข้ และจำนวนคนไข้ที่ใช้ทดสอบ 9 คนไข้

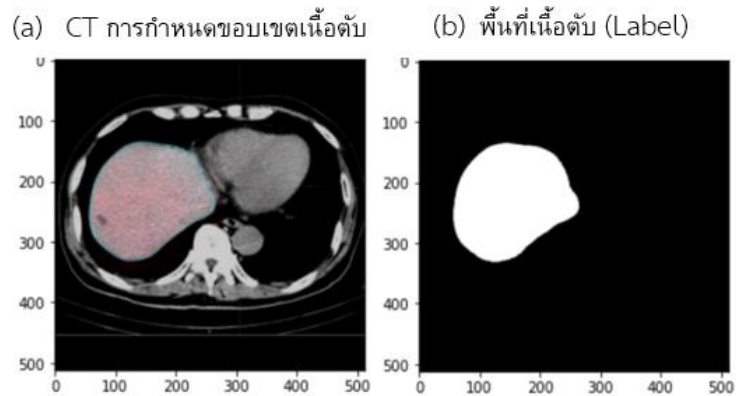
ตารางที่ 5 ชุดข้อมูลการแบ่งส่วนเนื้องอกตับและเนื้องอกตับจากภาพพิวซ์

ภาพ	ชุดข้อมูล	แหล่งข้อมูล	จำนวนภาพ	จำนวนคนไข้
พิวซ์ CT และ SPECT/CT	ชุดข้อมูลฝึก	โรงพยาบาลจุฬาลงกรณ์	5,958	34
พิวซ์ CT และ SPECT/CT	ชุดข้อมูลทดสอบ	โรงพยาบาลจุฬาลงกรณ์	1,087	9

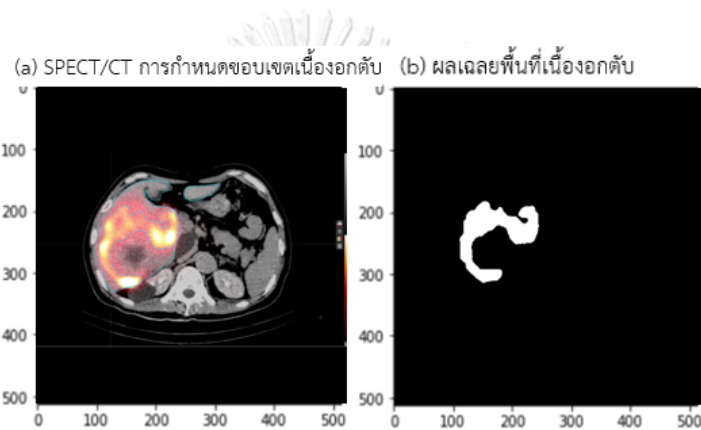
3.3 การเตรียมข้อมูล

3.3.1 การทำผลเฉลยข้อมูล

ชุดข้อมูลคนไข้โรงพยาบาลจุฬาลงกรณ์ ภาพการแบ่งส่วนเนื้องอกตับและเนื้องอกตับถูกแบ่งโดยนักรังสีการแพทย์ และแพทย์เวชศาสตร์นิวเคลียร์ โดยโปรแกรม Medical Image Merge (MIM) software version 7.1. ในการอ่านข้อมูลภาพทางการแพทย์โดยกำหนดขอบเขตของเนื้องอก รูปที่ 17 (a) และเนื้องอกตับรูปที่ 18 (a) จากนั้นจึงนำไปกำหนดพื้นที่เฉลย (Label) ดังรูปที่ 17 (b) และ 18 (b) เพื่อใช้ในการทดสอบแบบจำลอง




รูปที่ 17 การทำผลเฉลยเนื้อตับ จากโปรแกรม MIM




รูปที่ 18 การทำผลเฉลยเนื้ออกตับ จากโปรแกรม MIM

3.3.2 การปรับระดับสีของข้อมูลภาพ CT สแกน


ในภาพ CT สแกนจะได้ออกมาเป็นรูปภาพระดับสีเทา ซึ่งมีเฉดสีเทาที่สามารถแยกได้หลายระดับ โดยระบุความหนาแน่นกัมมันตภาพรังสีของวัสดุหน่วยวัดเป็น Hounsfield unit (HU) อยู่ในช่วงตั้งแต่ -1000 HU คือค่าสีเทาของอากาศ ถึง +1000 HU คือค่าสีเทาของกระดูก โดยมีค่าสีเทาของน้ำอยู่ตรงกลางที่ 0 [21] ค่าหน่วย HU สำหรับตับอยู่ในช่วงตั้งแต่ 40 ถึง 60 HU [21] ซึ่งงานวิจัยนี้ทำการปรับค่า HU ข้อมูลทั้งหมดในช่วง HU สำหรับตับในช่วงตั้งแต่ 30 ถึง 150 HU



รูปที่ 19 ค่าหน่วย HU




รูปที่ 20 รูป CT สแกน ข้อมูล 3DIRCADb-01 ก่อนปรับและหลังปรับค่าหน่วย HU




รูปที่ 21 รูป CT สแกน ข้อมูลโรงพยาบาลจุฬาลงกรณ์ ก่อนปรับและหลังปรับค่าหน่วย HU

3.3.3 การตัดเฉพาะส่วนช่องท้อง


ชุดข้อมูลผู้ป่วยที่ทำการฉายแสงด้วยเครื่องการตรวจเอกซเรย์คอมพิวเตอร์ CT สแกน และข้อมูลภาพ SPECT/CT สแกนที่ได้รับสารเภสัชรังสี ^{99m}Tc -MAA ข้อมูลภาพ CT สแกนช่องท้องของ คนไข้มีจำนวนและขนาดของภาพช่องท้องแตกต่างกันในแต่ละคนไข้ จึงมีการทำการตัดส่วนเฉพาะ ช่องท้องของแต่ละคนไข้ก่อนนำเข้าชุดทดสอบโมเดล ในงานวิจัยนี้ใช้เทคนิคการตัดเฉพาะส่วนช่องท้องอัตโนมัติใช้เทคนิคหาขอบ (boundary detection) ในการหาขอบของภาพด้วยเทคนิคการเปลี่ยนแปลงความเข้มแสง (intensity change) ระหว่างพิกเซลของภาพที่ต่างกันระหว่างภาพการ สแกนช่องท้องกับพื้นหลัง ทำให้สามารถแยกภาพขอบของช่องกับพื้นหลังออกจากกันได้ ดังรูปที่ 22 และ 24 รูปภาพ CT สแกนและ SPECT/CT สแกนก่อนการตัดเฉพาะส่วนของช่องท้อง รูปที่ 23 และ 25 ขนาดของภาพ CT สแกนและ SPECT/CT สแกนหลังการตัดเฉพาะส่วนของช่องท้อง




รูปที่ 22 ขนาดของชุดข้อมูลภาพ CT ก่อนการตัดเฉพาะส่วนของช่องท้อง



รูปที่ 23 ขนาดของชุดข้อมูลภาพ CT หลังการตัดเฉพาะส่วนของช่องท้อง



รูปที่ 24 ขนาดของชุดข้อมูลภาพ SPECT/CT ก่อนการตัดเฉพาะส่วนของช่องท้อง



รูปที่ 25 ขนาดของชุดข้อมูลภาพ SPECT/CT หลังการตัดเฉพาะส่วนของช่องท้อง

3.3.4 การแบ่งข้อมูลชุดการฝึกฝนและทดสอบ

การแบ่งข้อมูลรูปภาพในโมเดลแยกการแบ่งส่วนและโมเดลรวมการแบ่งส่วน ในแต่ละโมเดล จะแบ่งข้อมูลรูปภาพออกเป็นสามชุดคือ ชุดข้อมูลฝึกฝน (Training dataset), ชุดข้อมูลตรวจสอบ (Validation dataset) และชุดข้อมูลทดสอบ (Test dataset) โดยแบ่งชุดข้อมูลสำหรับการฝึกฝน

โมเดล 70% ของจำนวนคนไข้ทั้งหมดชุดข้อมูลสำหรับการตรวจสอบของโมเดล 10% ของจำนวนคนไข้ทั้งหมด และชุดข้อมูลสำหรับการทดสอบ 20% ของจำนวนคนไข้ทั้งหมด เพื่อเป็นการตรวจสอบประสิทธิภาพโมเดล โดยมีการสลับการแบ่งชุดข้อมูลคนไข้ที่ใช้ในการฝึกฝนและการทดสอบเป็น 3 ชุดที่ข้อมูลคนไข้ที่ใช้ฝึกฝนและทดสอบแตกต่างกัน ดังตารางที่ 6

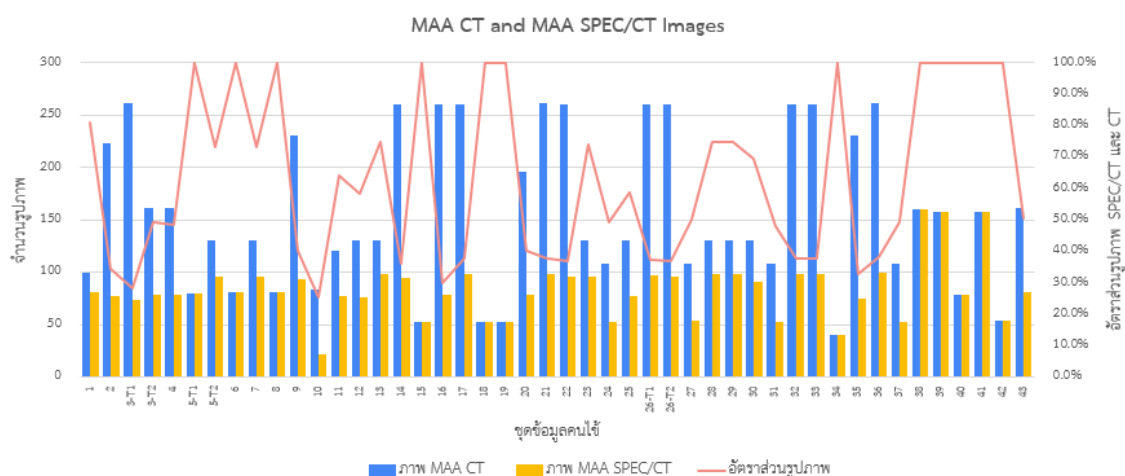
ตารางที่ 6 ชุดข้อมูลคนไข้

ชุดข้อมูล	ชุดข้อมูลฝึกฝนและตรวจสอบ	ชุดข้อมูลทดสอบ
ชุดข้อมูลที่ 1	ข้อมูลคนไข้คนที่ 1-34	ข้อมูลคนไข้คนที่ 35-43
ชุดข้อมูลที่ 2	ข้อมูลคนไข้คนที่ 35-41 และ 1-25	ข้อมูลคนไข้คนที่ 26-34
ชุดข้อมูลที่ 3	ข้อมูลคนไข้คนที่ 26-41 และ 1-16	ข้อมูลคนไข้คนที่ 17-25

3.4 การพิจารณา


3.4.1 การวัดดัชนีความคล้ายคลึงกันของโครงสร้าง

ขั้นตอนแรกในการพิจารณาชุดข้อมูลในแต่ละคนไข้ระหว่างภาพ CT สแกน และ SPECT/CT สแกน คือการจับคู่รูปภาพ CT สแกนกับรูปภาพ SPECT/CT สแกนที่มีความคล้ายคลึงกันมากที่สุด โดยจำนวนชุดข้อมูลรูปภาพ CT สแกน และ SPECT/CT สแกนของคนไข้มีความแตกต่างกัน ชุดข้อมูลคนไข้โรงพยาบาลจุฬาลงกรณ์ ที่ใช้ในการทดสอบค่าเฉลี่ยรูปภาพ CT สแกนจำนวน 156 ภาพต่อคนไข้ และค่าเฉลี่ยรูปภาพ SPECT/CT สแกน จำนวน 83 ภาพต่อคนไข้ ดังรูปที่ 26 โดยแกน X เป็นคนไข้แกน Y เป็นจำนวนรูปภาพโดยแท่งกราฟสีน้ำเงินเป็นจำนวนภาพ CT สแกน และแท่งกราฟสีเหลืองเป็นจำนวนภาพ SPECT/CT สแกนในแต่ละคนไข้



รูปที่ 26 จำนวนรูปภาพ CT และ SPECT/CT ในแต่ละคนไข้

ชุดข้อมูลคนไข้ โรงพยาบาลจุฬาลงกรณ์ ที่ใช้ในการทดสอบขนาดของรูปภาพ CT สแกนและ SPECT/CT สแกน มีทั้งคนไข้ที่มีขนาดรูปภาพ CT สแกน และ SPECT/CT สแกน เท่ากันและขนาดรูปภาพ CT สแกน และ SPECT/CT สแกนที่แตกต่างกัน เนื่องจากชุดข้อมูลภาพ CT สแกน ในทุกคนไข้มีจำนวนภาพ CT สแกน มากกว่า SPECT/CT สแกน จึงใช้ภาพ CT สแกนเป็นภาพตั้งต้นในการหาภาพ SPECT/CT สแกน ที่มีความคล้ายคลึงกับภาพ CT สแกนมากที่สุด ใช้การวัดดัชนีความคล้ายคลึงกันของโครงสร้างในการประเมินผลของภาพที่จะนำมาฟิวชั่น ตัวอย่างเช่นชุดข้อมูลคนไข้หมายเลข 1 มีจำนวนภาพ CT สแกนเป็น X และจำนวนภาพ SPECT/CT สแกนเป็น Y รูปภาพ CT สแกนรูปที่ 1 จะถูกนำไปคำนวณหาดัชนีความคล้ายคลึงกันของโครงสร้างของรูปภาพ SPECT/CT สแกนรูปที่ 1 ถึง Y และการจับคู่ภาพ CT สแกนรูปที่ 1 กับ SPECT/CT สแกน ที่ได้ค่าดัชนีความคล้ายคลึงกันของโครงสร้างมากที่สุดจะนำไปฟิวชั่นรูปภาพเข้าด้วยกัน จากนั้นทำขั้นตอนแบบเดียวกันของรูป CT สแกนที่ 2 จนถึง CT สแกนที่ X ซึ่งการวัดดัชนีความคล้ายคลึงกันของโครงสร้างของรูปภาพสองรูปที่เหมือนกันทั้งหมดเป็นภาพเดียวกันจะให้ค่าเป็น 1 ซึ่งการจับคู่ภาพที่ได้ค่าดัชนีความคล้ายคลึงกันของโครงสร้างมากที่สุดคือมีความเหมือนกันมาก ดังรูปที่ 27 ภาพ CT สแกนที่ 1 มีค่าความคล้ายคลึงกันของโครงสร้างกับภาพ SPECT/CT สแกนที่ 20 มากที่สุด ค่าดัชนีความคล้ายคลึงกันของโครงสร้างมีค่าเป็น 0.763 เพื่อความถูกต้องในการจับคู่ภาพ CT และ SPECT/CT จึงมีการตรวจสอบความคล้ายคลึงกันของรูปภาพ CT สแกน และ SPECT/CT สแกนทุกภาพด้วยบุคคลก่อนนำไปเข้ากระบวนการฟิวชั่น



รูปที่ 27 การจับคู่ภาพ CT และ SPECT/CT

3.4.2 การฟิวชั่น

ในงานวิจัยนี้ใช้เทคนิคการฟิวชั่นรูปภาพ 2 รูปเข้าด้วยกันให้เป็น 1 ภาพ ด้วยไลบรารี addweighted เป็นฟังก์ชันที่ช่วยในการผสมภาพแบบอัลฟา การผสมอัลฟาช่วยในการวางซ้อนภาพ การเพิ่มภาพคือการผสมภาพเพื่อให้สามารถมองเห็นภาพทั้งสองได้พร้อมกัน โดยสามารถให้น้ำหนักภาพต่างๆ กัน สามารถทำให้ภาพโปร่งแสงได้ตามน้ำหนักที่เพิ่มเข้าไป ค่าของน้ำหนักจะมีค่าตั้งแต่ 0 ถึง 1 ในงานวิจัยนี้ให้น้ำหนักของภาพ CT สแกน และ SPECT/CT สแกนเป็นค่า 1 เท่ากัน


$$Fusion = Weight_1 * CT + Weight_2 * SPECT/CT \quad \dots (2)$$

โดยที่

$Weight_1$ คือ ค่าน้ำหนักของภาพ CT สแกน

$Weight_2$ คือ ค่าน้ำหนักของภาพ SPECT/CT สแกน

ในขั้นตอนการฟิวชั่นภาพที่มีค่าความคล้ายคลึงกันมากที่สุดจะมีการปรับขนาดของภาพ CT สแกน และ SPECT/CT สแกนให้มีขนาดเท่ากันและนำไปเข้ากระบวนการฟิวชั่นรูปภาพ CT สแกน และภาพ SPECT/CT สแกนโดยให้ค่าน้ำหนักของทั้งสองภาพเป็นค่า 1 เท่ากัน ดังตัวอย่างรูปที่ 28




(a) ภาพ CT สแกน (b) ภาพ SPECT/CT สแกน (c) ภาพฟิวชั่น
รูปที่ 28 ภาพ CT ภาพ SPECT/CT และภาพการฟิวชั่น CT กับ SPECT/CT

3.5 การสร้างแบบจำลองการแบ่งส่วน

การทดลองดำเนินการในรูปแบบการแบ่งส่วนแพลตฟอร์ม PyTorch พร้อมภาษาการเขียนโปรแกรม Python 3, และใช้ไลบรารี Segment Models PyTorch และ Pydicom สำหรับโมเดลได้รับการฝึกฝนโดยใช้ NVIDIA-SMI 460.32.03 GPU Persistence-M and 11GB memory

3.5.1 การแบ่งส่วนเนื้อตับ

เพื่อเพิ่มประสิทธิภาพในชุดข้อมูลฝึกในการแบ่งส่วนเนื้อตับเพิ่มคุณภาพรูปภาพสำหรับตับด้วยการปรับระดับสีของข้อมูลภาพ CT สแกน เพื่อเพิ่มประสิทธิภาพของชุดข้อมูลฝึกให้มีประสิทธิภาพมากขึ้นด้วยการเพิ่มปริมาณข้อมูลการฝึกจากข้อมูลภาพเดิมโดยปรับมาตราส่วนพลิกแนวตั้งก่อนเข้าโมเดลในขั้นตอนดังรูปที่ 29



รูปที่ 29 กระบวนการโมเดลแยกการแบ่งส่วนเนื้อตับ


3.5.2 การแบ่งส่วนเนื้องอก

การแบ่งส่วนเนื้องอกจะใช้ภาพ SPECT/CT สแกน ในการรวมกันระหว่างภาพ SPECT สแกน และภาพ CT สแกน [22] เนื่องจากการดูดกลืนสารกัมมันตรังสี ในแต่ละคนไข้ที่แตกต่างกัน จึงมีการปรับค่าเทรสโฮลด์ ในแต่ละคนไข้ เพื่อให้ได้ภาพเนื้องอกตัดจากการดูดกลืนสารกัมมันตรังสี ดังรูปที่ 30 (a) ภาพ SPECT สแกน รูปที่ 30 (b) ภาพ CT สแกน และรูปที่ 30 (c) รูป SPECT/CT สแกน จากการรวมกันระหว่างภาพ SPECT สแกน และภาพ CT สแกน


(a) ภาพ SPECT



(b) ภาพ CT

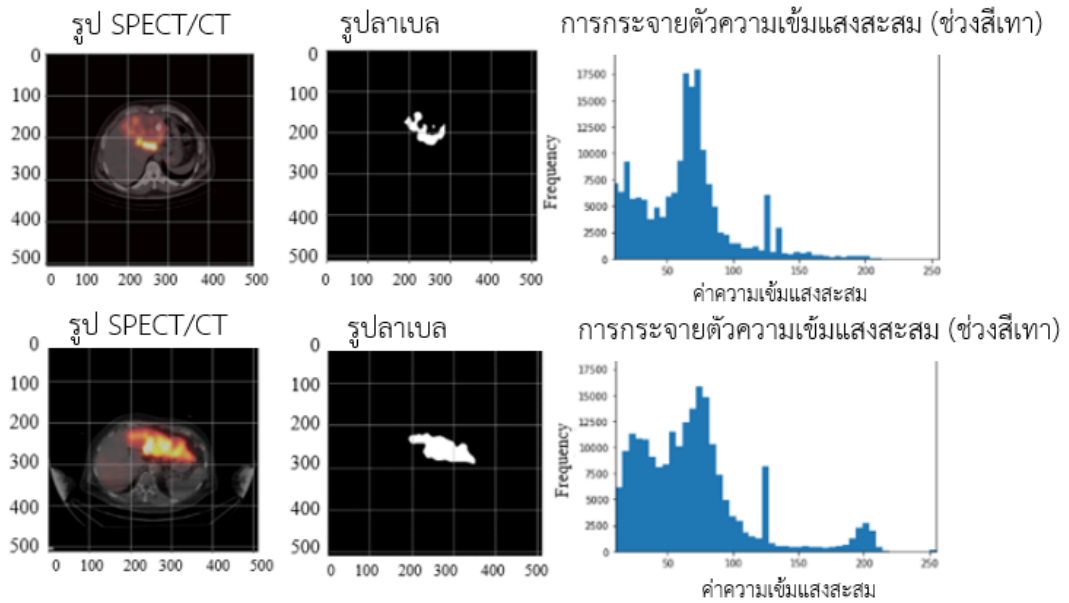


(c) ภาพ SPECT/CT




รูปที่ 30 ภาพ SPECT สแกน ภาพ CT สแกน และภาพ SPECT/CT สแกน

จากการตรวจสอบรูปภาพ SPECT/CT สแกน พบลักษณะการกระจายตัวของความเข้มแสงของรูปภาพแบ่งออกเป็นสองกลุ่ม โดยกลุ่มรูปภาพปกติพื้นที่ลาเบลของเนื้องอกจะใกล้เคียงกับบริเวณแสงสีเหลืองของภาพ SPECT/CT สแกน ดังรูปที่ 31 ซึ่งจะมีการกระจายตัวค่าความเข้มแสงสะสมของภาพ SPECT/CT สแกน ในช่วงความเข้มแสงที่ช่วงต่ำกว่า 150 และในกลุ่มรูปภาพที่ผิดปกติพื้นที่ลาเบลของเนื้องอกจะเล็กกว่าบริเวณแสงสีเหลืองของภาพ SPECT/CT สแกน ดังรูปที่ 32 ซึ่งจะมีลักษณะการกระจายตัวค่าความเข้มแสงสะสมในสองช่วงความเข้มแสงที่ต่ำกว่า 150 และ 200

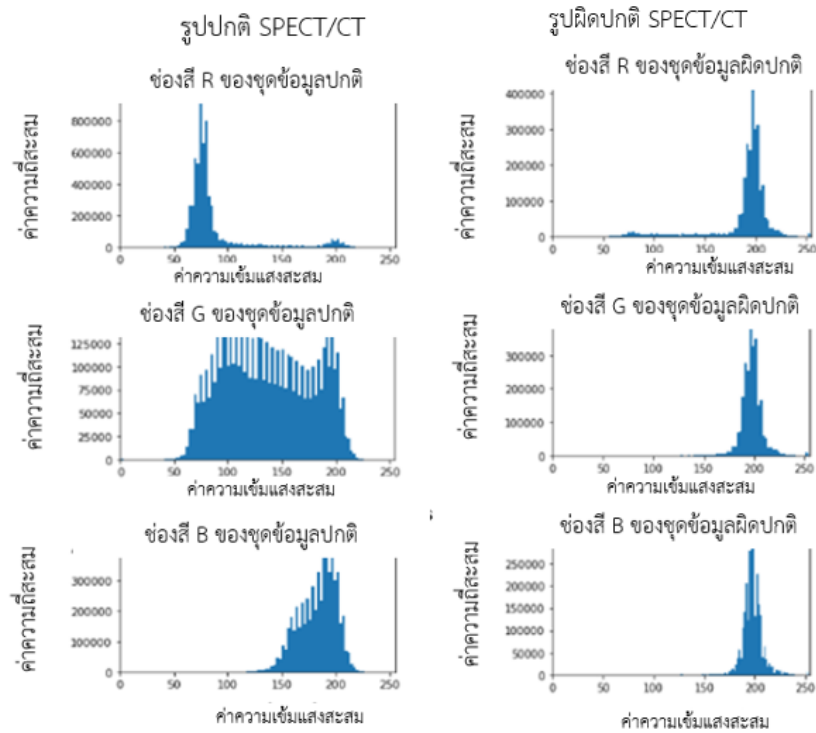


รูปที่ 31 รูป SPECT/CT สแกน ลาเบล และลักษณะการกระจายตัวความเข้มแสงภาพปกติ



รูปที่ 32 รูป SPECT/CT สแกน ลาเบล และลักษณะการกระจายตัวความเข้มแสงภาพผิดปกติ

ค่าความเข้มแสงสะสมของพื้นที่เนื้องอกดับในแต่ละช่องสี RGB จากกลุ่มข้อมูลทั้งหมดของรูปภาพปกติและรูปภาพที่ผิดปกติแสดงดังรูปที่ 33 สำหรับรูป SPECT/CT สแกนที่มีการแจกแจงแบบปกติ (ซ้าย) และการกระจายแบบผิดปกติ (ขวา) ข้อมูลภาพปกติประกอบด้วยผู้ป่วย 27 รายและภาพผิดปกติของผู้ป่วย 16 ราย




รูปที่ 33 การกระจายความเข้มในแต่ละช่องสี RGB ของข้อมูลกลุ่มปกติและผิดปกติ

เมื่อทำการแยกช่วงความเข้มสี RGB โดยใช้ค่าความเข้มเฉลี่ยต่ำสุดและสูงสุดของชุดข้อมูลปกติและผิดปกติดังตารางที่ 7 เพื่อหาความชันและจุดตัดในการคิดสมการเชิงเส้นในการปรับปรุงค่าความเข้มสีของรูปภาพที่ผิดปกติแกน X โดยมีการเปลี่ยนแปลงให้ค่าความเข้มสีให้อยู่ในช่วงเดียวกับรูปภาพปกติ แกน Y ดังรูปที่ 34

ตารางที่ 7 ค่าความเข้มสีเฉลี่ยน้อยสุดและมากที่สุดของชุดข้อมูลปกติและผิดปกติ

ชุดข้อมูล	ค่าเฉลี่ย	ค่าเฉลี่ย	ค่าเฉลี่ย	ค่าเฉลี่ย	ค่าเฉลี่ย	ค่าเฉลี่ย
	น้อยสุด	มากที่สุด	น้อยสุด	มากที่สุด	น้อยสุด	มากที่สุด
	ช่องสี R	ช่องสี R	ช่องสี G	ช่องสี G	ช่องสี B	ช่องสี B
ชุดข้อมูลปกติ	72	144	88	192	155	205
ชุดข้อมูลผิดปกติ	141	211	187	215	192	215




รูปที่ 34 การแปลงค่าความเข้มสีผิดพลาดให้อยู่ในระดับปกติ

หาสมการความชันในการแปลงค่าความเข้มสีข้อมูลผิดพลาดให้เป็นแบบข้อมูลปกติ ในแต่ละช่องสี RGB จากสมการ $y = mx + C$ ความชันของเส้นตรงเป็น m และค่าจุดตัดบนแกน y เป็น c


- การแปลงค่าความเข้มสีผิดพลาดช่องสี R ได้สมการ $y = (1.03)x - 73$ เมื่อค่าความเข้มสีช่องสี R ข้อมูลผิดพลาดอยู่ระหว่าง 141 ถึง 211
- การแปลงค่าความเข้มสีผิดพลาดช่องสี G ได้สมการ $y = (3.7)x - 606$ เมื่อค่าความเข้มสีช่องสี G ข้อมูลผิดพลาดอยู่ระหว่าง 187 ถึง 215
- การแปลงค่าความเข้มสีผิดพลาดช่องสี B ได้สมการ $y = (2.1)x - 262$ เมื่อค่าความเข้มสีช่องสี B ข้อมูลผิดพลาดอยู่ระหว่าง 192 ถึง 215

การปรับปรุงค่าความเข้มแสงของรูปภาพ SPECT/CT บริเวณตำแหน่งเนื้องอกตับในแต่ละวิธีการ Histogram Equalization, Clahe Histogram Equalization, Stretching การแปลงค่าความเข้มสี R, G, B และ R,G จากซ้ายไปขวาตามลำดับดังรูปที่ 35



รูปที่ 35 รูปภาพ SPECT/CT ที่มีการปรับปรุงค่าสี


การตรวจสอบคุณสมบัติการกระจายความเข้มของรูปภาพ SPECT/CT สแกน และนำภาพที่มีการกระจายตัวผิดปกติไปปรับการกระจายความเข้มให้อยู่ในการกระจายความเข้มแบบปกติก่อนนำเข้าโมเดล ทำให้ประสิทธิภาพของโมเดลดีขึ้นและเพิ่มประสิทธิภาพของชุดข้อมูลฝึกให้มีประสิทธิภาพมากขึ้น ด้วยการเพิ่มปริมาณข้อมูลการฝึกจากข้อมูลภาพเดิมโดยปรับมาตราส่วนพลิกแนวตั้ง ก่อนเข้าโมเดลในขั้นตอนดังรูปที่ 36



รูปที่ 36 กระบวนการโมเดลแยกการแบ่งส่วนเนื้องอกตับ

3.5.3 การแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพฟิวชั่น

การฟิวชั่นรูปภาพ CT สแกนและ SPECT/CT สแกนและฟิวชั่นรูปภาพของผลเฉลย CT และผลเฉลย SPECT/CT มีการฟิวชั่นที่กระบวนการอินพุตก่อนนำเข้าไปในโมเดลการแบ่งส่วนเนื้อตับและเนื้องอกตับของการฝึกชุดข้อมูลสำหรับการแบ่งส่วนเนื้อตับและเนื้องอกตับด้วยโมเดลเดียวกัน เพื่อเพิ่มประสิทธิภาพของชุดข้อมูลฝึกให้มีประสิทธิภาพมากขึ้นด้วยการเพิ่มปริมาณข้อมูลการฝึกจากข้อมูลภาพเดิม โดยปรับมาตราส่วนพลิกแนวตั้งและการตัดเฉพาะส่วนของช่องท้องก่อนเข้าโมเดลในขั้นตอน ดังรูปที่ 37



รูปที่ 37 กระบวนการฟิวชั่นและโมเดลรวมแบ่งส่วนเนื้อตับและเนื้องอกตับ

3.5.4 พารามิเตอร์ที่เกี่ยวข้องกับแบบจำลอง

ในงานวิจัยนี้ใช้ค่าพารามิเตอร์ที่เหมือนกันทั้งหมดในทุกโมเดลเพื่อทดสอบประสิทธิภาพของโมเดลแยกการแบ่งส่วนเนื้อตับจากภาพ CT สแกน และเนื้องอกตับจากภาพ SPECT/CT สแกน เปรียบเทียบกับโมเดลรวมการแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพฟิวชั่น CT สแกนและ SPECT/CT สแกน ฟิวชั่นที่กระบวนการอินพุต ค่าพารามิเตอร์ที่เกี่ยวข้องกับแบบจำลองดังตารางที่ 8

ตารางที่ 8 พารามิเตอร์ที่เกี่ยวข้องกับแบบจำลอง

พารามิเตอร์	กำหนด
Input image size	256 X 256
Output image size	256 X 256
Epochs	50
Drop out	0
Data augmentation	มาตราส่วนพลิกแนวตั้ง 0.5
Learning rate	0.0001
Loss	ADAM optimizer with dice loss
Batch size	16

3.6 การตรวจสอบความถูกต้องของแบบจำลอง เกณฑ์การประเมินผลการวิจัย

กำหนดให้ตัวแปร A คือข้อมูลผลเฉลย B คือผลของแบบจำลองจากโมเดล

3.6.1 Dice Similarity Coefficient (DSC)

การหาเปอร์เซ็นต์ความคล้ายกันระหว่างข้อมูลผลเฉลย และผลของแบบจำลองจากโมเดล [23]

$$DSC = \frac{2 \times |A \cap B|}{|A| + |B|} \quad \dots (3)$$

3.6.2 Intersection over Union (IoU)

การหาเปอร์เซ็นต์พิกเซลที่ทับซ้อนกันระหว่างข้อมูลผลเฉลย และผลของแบบจำลองจากโมเดล [23]

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad \dots (4)$$

บทที่ 4

การประเมินผลการวิจัย

4.1 เปรียบเทียบประสิทธิภาพการแบ่งส่วนเนื้อตับ

4.1.1 ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ Backbone

การฝึกชุดข้อมูลโดยใช้ชุดข้อมูล 3DIRCADb-01 จำนวน 20 คนไข้ และชุดข้อมูลโรงพยาบาลจุฬาลงกรณ์ จำนวน 29 คนไข้ และชุดข้อมูลทดสอบโรงพยาบาลจุฬาลงกรณ์จำนวน 14 คนไข้ โดยกำหนด Backbone แตกต่างกัน และใช้ ImageNet ที่เหมือนกันในโมเดล U-Net พบว่า EfficientNet-B3 ให้ค่าผลการประเมินแบบทดสอบสูงที่สุดในโมเดล U-Net โดยค่า DSC เป็น 0.72 และ IoU เป็น 0.66 เมื่อทดสอบกับโมเดลอื่นพบว่า Backbone EfficientNet-B3 โมเดล MA-Net ให้ค่าผลการประเมินสูงที่สุดเมื่อเทียบกับโมเดล U-Net และ UNet++ โดยค่าการประเมินผลชุดข้อมูลทดสอบ DSC เป็น 0.78 และ IoU เป็น 0.70 ดังตารางที่ 9

ตารางที่ 9 ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ Backbone

โมเดล	Backbone พารามิเตอร์	DSC	IoU
U-Net	Resnet34	0.68	0.61
U-Net	Resnet101	0.69	0.63
U-Net	EfficientNet-B3	0.72	0.66
U-Net	xception	0.69	0.62
U-Net	Mobilenet_V2	0.71	0.66
U-Net	VGG16	0.71	0.65
UNet++	Resnet34	0.70	0.63
UNet++	Resnet101	0.70	0.63
MA-Net	Resnet34	0.72	0.66
MA-Net	EfficientNet-B3	0.78	0.70

4.1.2 ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ EfficientNet และ pre-trained


การฝึกชุดข้อมูลและทดสอบใน EfficientNet และ timm-EfficientNet โดยใช้พารามิเตอร์ pre-trained เป็น ImageNet และ noisy student พบว่า timm-EfficientNet-B6 ให้ผลการประเมินที่สูงกว่า timm-EfficientNet-B3 และ pre-trained noisy student ให้ค่าการประเมินที่

สูงกว่า ImageNet โดยผลการประเมินการแบ่งส่วนเนื้อตับด้วยพารามิเตอร์ timm- EfficientNet-B6 และ pre-trained เป็น noisy-student ให้ค่าผลการประเมินชุดข้อมูลทดสอบสูงที่สุดในโมเดล MA-Net ผลการประเมินเพิ่มขึ้นเมื่อมีการตัดส่วนเฉพาะช่องท้องของชุดข้อมูลการฝึกก่อนนำเข้ามาทดสอบ โดยค่าผลการทดสอบเพิ่มขึ้นค่า DSC เป็น 0.90 และ IoU เป็น 0.84 ดังตารางที่ 10

ตารางที่ 10 ผลลัพธ์การแบ่งส่วนเนื้อตับของแต่ละ EfficientNet และ pre-trained

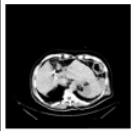



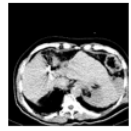


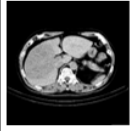



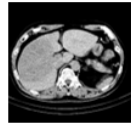


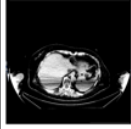



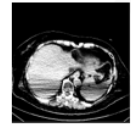


โมเดล	พารามิเตอร์	DSC	IoU
U-Net	timm-EfficientNet-B6 + noisy student	0.79	0.71
UNet++	timm-EfficientNet-B6 + noisy student	0.83	0.77
MA-Net	VGG16 + noisy student	0.84	0.78
MA-Net	timm-EfficientNet-B6 + ImageNet	0.86	0.80
MA-Net	timm-EfficientNet-B3 + noisy-student	0.86	0.80
MA-Net	timm-EfficientNet-B6 + noisy-student	0.87	0.81
MA-Net	timm-EfficientNet-B6 + noisy-student + Cropping	0.90	0.84

ในผู้ป่วยบางรายรูปภาพ CT สแกนอาจมีซีสตีในตับ ซึ่งถือเป็นถุงน้ำที่ผิดปกติซีสตีในตับ ประกอบด้วยของไหลหรือมวลเซลล์ที่เป็นของแข็งซึ่งจะไม่นำไปคำนวณปริมาตรของเนื้อตับเพื่อใช้ประเมินปริมาณสารกัมมันตรังสี 90Y ผลการทดสอบการแบ่งส่วนสามารถแยกความแตกต่างระหว่างซีสตีในตับได้ดีกว่าการทำผลเฉลยโดยมนุษย์ เนื่องจากการทำผลเฉลยที่มีขนาดเล็กในถุงน้ำที่ผิดปกติ จะใช้เวลานาน ดังรูปที่ 38



รูปที่ 38 รูปภาพ CT สแกนที่มีซีสตีในตับและผลการทดสอบ


ผลการแบ่งส่วนเนื้อตับด้วยพารามิเตอร์ timm- EfficientNet-B6 และ pre-trained เป็น noisy-student ผลการแบ่งส่วนเนื้อตับของคนที่ทดสอบ 3 ราย เปรียบเทียบภาพการแบ่งส่วนเนื้อตับระหว่างโมเดล U-Net, UNet++, MA-Net ซึ่งโมเดล MA-Net ที่มีการตัดเฉพาะช่องท้องให้ผลการทดสอบภาพการแบ่งส่วนจากโมเดลมีความใกล้เคียงกับผลเฉลยมากกว่าโมเดล U-Net และ UNet++

คนไข้	ไม่มีการตัดเฉพาะส่วนช่องท้อง				มีการตัดเฉพาะส่วนช่องท้อง		
	ภาพ CT สแกน	ผลเฉลย	U-Net	UNet++	ภาพ CT สแกน	ผลเฉลย	MA-Net
1							
2							
3							


รูปที่ 39 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้อตับ

4.1.3 ผลการแบ่งส่วนเนื้อตับที่มีประสิทธิภาพต่ำสุด

ผลการแบ่งส่วนเนื้อตับพบความแม่นยำต่ำสุดเปรียบเทียบภาพผลเฉลย (b) และภาพการแบ่งส่วนจากโมเดล (c) สำหรับการแบ่งส่วนเนื้อตับในผู้ป่วยที่มีภาพ CT สแกนมีลักษณะที่ผิดปกติ (a) เช่น ในคนไข้ที่มีสิ่งแปลกปลอมในร่างกายคนไข้ หรือ คนไข้ที่ได้รับการรักษาทางการแพทย์ที่มีการใช้เคมีบำบัด



รูปที่ 40 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้อตับในคนไข้ที่มีสิ่งแปลกปลอมในร่างกาย



รูปที่ 41 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้อตับในคนไข้ที่มีการใช้เคมีบำบัด

4.2 เปรียบเทียบประสิทธิภาพการแบ่งส่วนเนื้ออกตับ

4.2.1 ผลลัพธ์การแบ่งส่วนเนื้ออกตับของแต่ละ Model

การฝึกชุดข้อมูลจากโรงพยาบาลจุฬาลงกรณ์จำนวน 33 ราย และชุดข้อมูลทดสอบโรงพยาบาลจุฬาลงกรณ์จำนวน 10 ราย ในการแบ่งส่วนเนื้ออกตับกำหนด pre-trained เป็น noisy student และตรวจสอบหาค่า Backbone ที่ timm-EfficientNet-B6 ในโมเดลที่แตกต่างกัน U-Net, UNet++ และ MA-Net พบว่า time-EfficientNet-B6 ที่โมเดล MA-Net ให้ค่าผลการประเมินข้อมูลทดสอบสูงที่สุดโดยค่า DSC เป็น 0.62 และ IoU เป็น 0.49 ดังตารางที่ 11

ตารางที่ 11 ผลลัพธ์การแบ่งส่วนเนื้ออกตับของแต่ละ Backbone และ Model

โมเดล	พารามิเตอร์	DSC	IoU
U-Net	tim-EfficientNet-B6	0.58	0.46
UNet++	tim-EfficientNet-B6	0.58	0.47
MA-Net	EfficientNet-B3	0.55	0.45
MA-Net	tim-EfficientNet-B0	0.54	0.44
MA-Net	tim-EfficientNet-B6	0.62	0.49

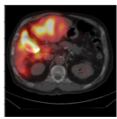






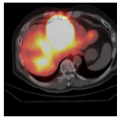






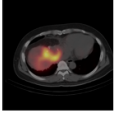



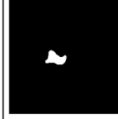


4.2.2 ผลลัพธ์การแบ่งส่วนเนื้ออกตับในแต่ละวิธีการปรับปรุงค่าสี

โมเดล MA-Net โดยกำหนดพารามิเตอร์ tim-EfficientNet-B6 และ pre-trained เป็น noisy student ที่มีการปรับปรุงค่าความเข้มของสีในรูปแบบที่ผิดปกติในช่องสี R และ G ให้ค่าผลการประเมินที่สูงที่สุดเมื่อเทียบกับการไม่ปรับปรุงค่าความเข้มของสีในช่องสี RGB โดยผลการประเมินได้ค่า DSC เป็น 0.65 และ IoU เป็น 0.55 ในการแบ่งส่วนเนื้ออกตับการตัดส่วนเฉพาะช่องท้องของชุดข้อมูลการฝึกก่อนนำเข้าทดสอบ ผลการทดสอบไม่เปลี่ยนแปลงเมื่อเทียบกับข้อมูลที่ไม่มีการตัดเฉพาะช่องท้อง ดังตารางที่ 12

ตารางที่ 12 ผลลัพธ์การแบ่งส่วนเนื้องอกตับในการปรับปรุงค่าสี

โมเดล	พารามิเตอร์	DSC	IoU
U-Net	การปรับปรุงค่าสี R, G	0.61	0.50
UNet++	การปรับปรุงค่าสี R, G	0.60	0.48
MA-Net	ไม่มีการปรับปรุงค่าสี	0.62	0.49
MA-Net	การปรับปรุงค่าสี R, G, B	0.64	0.52
MA-Net	การปรับปรุงค่าสี R, G	0.65	0.55
MA-Net	การปรับปรุงค่าสี R, G + Cropping	0.66	0.55

ผลการแบ่งส่วนเนื้องอกตับด้วยพารามิเตอร์ timm- EfficientNet-B6 และ pre-trained เป็น noisy-student ผลการแบ่งส่วนเนื้องอกตับของคนที่ทดสอบ 3 ราย โดยคนที่ 1, 2 มีการกระจายความเข้มแสงผิดปกติบริเวณตำแหน่งเนื้องอกและคนที่ 3 ที่มีการกระจายความเข้มแสงปกติบริเวณตำแหน่งเนื้องอกตับ โดยเปรียบเทียบภาพการแบ่งส่วนเนื้องอกตับระหว่างโมเดล U-Net, UNet++, MA-Net, MA-Net ที่มีปรับปรุงค่าสี และ MA-Net ที่มีปรับปรุงค่าสี R, G ผลการทดสอบภาพการแบ่งส่วนเนื้องอกตับจากโมเดล MA-Net ที่มีปรับปรุงค่าสี R, G ให้ผลที่มีความใกล้เคียงกับผลเฉลยมากกว่าโมเดล U-Net และ UNet++ จากภาพผลการทดสอบจากโมเดลในคนที่ 3 ที่มีการกระจายความเข้มแสงปกติบริเวณตำแหน่งเนื้องอกตับให้ผลการแบ่งส่วนที่ใกล้เคียงกับผลเฉลยมากกว่าในคนที่ 1 และ 2 ที่มีการกระจายความเข้มแสงผิดปกติบริเวณตำแหน่งเนื้องอกตับ

คนใช้	ภาพ SPECT/CT สแกน	ผลเฉลย	U-Net	UNet++	MA-Net	MA-Net ปรับปรุงค่าสี R, G, B	MA-Net ปรับปรุงค่าสี R, G	ลักษณะภาพ
1								รูปที่มีการกระจายความเข้มแสงผิดปกติบริเวณตำแหน่งเนื้องอก
2								รูปที่มีการกระจายความเข้มแสงผิดปกติบริเวณตำแหน่งเนื้องอก
3								รูปที่มีการกระจายความเข้มแสงปกติบริเวณตำแหน่งเนื้องอก

รูปที่ 42 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้องอกตับ


4.2.3 ผลการแบ่งส่วนเนื้ออกตับที่มีประสิทธิภาพต่ำสุด

ผลการแบ่งส่วนเนื้ออกตับพบความแม่นยำต่ำสุดเปรียบเทียบภาพผลเฉลย (b) และภาพการแบ่งส่วนจากโมเดล (c) สำหรับการแบ่งส่วนเนื้ออกตับในผู้ป่วยที่มีภาพ SPECT/CT สแกน (a) ที่มีเนื้ออกขนาดเล็กและในภาพคนไข้ที่มีการกระจายความเข้มของแสงบริเวณเนื้ออกตับผิดปกติ



(a) ภาพ SPECT/CT สแกน (b) ภาพผลเฉลย (c) ภาพการแบ่งส่วนจากโมเดล

รูปที่ 43 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้ออกตับในคนไข้ที่มีเนื้ออกขนาดเล็ก



(a) ภาพ SPECT/CT สแกน (b) ภาพผลเฉลย (c) ภาพการแบ่งส่วนจากโมเดล

รูปที่ 44 ผลการทดสอบโมเดลแยกการแบ่งส่วนเนื้ออกตับที่มีการกระจายความเข้มแสงผิดปกติ

ผลการแบ่งส่วนเนื้ออกตับโดยใช้ชุดข้อมูลคนไข้ที่มีการกระจายความเข้มแสงแบบปกติชุดเดียวกัน พบว่าชุดข้อมูลเฉพาะคนไข้ที่มีการกระจายความเข้มแสงแบบปกติของภาพ SPECT/CT ค่า DSC เป็น 0.68 และ IoU เป็น 0.56 มากกว่าการแบ่งส่วนเนื้ออกตับจากภาพชุดข้อมูลคนไข้ที่มีการกระจายความเข้มแสงแบบปกติและผิดปกติในชุดข้อมูลทดสอบ ซึ่งได้ผลการประเมินค่า DSC เป็น 0.66 และ IoU เป็น 0.55 จากผลการเปรียบเทียบสามารถสรุปได้ว่าชุดข้อมูลทดสอบที่มีภาพการกระจายความเข้มแสงแบบปกติมีผลทำให้ค่าความแม่นยำโดยรวมของโมเดลลดลง ดังตารางที่ 13

ตารางที่ 13 ผลลัพธ์การแบ่งส่วนเนื้ออกตับในคนไข้ที่มีการกระจายความเข้มแสงปกติ

โมเดล	ชุดข้อมูลทดสอบการแบ่งส่วนเนื้ออกตับ	จำนวนคนไข้การกระจายแสงปกติ	จำนวนคนไข้การกระจายแสงผิดปกติ	DSC	IoU
MA-Net	กระจายแสงแบบปกติและผิดปกติ	6	3	0.66	0.55
MA-Net	การกระจายแสงแบบปกติ	6	0	0.68	0.56

4.3 เปรียบเทียบประสิทธิภาพการแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพฟิวชั่น

การฝึกชุดข้อมูลจากโรงพยาบาลจุฬาลงกรณ์ จำนวน 34 คนไข้ และชุดข้อมูลทดสอบ โรงพยาบาลจุฬาลงกรณ์ จำนวน 9 คนไข้ ด้วยชุดข้อมูลที่ผ่านมากระบวนการฟิวชั่นรูปภาพ CT สแกน และ SPECT/CT สแกนในกระบวนการอินพุตด้วยวิธีการการบวกรูปภาพ (addWeighted) และการตัดส่วนเฉพาะช่องทางท้องในการแบ่งส่วนเนื้อตับและเนื้องอกตับ ทำการทดสอบด้วยโมเดล MA-Net pre-trained เป็น noisy student Backbone เป็น timm-EfficientNet-B6 โดยใช้พารามิเตอร์เหมือนกับโมเดลแยกการแบ่งส่วนเนื้อตับจากภาพ CT สแกนและเนื้องอกตับจากภาพ SPECT/CT สแกน โมเดลรวมการแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพฟิวชั่นให้ค่าผลการประเมินข้อมูลทดสอบสูงที่สุดจากการทดลองที่ไม่มีการปรับปรุงค่าความเข้มของสีในช่องสี โดยใช้พารามิเตอร์เดียวกันกับโมเดลแยกการแบ่งส่วน โดยค่าการประเมิน DSC เนื้อตับและเนื้องอกตับเป็น 0.83, 0.62 และ IoU เนื้อตับและเนื้องอกตับเป็น 0.74, 0.51 ดังตารางที่ 14

ตารางที่ 14 ผลลัพธ์การแบ่งส่วนโมเดลเนื้อตับและเนื้องอกตับ


โมเดล	พารามิเตอร์	เนื้อตับ	เนื้อตับ	เนื้องอกตับ	เนื้องอกตับ
		DSC	IoU	DSC	IoU
U-Net	ค่าน้ำหนักภาพฟิวชั่น CT เป็น 0.5, SPECT/CT เป็น 0.5	0.74	0.62	0.54	0.41
UNet++	ค่าน้ำหนักภาพฟิวชั่น CT เป็น 0.5, SPECT/CT เป็น 0.5	0.77	0.67	0.51	0.39
MA-Net	ค่าน้ำหนักภาพฟิวชั่น CT เป็น 0.5, SPECT/CT เป็น 0.5	0.83	0.74	0.62	0.51
MA-Net	การปรับปรุงค่าสี R, G ค่าน้ำหนักภาพฟิวชั่น CT เป็น 0.5, SPECT/CT เป็น 0.5	0.81	0.72	0.59	0.48
MA-Net	ค่าน้ำหนักภาพฟิวชั่น CT เป็น 0.8, SPECT/CT เป็น 0.2	0.77	0.66	0.56	0.43
MA-Net	ค่าน้ำหนักภาพฟิวชั่น CT เป็น 0.2, SPECT/CT เป็น 0.8	0.76	0.65	0.58	0.45
MA-Net	ค่าน้ำหนักภาพฟิวชั่น CT เป็น 0, SPECT/CT เป็น 1	0.54	0.45	0.43	0.34

การตรวจสอบประสิทธิภาพโมเดลรวมการแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพพีวซันที่นำภาพ CT สแกน ตรวจสอบหาค่าความคล้ายคลึงกันกับภาพ SPECT/CT ในแต่ละคนไข้ ด้วยโมเดล MA-Net พารามิเตอร์ timm- EfficientNet-B6 และ pre-trained เป็น noisy-student ที่มีการกำหนดค่าน้ำหนักภาพพีวซัน CT เป็น 0.5, SPECT/CT เป็น 0.5 ประสิทธิภาพของโมเดลรวมการแบ่งส่วนให้ผลการแบ่งส่วนเนื้อตับ ค่า DSC เป็น 0.83 และเนื้องอกตับ ค่า DSC เป็น 0.62 มากกว่าโมเดลรวมการแบ่งส่วนจากภาพพีวซันที่นำภาพ SPECT/CT ไปตรวจสอบหาค่าความคล้ายคลึงกันกับทุกภาพ CT สแกนในแต่ละคนไข้ที่มีผลการแบ่งส่วนเนื้อตับ ค่า DSC เป็น 0.73 และเนื้องอกตับ ค่า DSC เป็น 0.61 ตามลำดับ เนื่องจากการนำภาพ SPECT/CT ที่มีจำนวน 3,836 ภาพ ไปจับคู่ความคล้ายคลึงกันกับภาพ CT สแกน ทำให้จำนวนภาพพีวซันการแบ่งส่วนเนื้อตับลดลงจาก 7,085 ภาพ เหลือ 3,836 ภาพ ข้อมูลการฝึกฝนโมเดลที่น้อยลงส่งผลกับประสิทธิภาพของโมเดลลดลง

ตารางที่ 15 ผลลัพธ์การแบ่งส่วนโมเดลภาพ SPECT/CT ตรวจสอบความคล้ายคลึงกับภาพ CT

โมเดล	การตรวจสอบความคล้ายคลึง	จำนวนภาพข้อมูลฝึกฝน	จำนวนภาพข้อมูลทดสอบ	เนื้อตับ DSC	เนื้อตับ IoU	เนื้องอกตับ DSC	เนื้องอกตับ IoU
MA-Net	CT ตรวจสอบความคล้ายคลึงกับภาพ SPECT/CT	5,958	1,087	0.83	0.74	0.62	0.51
MA-Net	SPECT/CT ตรวจสอบความคล้ายคลึงกับภาพ CT	3,131	705	0.73	0.65	0.61	0.48

โมเดลรวมการแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพพีวซันเปรียบเทียบกับโมเดลแยกการแบ่งส่วน โดยกำหนดพารามิเตอร์ timm- EfficientNet-B6 และ pre-trained เป็น noisy-student ผลการแบ่งส่วนจากโมเดลพบว่าในภาพพีวซันโมเดลรวมการแบ่งส่วน MA-Net ให้ผลการทดสอบในการแบ่งส่วนใกล้เคียงกับผลเฉลยมากกว่าโมเดล U-Net และ UNet++ แต่เมื่อเปรียบเทียบกับโมเดลแยกการแบ่งส่วนด้วยคนไข้ทดสอบเดียวกัน โมเดลแยกการแบ่งส่วนเนื้อตับและเนื้องอกตับให้ผลการทดสอบที่ใกล้เคียงกับผลเฉลยมากกว่าโมเดลรวมการแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพพีวซัน ดังรูปที่ 45



รูปที่ 45 ผลการทดสอบโมเดลการแบ่งส่วนเนื้อตับและเนื้องอกตับจากภาพพีวชั้น

4.4 เปรียบเทียบผลลัพธ์การแบ่งส่วนในชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ

การทดสอบโมเดลโดยใช้ชุดข้อมูลคนไข้ที่สลับกันตามตารางที่ 5 ด้วยพารามิเตอร์การฝึกฝนให้ประสิทธิภาพดีที่สุดในแต่ละโมเดล MA-Net กำหนด backbone เป็น timm- EfficientNet-B6 pre-trained เป็น noisy-student ให้ผลการทดสอบค่า DSC และ IoU ที่ใกล้เคียงกัน ดังตารางที่ 16

ตารางที่ 16 เปรียบเทียบผลลัพธ์การแบ่งส่วนในแต่ละชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ

ข้อมูล	โมเดลแยกการแบ่งส่วน				โมเดลรวมการแบ่งส่วน			
	แบ่งส่วนเนื้อตับ		แบ่งส่วนเนื้องอกตับ		แบ่งส่วนเนื้อตับ		แบ่งส่วนเนื้องอกตับ	
	DSC	IoU	DSC	IoU	DSC	IoU	DSC	IoU
ชุดที่ 1	0.90	0.84	0.66	0.55	0.83	0.74	0.62	0.51
ชุดที่ 2	0.90	0.84	0.66	0.55	0.82	0.73	0.62	0.51
ชุดที่ 3	0.89	0.83	0.65	0.54	0.82	0.72	0.61	0.50
เฉลี่ย	0.90	0.84	0.66	0.55	0.82	0.73	0.62	0.51

4.5 เปรียบเทียบระยะเวลาในการทดสอบ

การทดสอบใช้ NVIDIA-SMI 460.32.03 GPU Persistence-M and 11GB memory เวลาในการประมวลผลชุดข้อมูลทดสอบ ในกระบวนการเริ่มต้นโดยเตรียมชุดข้อมูลการตัดเฉพาะส่วนท้อง และการปรับระดับสี HU ของภาพ CT สแกนนำเข้าทดสอบในโมเดลที่มีการฝึกฝนแล้ว และแสดงผลรูปภาพการทำนาย โมเดลแยกการแบ่งเนื้อตับและเนื้องอกตับใช้เวลาทดสอบต่อภาพ 1.66 วินาที และ 1.70 วินาที ตามลำดับ ในโมเดลรวมการแบ่งส่วนใช้เวลาทดสอบต่อภาพ 1.93 วินาที ซึ่งในโมเดลแยกการแบ่งส่วนรูปภาพที่ใช้ทดสอบแบ่งส่วนเนื้อตับและเนื้องอกตับใช้เวลารวม 3.36 วินาที ต่อภาพ ในขณะที่โมเดลรวมการแบ่งส่วนเนื้อตับและเนื้องอกตับใช้เวลา 1.93 วินาทีต่อภาพ

ตารางที่ 17 ระยะเวลาในการทดสอบโมเดล

โมเดล	แบ่งส่วนเนื้อตับ	แบ่งส่วนเนื้องอกตับ	แบ่งส่วนเนื้อตับและเนื้องอกตับ
เวลาในการทดสอบ	30 นาที	20 นาที	35 นาที
ชนิดรูปภาพทดสอบ	CT สแกน	SPECT/CT สแกน	พีวชั่น CT, SPECT/CT สแกน
จำนวนรูปภาพทดสอบ	1,087	705	1,087
เวลาทดสอบต่อภาพ	1.66 วินาที	1.70 วินาที	1.93 วินาที

บทที่ 5

บทสรุป

5.1 สรุปผลการวิจัย

การแบ่งส่วนเนื้องอกและเนื้องอกตับโดยอัตโนมัติจะช่วยสร้างมาตรฐานในการแบ่งส่วนเนื้องอกและเนื้องอกตับระหว่างนักรังสีวิทยา และช่วยลดเวลาระยะเวลาที่ใช้ในการแบ่งส่วนเนื้องอกและเนื้องอกตับ สำหรับโมเดล MA-Net เป็นรูปแบบความสนใจที่ใช้สำหรับการแบ่งส่วนที่มีความสามารถในการรวมหลายสเกลและฟังก์ชันลักษณะ (Feature map) ซึ่งสามารถเรียนรู้รูปร่างประกอบต่าง ๆ ได้ในแต่ละขนาดของรูปภาพ สำหรับการแบ่งส่วนเนื้องอกตับการตรวจสอบคุณสมบัติการกระจายความเข้มของรูปภาพ SPECT/CT สแกน และนำไปปรับฮิสโตแกรมให้อยู่ในการกระจายแบบปกติสำหรับค่าการกระจายความเข้มสำหรับสีแดงและสีเขียวของโมเดล RGB ก่อนนำเข้าโมเดลจะทำให้ประสิทธิภาพของโมเดลแยกการแบ่งส่วนเนื้องอกตับดีขึ้นจากค่า DSC 0.62 เป็น 0.66 และ IoU จาก 0.49 เป็น 0.55 และในการเพิ่มการตัดส่วนเฉพาะช่องท้องของรูปภาพ CT สแกนที่มีขนาดช่องท้องเล็กกว่าภาพพื้นหลังมากเพื่อเพิ่มการตัดส่วนเฉพาะช่องท้องทำให้ประสิทธิภาพของโมเดลดีขึ้นเช่นกัน

โมเดลรวมการแบ่งส่วนเนื้องอกและเนื้องอกตับการปรับฮิสโตแกรมให้อยู่ในการกระจายแบบปกติ สำหรับการกระจายความเข้มสำหรับสีแดงและสีเขียวก่อนนำเข้าโมเดลทำให้ประสิทธิภาพการแบ่งส่วนเนื้องอกลดลงเนื่องจากการปรับค่าการกระจายความเข้มส่งผลต่อการกระจายความเข้มสีบริเวณขอบเนื้องอกตับ ซึ่งเป็นบริเวณเนื้องอกและการปรับฮิสโตแกรมของรูปภาพพิวซ์ไม่ทำให้ประสิทธิภาพของการแบ่งส่วนเนื้องอกตับในโมเดลรวมเพิ่มขึ้น

ในส่วนของประสิทธิภาพจากการเปรียบเทียบโมเดลแยกการแบ่งส่วนของเนื้องอกและเนื้องอกตับ การแบ่งส่วนเนื้องอกและเนื้องอกตับ ค่า DSC เป็น 0.90, 0.66 และค่า IoU เป็น 0.84, 0.55 ตามลำดับ ซึ่งให้ผลการตัดสินใจของโมเดลมีประสิทธิภาพดีกว่าโมเดลรวมการแบ่งส่วนเนื้องอกและเนื้องอกตับในโมเดลเดียวกัน ค่าประสิทธิภาพของโมเดลรวมการแบ่งส่วนเนื้องอกและเนื้องอกตับ ค่า DSC เป็น 0.83, 0.62 และค่า IoU เป็น 0.74, 0.51 ตามลำดับ เนื่องจากต้องมีการตัดสินใจที่เพิ่มขึ้นของโมเดลและความคล้ายคลึงกันของรูปภาพ CT สแกน และ SPECT/CT สแกนที่แตกต่างกันในมุมมองของเวลาในการทดสอบโมเดลรวมการแบ่งส่วนเนื้องอกและเนื้องอกตับให้การประมวลผลที่เร็วกว่าโมเดลแยกการแบ่งส่วนเนื้องอกและโมเดลการแบ่งส่วนเนื้องอกตับ

ในการสลับชุดข้อมูลคนไข้ระหว่างชุดข้อมูลทดสอบและฝึกฝนจากการสลับชุดข้อมูล 3 ชุด ผลการแบ่งส่วนให้ค่าประสิทธิภาพใกล้เคียงกันทั้งโมเดลแยกการแบ่งส่วนและโมเดลรวมการแบ่งส่วน ซึ่งสามารถประมาณได้ว่าชุดข้อมูลคนไข้ที่มีรูปภาพแตกต่างกันไม่มีผลต่อประสิทธิภาพของโมเดลการ

แบ่งส่วนเนื้อตับและเนื้ออกตับ ในส่วนของโมเดลรวมการแบ่งส่วนเนื้อตับและเนื้ออกใช้ระยะเวลาการทดสอบที่เร็วกว่าโมเดลการแยกการแบ่งส่วนเนื้อตับและเนื้ออกตับใช้เวลา 1.43 วินาทีต่อภาพ

5.2 ปัญหาและข้อจำกัดที่พบจากการวิจัย

- 5.2.1 กลุ่มตัวอย่างของเนื้ออกตับที่ใช้มีจำนวนน้อยมากเมื่อเทียบกับกลุ่มตัวอย่างที่ไม่มีเนื้ออกตับทำให้มีความไม่สมดุลของข้อมูล
- 5.2.2 การแบ่งส่วนเนื้ออกตับจะใช้ภาพ SPECT/CT มีการปรับค่า threshold ที่แตกต่างกันในแต่ละคนไข้ ซึ่งขึ้นอยู่กับารูดกลืนรังสีในแต่ละคนไข้ที่แตกต่างกัน ทำให้ภาพเนื้ออกมีค่าความเข้มแสงที่แตกต่างกันอย่างมาก
- 5.2.3 การพิวชันรูปภาพ CT และ SPECT/CT ในคนไข้ที่มีจำนวนรูปภาพแตกต่างกันมากทำให้ความคล้ายคลึงกันของภาพที่พิวชันมีค่าน้อย เมื่อนำเข้าโมเดลอาจทำให้มีความไม่สมดุลของข้อมูล

5.3 ข้อเสนอแนะ

- 5.3.1 ควรเพิ่มจำนวนกลุ่มตัวอย่างเนื้ออกตับของภาพ SPECT/CT ให้มากขึ้น และมีความหลากหลาย
- 5.3.2 จำนวนภาพของเนื้อตับและเนื้ออกมีจำนวนน้อยเมื่อเทียบกับจำนวนภาพถ่ายทางการแพทย์ทั้งหมดของคนไข้แต่ละราย
- 5.3.3 ทดลองสร้างการพิวชันระดับระดับเลเยอร์ (Layer-level) และพิวชันระดับการตัดสินใจ (Decision-level) เพื่อเปรียบเทียบความแม่นยำและความถูกต้องกับพิวชันระดับอินพุต (Input-level)
- 5.3.4 เพื่อเพิ่มประสิทธิภาพในการทำนายเนื้ออกตับ อาจจะตัดเฉพาะส่วนของเนื้อตับมาทำการทดสอบในโมเดลการแบ่งส่วนเนื้ออกตับ

บรรณานุกรม

1. WHO. 2022 [cited 2565 20 ตุลาคม]; Available from: <https://www.who.int/news-room/fact-sheets/detail/cancer>.
2. เว็บไซต์สารสนเทศประเทศไทย. 2022 [cited 2565 20 ตุลาคม]; Available from: https://www.hiso.or.th/hiso5/report/download.php?name=thai2021_19.
3. Elboga, U., *Yttrium-90 Selective Internal Radiation Therapy for Liver Tumors*. Radionuclide Treatments, 2017.
4. Ronneberger, O., P. Fischer, and T. Brox. *U-net: Convolutional networks for biomedical image segmentation*. in *International Conference on Medical image computing and computer-assisted intervention*. 2015. Springer.
5. Zhou, Z., et al., *Unet++: A nested u-net architecture for medical image segmentation*, in *Deep learning in medical image analysis and multimodal learning for clinical decision support*. 2018, Springer. p. 3-11.
6. Fan, T., et al., *Ma-net: A multi-scale attention network for liver and tumor segmentation*. IEEE Access, 2020. 8: p. 179656-179665.
7. He, K., et al. *Deep residual learning for image recognition*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
8. Simonyan, K. and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556, 2014.
9. Russakovsky, O., et al., *Imagenet large scale visual recognition challenge*. International journal of computer vision, 2015. 115(3): p. 211-252.
10. Xie, Q., et al. *Self-training with noisy student improves imagenet classification*. in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2020.
11. Wang, Z., et al., *Image quality assessment: from error measurement to structural similarity*. IEEE transactions on image processing, 2004. 13(1).
12. *Liver Tumor Segmentation Benchmark*. [cited 2566 2 มิถุนายน]; Available from: <https://competitions.codalab.org/competitions/17094>.

13. 3D Institute for Research into Cancer of the Digestive System. [cited 2566 2 มิถุนายน]; Available from: <https://www.ircad.fr/research/data-sets/liver-segmentation-3d-ircadb-01/>.
14. Li, X., et al., *H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes*. IEEE transactions on medical imaging, 2018. 37(12): p. 2663-2674.
15. Jin, Q., et al., *RA-UNet: A Hybrid Deep Attention-Aware Network to Extract Liver and Tumor in CT Scans*. Front Bioeng Biotechnol, 2020. 8: p. 605132.
16. Jiang, H., et al., *Ahcnet: An application of attention mechanism and hybrid connection for liver tumor segmentation in ct volumes*. IEEE Access, 2019. 7: p. 24898-24909.
17. Efremova, D.B., et al., *Automatic segmentation of kidney and liver tumors in CT images*. arXiv preprint arXiv:1908.01279, 2019.
18. Chaichana, A., et al., *Automated segmentation of lung, liver, and liver tumors from Tc-99m MAA SPECT/CT images for Y-90 radioembolization using convolutional neural networks*. Medical physics, 2021. 48(12): p. 7877-7890.
19. Luu, M.H., et al., *Quantification of liver-Lung shunt fraction on 3D SPECT/CT images for selective internal radiation therapy of liver cancer using CNN-based segmentations and non-rigid registration*. Computer Methods and Programs in Biomedicine, 2023. 233: p. 107453.
20. Zhou, T., S. Ruan, and S. Canu, *A review: Deep learning for medical image segmentation using multi-modality fusion*. Array, 2019. 3: p. 100004.
21. Tisch, C., et al., *Hounsfield unit values of liver pathologies in unenhanced post-mortem computed tomography*. International journal of legal medicine, 2019. 133(6): p. 1861-1867.
22. Buck, A.K., et al., *Spect/ct*. Journal of Nuclear Medicine, 2008. 49(8): p. 1305-1319.
23. Taha, A.A. and A. Hanbury, *Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool*. BMC medical imaging, 2015. 15(1): p. 1-28.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	สุกัญญา แซ่คู
วัน เดือน ปี เกิด	28 สิงหาคม 2531
สถานที่เกิด	ร้อยเอ็ด
วุฒิการศึกษา	พ.ศ. 2553 วิศวกรรมศาสตรบัณฑิต สาขา วิศวกรรมโทรคมนาคม จาก มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ที่อยู่ปัจจุบัน	1/375 ซอย วัดเวฬุวนาราม 10 แขวง ดอนเมือง เขต ดอนเมือง กรุงเทพมหานคร 10210
ผลงานตีพิมพ์	Sukanya Saeku, Nut Noipinit, Kitiwat Khamwan, Punnarai Siricharoen, "Liver and Tumor Segmentation in Selective Internal Radiation Therapy 99mTc-MAA SPECT/CT Images using MANet and Histogram Adjustment", 2022 3rd Asia Symposium on Signal Processing (ASSP)