

การแบ่งส่วนโรคหลอดเลือดเจริญผิดปกติบนภาพกล้องแคปซูลโดยใช้โครงข่ายตัวเข้ารหัสตัวถอดรหัส
ที่เพิ่มประสิทธิภาพ



นายสิริชาติ กอบประดิษฐ์

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2562
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

ANGIODYSPLASIA SEGMENTATION ON CAPSULE ENDOSCOPY IMAGES USING ENHANCED
ENCODER-DECODER 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 2019
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การแบ่งส่วนโรคหลอดเลือดเจริญผิดปกติบนภาพกล้อง แคปซูลโดยใช้โครงข่ายตัวเข้ารหัสตัวถอดรหัสที่เพิ่ม ประสิทธิภาพ
โดย	นายสิริชาติ กอบประดิษฐ์
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

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

คณะกรรมการสอบวิทยานิพนธ์

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

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล)

..... กรรมการ
(อาจารย์ ดร.ดวงดาว วิชาดากุล)

..... กรรมการภายนอกมหาวิทยาลัย
(อาจารย์ ดร.ธนภัทร ช้างคะจิตร)

สิริชาติ กอบประดิษฐ์ : การแบ่งส่วนโรคหลอดเลือดเจริญผิดปกติบนภาพกล้องแคปซูล โดยใช้โครงข่ายตัวเข้ารหัสตัวถอดรหัสที่เพิ่มประสิทธิภาพ. (ANGIODYSPLASIA SEGMENTATION ON CAPSULE ENDOSCOPY IMAGES USING ENHANCED ENCODER-DECODER NETWORKS) อ.ที่ปรึกษาหลัก : ผศ. ดร.พีรพล เวทีกุล

โรคหลอดเลือดเจริญผิดปกติเป็นรอยแผลที่อาจเกิดขึ้นได้ในทางเดินอาหารส่วนล่าง ถึงแม้รอยแผลเหล่านี้จะไม่แสดงอาการเจ็บในผู้ป่วย แต่อาจเกิดการเลือดออกจากรอยแผลเหล่านี้ได้ หนึ่งในวิธีการตรวจสอบโรคนี้คือใช้การส่องกล้องแคปซูลไร้สายด้วยการกลืน ข้อมูลที่ได้จากการเก็บภาพภายในทางเดินอาหารจะมีปริมาณมากซึ่งจะมีทั้งภาพที่มีรอยโรคที่สนใจ และภาพที่ไม่มีรอยโรคปะปนกันอยู่ งานวิจัยการตรวจจับรอยโรคที่ได้ศึกษามานี้มักมุ่งเน้นการสร้างแบบจำลองที่มีความแม่นยำในตรวจจับเฉพาะส่วนของภาพที่มีรอยโรคโดยเฉพาะ ไม่ได้ศึกษาการนำแบบจำลองไปใช้งานกับภาพส่วนที่ไม่มีรอยโรค วิทยานิพนธ์ฉบับนี้ได้เห็นถึงส่วนที่สามารถเพิ่มประสิทธิภาพแก่แบบจำลองในการใช้งานในโลกจริงได้เหมาะสมขึ้น โดยนำเสนอวิธีการประมวลผลภาพเบื้องต้นและการเพิ่มกลไกจุดสนใจแก่แบบจำลอง นอกจากนี้ยังได้นำเสนอการสร้างแบบจำลอง 2 รูปแบบคือ แบบจำลองเรียงซ้อน และแบบจำลองร่วมกัน เพื่อเพิ่มประสิทธิภาพในงานแบ่งส่วนโรคอีกด้วย การทดลองได้ทดสอบแบบชุดข้อมูลโรคหลอดเลือดเจริญผิดปกติ MICCAI 2017 และ MICCAI 2018 ผลลัพธ์แสดงให้เห็นว่าแบบจำลองร่วมกันที่นำเสนอมีประสิทธิภาพดีที่สุด สามารถแบ่งส่วนภาพ และจำแนกประเภทภาพที่มีรอยโรค และไม่มีรอยโรคได้ด้วยค่าคะแนนมาตรวัดที่สูง

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2562

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6170970021 : MAJOR COMPUTER SCIENCE

KEYWORD: angiodysplasia, deep learning, segmentation, classification

Sirichart Gobpradit : ANGIODYSPLASIA SEGMENTATION ON CAPSULE
ENDOSCOPY IMAGES USING ENHANCED ENCODER-DECODER NETWORKS.

Advisor: Asst. Prof. PEERAPON VATEEKUL, Ph.D.

Angiodysplasia refers to a lesion that could be found in the lower gastrointestinal tract. Even though the lesions would not cause patients to hurt, it still would cause bleeding. The method that could diagnose this disease is swallowing a wireless endoscopy capsule. The wireless camera takes many pictures of pathology and non-pathology images. Many papers the researcher studied aim to create a model that focuses on precise pathology object detection, but miss the applying to a non-pathology image in the training process. This thesis address this issue by introducing the model more suitable to the real-world usage by proposed the image pre-processing and adding attention mechanism. Moreover, we propose two approaches: cascading and joint model. The experiment was conducted on MICCAI 2017 and MICCAI 2018. The results showed that the proposed joint model is the best model in angiodysplasia image segmentation and classification tasks.

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Field of Study: Computer Science

Student's Signature

Academic Year: 2019

Advisor's Signature

กิตติกรรมประกาศ

การที่วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดีนั้น นอกจากการทำงานของตัวผู้วิจัยแล้ว ยังมีบุคคลท่านอื่นที่เป็นส่วนสำคัญที่ได้ให้ความช่วยเหลือในการจัดทำวิทยานิพนธ์ฉบับนี้ขึ้นมา ผู้วิจัยรู้สึกซาบซึ้งในความกรุณาเหล่านี้เป็นอย่างมากจึงใคร่ขอใช้เนื้อหาในส่วนกิตติกรรมประกาศของวิทยานิพนธ์ฉบับนี้แสดงความขอบพระคุณเป็นอย่างสูงมา ณ ที่นี้

ขอขอบพระคุณอาจารย์ที่ปรึกษา ผศ. ดร. พีรพล เวทีกุล ผู้ที่คอยให้ความช่วยเหลือ และให้คำปรึกษาอย่างเต็มที่ รวมทั้งผลักดันให้งานวิจัยและวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้

ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ซึ่งประกอบไปด้วย ศ. ดร.บุญเสริม กิจศิริกุล, อ. ดร.ดวงดาว วิชาดากุล และ อ. ดร.ธนภัทร ชังคะจิตร ที่ได้กรุณาให้เกียรติเป็นคณะกรรมการ รวมทั้งให้คำปรึกษา และข้อเสนอแนะอันเป็นประโยชน์อย่างมากต่อการทำวิจัย และวิทยานิพนธ์ฉบับนี้

ขอขอบคุณเพื่อน ๆ พี่ ๆ น้อง ๆ สมาชิก “Data Mining Group, MIND Lab” ทุกท่านสำหรับกำลังใจ และคำแนะนำต่าง ๆ เพื่อนำมาปรับใช้ในวิทยานิพนธ์ฉบับนี้

สุดท้ายนี้ขอขอบพระคุณครอบครัว และบุคคลอันเป็นที่รักของผู้วิจัยที่ให้การสนับสนุนในทุก ๆ ด้าน และคอยให้กำลังใจตลอดระยะเวลาในการดำเนินการทำงานวิจัยนี้

สิริชาติ กอบประดิษฐ์

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญรูปภาพ.....	ญ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	3
1.3 ขอบเขตการวิจัย.....	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.5 ขั้นตอนการดำเนินงาน.....	3
1.6 ผลงานวิจัยที่ตีพิมพ์.....	5
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	6
2.1 โครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network).....	6
2.2 โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional Neural Network หรือ CNN).....	6
2.3 โครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัส (Encoder-Decoder Neural Network).....	8
2.4 กลไกจุดสนใจ (Attention Mechanism).....	9
2.5 การแต่งเติมภาพ (Image Augmentation).....	9

2.6 การประมวลผลภาพ (Image processing).....	10
บทที่ 3 งานวิจัยที่เกี่ยวข้อง.....	11
บทที่ 4 แนวคิดและแบบจำลองที่นำเสนอ.....	14
4.1 การเตรียมข้อมูล (Data preparation).....	14
4.2 ชุดข้อมูล (Dataset).....	15
4.3 การวัดผล (Evaluation).....	16
4.4 ฟังก์ชันสูญเสีย (Loss function).....	17
4.5 การฝึกสอน (Training strategy).....	18
4.6 แบบจำลองที่นำเสนอ (Proposed models).....	19
บทที่ 5 การทดลอง.....	25
5.1 การทดลองของแบบจำลองแบ่งส่วน.....	25
5.2 การทดลองเปรียบเทียบแบบจำลองเรียงซ้อนกับแบบจำลองร่วมกัน.....	26
5.3 การทดลองเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกัน.....	27
5.4 การวิเคราะห์สำรวจข้อมูล.....	29
บทที่ 6 สรุปผลวิจัยและแนวทางวิจัยในขั้นถัดไป.....	38
6.1 สรุปผลการวิจัย.....	38
6.2 แนวทางวิจัยถัดไป.....	38
บรรณานุกรม.....	39
ประวัติผู้เขียน.....	43

สารบัญตาราง

	หน้า
ตาราง 1 แผนภูมิแกนต์แสดงขั้นตอนการดำเนินงาน	4
ตาราง 2 กำหนดชื่อแบบจำลอง	25
ตาราง 3 ค่า Dice และ IoU เมื่อทดสอบด้วยชุดข้อมูล MICCAI 2017 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)	25
ตาราง 4 ค่า Dice และ IoU เมื่อทดสอบด้วยชุดข้อมูล MICCAI 2018 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)	25
ตาราง 5 ผลลัพธ์การเปรียบเทียบของแบบจำลองที่นำเสนอด้วยชุดข้อมูล MICCAI 2017 โดยมีหน่วย เป็นเปอร์เซ็นต์ (%)	27
ตาราง 6 ผลลัพธ์การเปรียบเทียบของแบบจำลองที่นำเสนอด้วยชุดข้อมูล MICCAI 2018 โดยมีหน่วย เป็นเปอร์เซ็นต์ (%)	27
ตาราง 7 ผลลัพธ์มาตรการจัดการจำแนกประเภทเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกัน ด้วยชุดข้อมูล MICCAI 2017 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%).....	27
ตาราง 8 ผลลัพธ์มาตรการจัดการจำแนกประเภทเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกัน ด้วยชุดข้อมูล MICCAI 2018 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%).....	28
ตาราง 9 ผลลัพธ์มาตรการจัดการแบ่งส่วนเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันด้วยชุด ข้อมูล MICCAI 2017 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%).....	28
ตาราง 10 ผลลัพธ์มาตรการจัดการแบ่งส่วนเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันด้วย ชุดข้อมูล MICCAI 2018 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)	28
ตาราง 11 ชุดข้อมูลแบ่งตามประเภท	29
ตาราง 12 จำนวนรอยแผลต่อภาพของชุดข้อมูล MICCAI 2017.....	30
ตาราง 13 จำนวนรอยแผลต่อภาพของชุดข้อมูล MICCAI 2018.....	31
ตาราง 14 เปรียบเทียบจำนวนรอยแผลต่อภาพของชุดข้อมูล MICCAI 2017 กับ MICCAI 2018	33

ตาราง 15 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017 แบบจำแนกประเภท 35

ตาราง 16 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017 แบบแจกแจงจำนวนรอยโรค 35

ตาราง 17 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2018 แบบแจกแจงจำนวนรอยโรค 36

ตาราง 18 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2018 แบบแจกแจงจำนวนรอยโรค 36



สารบัญรูปภาพ

	หน้า
รูป 1 โครงสร้างของแคปซูลไร้สาย [2] (ซ้าย) กล้องส่องลำไส้ใหญ่ [6] (ขวา).....	1
รูป 2 ภาพตัวอย่างรอยโรคหลอดเลือดเจริญผิดปกติ [7] (ซ้าย) ภาพตัวอย่างรอยโรคติ่งเนื้อเมือก [8] (ขวา).....	2
รูป 3 โครงข่ายประสาทเทียมเชิงลึก	6
รูป 4 การขยับของตัวกรองเพื่อสร้างฟังก์ชันลักษณะ	7
รูป 5 การรวมกันด้วยค่าสูงสุด	8
รูป 6 โครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัส	8
รูป 7 ตัวอย่างการแต่งเติมภาพจาก [17].....	9
รูป 8 ตัวอย่างภาพต้นฉบับการภาพหลังการทำ CLAHE	10
รูป 9 แบบจำลอง U-Net [9].....	11
รูป 10 ตัวอย่างโครงสร้างโดยรวมของ Mask R-CNN.....	12
รูป 11 แบบจำลอง AlbuNet [12].....	13
รูป 12 ตัวอย่างโครงสร้างโมดูล Squeeze-and-excitation [31].....	13
รูป 13 ตัวอย่างภาพจากชุดข้อมูลที่มีรอยโรค MICCAI 2017 (บน) และ MICCAI 2018 (ล่าง).....	15
รูป 14 ตัวอย่างภาพจากชุดข้อมูลที่ไม่มีรอยโรค MICCAI 2017 (บน) และ MICCAI 2018 (ล่าง)....	16
รูป 15 ตัวอย่างภาพ CLAHE ที่นำไปใช้งานจากชุดข้อมูล MICCAI 2017 [10] (บน) และ MICCAI 2018 [11] (ล่าง).....	19
รูป 16 แบบจำลองแบ่งส่วนเพียงอย่างเดียว	21
รูป 17 แบบจำลองเรียงซ้อน.....	22
รูป 18 แบบจำลองร่วมกัน.....	23
รูป 19 การนำแบบจำลองร่วมกัน มาประยุกต์ใช้กับแบบจำลองแบ่งส่วนเพียงอย่างเดียว	24

รูป 20 ตัวอย่างภาพที่มีรอยโรคจริง (ซ้าย) ภาพการแบ่งส่วนภาพรอยโรคจากแบบจำลอง AlbuNet (กลาง) และ ภาพการแบ่งส่วนภาพรอยโรคจากแบบจำลองแบ่งส่วนที่นำเสนอ (ขวา).....	26
รูป 21 ตัวอย่างผลลัพธ์ที่ได้จากแบบจำลอง.....	29
รูป 22 ตัวอย่างภาพที่แบบจำลองร่วมกันทำนายผลการจำแนกประเภทผิดเป็นค่าลบเท็จ	29
รูป 23 จำนวนภาพต่อจำนวนรอยโรคบนชุดข้อมูล MICCAI 2017	30
รูป 24 ฮิสโตแกรมแสดงจำนวนรอยโรคในหน่วยพิกเซลต่อภาพบนชุดข้อมูล MICCAI 2017	31
รูป 25 จำนวนภาพต่อจำนวนรอยโรคบนชุดข้อมูล MICCAI 2018	32
รูป 26 ฮิสโตแกรมแสดงจำนวนรอยโรคในหน่วยพิกเซลต่อภาพบนชุดข้อมูล MICCAI 2018	32
รูป 27 เปรียบเทียบจำนวนภาพต่อจำนวนรอยโรคบนชุดข้อมูล MICCAI 2017 กับ MICCAI 2018.	33
รูป 28 เปรียบเทียบจำนวนรอยโรคในหน่วยพิกเซลต่อภาพบนชุดข้อมูล MICCAI 2017 กับ MICCAI 2018.....	34
รูป 29 เปรียบเทียบจำนวนภาพต่อจำนวนรอยโรคจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017.....	35
รูป 30 เปรียบเทียบจำนวนรอยโรคในหน่วยพิกเซลต่อภาพจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017	36
รูป 31 เปรียบเทียบจำนวนภาพต่อจำนวนรอยโรคจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2018.....	37
รูป 32 เปรียบเทียบจำนวนรอยโรคในหน่วยพิกเซลต่อภาพจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2018	37

บทที่ 1


บทนำ

1.1 ที่มาและความสำคัญ


รอยโรคหลอดเลือดที่พบมากที่สุดที่สุดในระบบทางเดินอาหารคือโรคหลอดเลือดเจริญผิดปกติ (angiodyplasia) โรคนี้อาจไม่แสดงอาการ แต่อาจทำให้มีเลือดออกในทางเดินอาหาร [1] การส่องกล้องแคปซูลไร้สาย (wireless capsule endoscopy หรือ WCE) ในรูป 1 [2] เป็นเครื่องมือขนาดเล็กที่ใช้สำหรับจับภาพตามทางเดินอาหาร และภาพเหล่านั้นจะถูกส่งไปยังผู้เชี่ยวชาญสำหรับการวินิจฉัย การส่องกล้องแคปซูลไร้สายสามารถสร้างภาพจำนวนมากกว่า 50,000 ภาพสำหรับผู้ป่วยแต่ละราย [3] ขึ้นอยู่กับความเร็วในการประมวลผลภาพโดยวัดหน่วยเป็นภาพต่อวินาที (frame per second) ของตัวอุปกรณ์ [4] แพทย์อาจต้องใช้เวลาประมาณ 1 ชั่วโมงครึ่งเพื่อตรวจสอบผลการส่องกล้องในแต่ละครั้ง ตัวอย่างโรคหลอดเลือดเจริญผิดปกติจากกล้องแคปซูลแสดงในรูป 2

การแบ่งส่วนภาพ (image segmentation) เป็นวิธีการในการระบุตำแหน่งของวัตถุเป้าหมายที่กำหนดภายในภาพ ภาพแต่ละภาพสามารถถูกแบ่งออกเป็นส่วนต่าง ๆ ที่เรียกว่า “ส่วน” (segment) ได้ ซึ่งสามารถใช้ประโยชน์จากส่วนที่ถูกแบ่งนี้สำหรับการประมวลผลภาพเพื่อค้นหาวัตถุที่สนใจได้ การแบ่งส่วนภาพจะสร้างรูปร่างของวัตถุสำหรับแต่ละวัตถุในภาพ ทำให้เห็นรูปร่างของวัตถุได้ มีขั้นตอนวิธีมากมายสำหรับการแบ่งส่วนภาพเช่น การแบ่งส่วนบริเวณ (region-based) การแบ่งส่วนการตรวจจับเส้นเชื่อม (edge detection) การแบ่งส่วนการจับกลุ่ม (clustering-based) และการแบ่งส่วนการเรียนรู้เชิงลึก (deep learning-based)

วิธีการดั้งเดิมในการแบ่งส่วนภาพในทางวิสัยทัศน์คอมพิวเตอร์ที่พัฒนาขึ้นสำหรับโรคหลอดเลือดเจริญผิดปกติจากภาพที่ได้จากการส่องกล้องด้วยแคปซูลไร้สาย [5] เป็นวิธีการแบ่งส่วนบริเวณเพื่อค้นหาพื้นที่ที่น่าสนใจและจำแนกรอยโรคโดยใช้คุณสมบัติต่าง ๆ ในภาพ



รูป 1 โครงสร้างของแคปซูลไร้สาย [2] (ซ้าย) กล้องส่องลำไส้ใหญ่ [6] (ขวา)



รูป 2 ภาพตัวอย่างรอยโรคหลอดเลือดเจริญผิดปกติ [7] (ซ้าย) ภาพตัวอย่างรอยโรคติ่งเนื้อเมือก [8] (ขวา)

รูปแบบการแบ่งส่วนภาพบนพื้นฐานการเรียนรู้ในอดีตได้ถูกนำไปใช้งานโดยโครงข่ายประสาทเทียม (NN) ซึ่งมีประสิทธิภาพสูงกว่าการใช้วิธีวิสัยทัศน์คอมพิวเตอร์แบบดั้งเดิมในงานด้านภาพทางการแพทย์หลายงาน รวมถึงงานที่เกี่ยวข้องกับลำไส้ด้วย ตัวอย่างเช่นการใช้ U-Net [9] เป็นแบบจำลองการเรียนรู้เชิงลึกสำหรับงานการแบ่งส่วนภาพเซลล์ Attention U-Net [10] เป็นแบบจำลองการเรียนรู้เชิงลึกสำหรับงานการแบ่งส่วนภาพตับอ่อน และ Y-Net [11] เป็นแบบจำลองการเรียนรู้เชิงลึกสำหรับการแบ่งส่วนภาพติ่งเนื้อเมือก (polyp) ในรูป 2 ซึ่งมักใช้วิธีการส่องกล้องตรวจลำไส้ใหญ่ (colonoscopy) ด้วยกล้องส่องลำไส้ใหญ่ในรูป 1 โดยที่ในการวิจัยเหล่านั้นไม่ได้กล่าวถึงความสามารถในการแบ่งส่วนภาพที่ภาพนั้นไม่มีส่วนที่เป็นเป้าหมายภายในภาพ เช่น การนำแบบจำลอง U-Net ที่เรียนรู้การแบ่งส่วนภาพเซลล์ไปใช้แบ่งส่วนภาพที่ไม่ใช่ภาพเซลล์ การนำแบบจำลอง Attention U-Net ที่เรียนรู้การแบ่งส่วนภาพตับอ่อนไปใช้แบ่งส่วนภาพที่ไม่ใช่ตับอ่อน และการนำ Y-Net ที่เรียนรู้การแบ่งส่วนภาพติ่งเนื้อเมือกภายในลำไส้ไปใช้แบ่งส่วนภาพภายในลำไส้ที่ไม่มีติ่งเนื้อเมือก เป็นต้น ซึ่งหากมีการนำแบบจำลองดังกล่าวไปใช้งานจริงอาจทำให้เกิดค่าเท็จบวกต่อภาพเหล่านั้นจนนำไปใช้งานจริงไม่ได้

งานวิจัยก่อนหน้านี้ได้มีการเสนอแบบจำลองการแบ่งส่วนภาพสำหรับงานโรคเลือดออกในทางเดินอาหารส่วนล่างซึ่งในงานวิจัยนั้นได้เรียกแบบจำลองนั้นว่า “AlbuNet” [12] ซึ่งงานวิจัยนี้จะใช้แบบจำลองนี้เป็นแบบจำลองพื้นฐานเพื่อเปรียบเทียบวิธีที่งานวิจัยนั้นนำเสนอเนื่องจากแบบจำลองพื้นฐานนั้นมีประสิทธิภาพเหนือกว่าวิธีอื่น ๆ ในการแบ่งส่วนภาพโรคเลือดออกในทางเดินอาหารส่วนล่าง (lower gastrointestinal bleeding) ซึ่งในงานวิจัยนี้เองก็ไม่ได้กล่าวถึงการวัดผลกับภาพส่วนของทางเดินอาหารที่เป็นปกติ ทำให้ไม่มีผลที่แสดงให้เห็นว่าแบบจำลองสามารถทำงานได้ดีกับภาพที่ไม่มีความผิดปกติหรือไม่

นอกจากงานวิจัยข้างต้นที่เป็นงานวิจัยการแบ่งส่วน ยังมียานวิจัยที่ใช้แบบจำลองแบบหลายงาน (multi-task) ที่ถูกนำมาใช้ในการแบ่งส่วนรอยโรค เช่น การใช้ Faster R-CNN [13] ซึ่งเป็นโครงข่ายที่มีความสามารถในการตรวจจับวัตถุ (object detection) ร่วมกับการจำแนกประเภท (classification) ของวัตถุพร้อมกัน มาใช้ตรวจจับติ่งเนื้อเมือก การใช้ Mask R-CNN ซึ่งเป็นโครงข่ายที่มีความสามารถในการตรวจจับวัตถุ การจำแนกประเภทวัตถุ และการแบ่งส่วนวัตถุพร้อมกันได้ มาใช้ในการตรวจจับติ่งเนื้อเมือก เป็นต้น เพื่อให้สอดคล้องกับการปรับปรุงประสิทธิภาพของแบบจำลองให้สามารถจำแนกข้อมูลภาพที่มีรอยโรค และไม่มีรอยโรคได้ด้วย จึงได้มีการนำแนวคิดการทำงานแบบหลายงานเข้ามาประยุกต์ใช้งานกับแบบจำลองที่นำเสนอด้วย

ในงานวิจัยนี้จะเสนอวิธีการแก้ปัญหาด้วยการเรียนรู้เชิงลึกร่วมกับการประมวลผลภาพเบื้องต้นสำหรับการแบ่งส่วนภาพ โรคเลือดออกในทางเดินอาหารส่วนล่างจากภาพที่จับจากการส่องกล้องด้วยแคปซูลแบบไร้สาย โดยเพิ่มการวัดประสิทธิภาพของแบบจำลองด้วยการฝึกสอน และทดสอบด้วยข้อมูลที่ไม่มีรอยโรคร่วมด้วย โดยชุดข้อมูลในงานวิจัยนี้ใช้ในการวัดประสิทธิภาพของแบบจำลองคือชุดข้อมูลจาก MICCAI 2017 และ MICCAI 2018 [7, 14-16] เท่าที่ได้ได้ค้นคว้ามางานวิจัยนี้เป็นครั้งแรกที่ใช้ชุดข้อมูล MICCAI 2018 เป็นชุดข้อมูลสำหรับการวัดประสิทธิภาพ งานวิจัยนี้จึงจะนำเสนอผลลัพธ์ที่ได้จากชุดข้อมูลนี้เป็นผลลัพธ์พื้นฐานสำหรับนักวิจัยคนอื่น ๆ สำหรับเปรียบเทียบผลลัพธ์ต่อไปในอนาคต

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อนำเสนอวิธีการแบ่งส่วนภาพงานโรคหลอดเลือดเจริญผิดปกติ โดยใช้แบบจำลองการเรียนรู้เชิงลึกที่เป็นโครงข่ายตัวเข้ารหัสตัวถอดรหัสที่มีการเพิ่มประสิทธิภาพด้วยวิธีการหลากหลายเทคนิค เช่น การนำกลไกจุดสนใจ (attention mechanism) มาประยุกต์ใช้กับโครงข่าย การประมวลผลภาพ (image processing) จากภาพที่ได้จากกล้องแคปซูล และการเลือกฟังก์ชันสูญเสีย (loss function) ให้เหมาะสม เป็นต้น โดยมุ่งเน้นที่ประสิทธิภาพด้านความถูกต้องแม่นยำที่รวมถึงการตรวจจับภาพที่ปกติได้อย่างถูกต้องด้วย

1.3 ขอบเขตการวิจัย

1. งานวิจัยฉบับนี้ใช้ข้อมูลสาธารณะโรคหลอดเลือดเจริญผิดปกติจากงานแข่งขันรอง (sub-challenge) ของ MICCAI ปี 2017 และปี 2018 เพื่อใช้ในการฝึกสอน และวัดประสิทธิภาพของแบบจำลอง
2. ทำการวัดประสิทธิภาพของแบบจำลองจะเข้ามาตรวจวัดที่เหมาะสม และหลากหลายในการพิจารณา เช่น ค่า Dice coefficient, Jaccard index, Accuracy, Precision, Recall, F1 เป็นต้น
3. เปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกที่มีการนำเสนอมาก่อนในงานด้านการแบ่งส่วนภาพโรคหลอดเลือดเจริญผิดปกติโดยใช้ข้อมูลชุดเดียวกัน

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถเพิ่มประสิทธิภาพการแบ่งส่วนภาพในงานโรคหลอดเลือดเจริญผิดปกติได้
2. สามารถลดเวลาในการตรวจรอยโรคของโรคหลอดเลือดเจริญผิดปกติได้
3. สามารถนำกรอบงานวิจัยนี้ไปประยุกต์กับข้อมูลอื่น ๆ ที่มีลักษณะใกล้เคียงกันได้

1.5 ขั้นตอนการดำเนินงาน

1. ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง
2. ศึกษาเกี่ยวกับโครงข่ายประสาทเทียม และการเรียนรู้เชิงลึก
3. สร้างวิธีการทดลอง พัฒนาแบบจำลอง และเก็บผลการทดลอง
4. สรุปผลการทดลองทั้งหมด
5. สอบหัวข้อวิทยานิพนธ์

1.6 ผลงานวิจัยที่ตีพิมพ์

“Angiodysplasia Segmentation on Capsule Endoscopy Images Using AlbuNet with Squeeze-and-Excitation Blocks” โดย สิริชาติ กอบประดิษฐ์ และ พีรพล เวทีกุล ในงานประชุมวิชาการ “2020 12th Asian Conference on Intelligent Information and Database Systems (ACIIDS 2020)” ซึ่งจัดขึ้นโดยระบบออนไลน์ระหว่างวันที่ 23-25 มีนาคม 2563

“Combining Angiodysplasia Classification and Segmentation on Capsule Endoscopy Images Using Attentional AlbuNet” โดย สิริชาติ กอบประดิษฐ์ และ พีรพล เวทีกุล ในงานประชุมวิชาการ “2020 The 8th International Conference on Computer and Communications Management (ICCCM 2020)” ซึ่งจัดขึ้นโดยระบบออนไลน์ระหว่างวันที่ 17-19 กรกฎาคม 2563



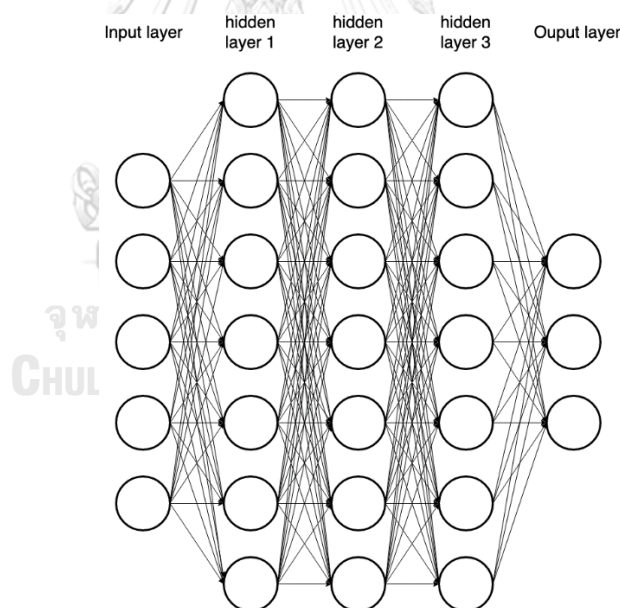
บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องกับงานวิจัยนี้แบ่งออกได้เป็น 6 หัวข้อ ได้แก่ โครงข่ายประสาทเทียมเชิงลึก โครงข่ายประสาทเทียมคอนโวลูชัน โครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัส กลไกจุดสนใจ การเติมแต่งภาพ และการประมวลผลภาพ

2.1 โครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network)

โครงข่ายประสาทเทียมเชิงลึกคือโครงข่ายประสาทเทียมที่มีจำนวนของชั้นซ่อน (hidden layer) จำนวนหลายชั้น ซึ่งแสดงอยู่ในรูป 3 หรือในบางครั้งอาจถูกเรียกว่าชั้นเชื่อมต่ออย่างเต็มที่ (fully connected layer) ซึ่งทำหน้าที่ในการสกัดคุณลักษณะของข้อมูลเพื่อผลลัพธ์บางอย่าง เช่น การหาคุณลักษณะจำเพาะของข้อมูล การแบ่งประเภท การแบ่งส่วน เป็นต้น โดยโครงข่ายประสาทเทียมเชิงลึกที่มีรู้จักกันโดยทั่วไปคือโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network หรือ RNN) กับ โครงข่ายประสาทเทียมคอนโวลูชัน (Convolution Neural Network หรือ CNN) ซึ่งในงานวิจัยนี้จะนำส่วนประกอบของโครงข่ายประสาทเทียมคอนโวลูชันมาใช้เป็นส่วนหลักของเครือข่ายเพื่อสร้างแบบจำลองที่ใช้ในงานวิจัย

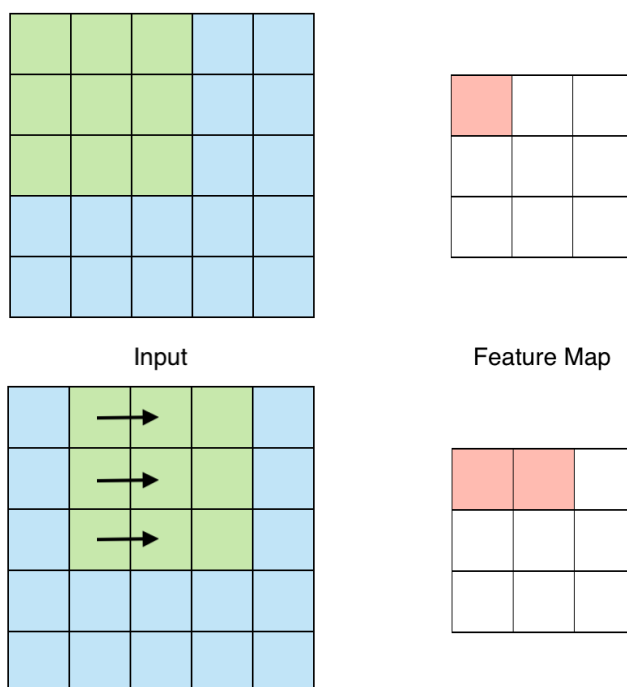


รูป 3 โครงข่ายประสาทเทียมเชิงลึก

2.2 โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional Neural Network หรือ CNN)


โครงข่ายประสาทเทียมคอนโวลูชันคือโครงข่ายประสาทเทียมที่มีชั้นคอนโวลูชัน (convolution layer) เป็นส่วนประกอบหลักในเครือข่ายมักใช้กับข้อมูลนำเข้าที่เป็นภาพเนื่องจากชั้นคอนโวลูชันมีตัวกรอง (filter) ขนาดเมตริกซึ่งสามารถหาความสัมพันธ์แบบพื้นที่ได้ทำให้สามารถสกัดคุณลักษณะของข้อมูลที่เป็นรูปภาพที่ลักษณะของข้อมูลมีความสัมพันธ์กับข้อมูลรอบข้างสูงเมื่อเทียบกับข้อมูลประเภทอื่น แต่ถึงอย่างนั้นก็ได้มีการนำชั้นคอนโวลูชันไปประยุกต์ใช้ในงานอื่นที่ข้อมูลไม่ได้เป็นรูปภาพแต่ต้องการหาความสัมพันธ์แบบพื้นที่กับข้อมูลอยู่เช่นกัน

ส่วนประกอบหลักของชั้นคอนโวลูชันคือตัวกรอง หรือเคอร์เนล (kernel) ซึ่งผู้ใช้ต้องเป็นผู้ระบุขนาดเพื่อให้ชั้นคอนโวลูชันเลื่อนตัวกรองสำหรับใช้สร้างฟังก์ชันลักษณะ (feature map) จากข้อมูลนำเข้าดังตัวอย่างในรูป 4 โดยนอกจากขนาดของตัวกรองแล้วยังต้องกำหนดค่าที่สำคัญอีกสองอย่างคือก้าวย่าง (stride) และการเสริมเติม (padding) โดยที่ก้าวย่างคือขนาดการขยับของตัวกรองว่าจะต้องขยับตัวกรองไปที่ช่อง ส่วนการเสริมเติมคือการเสริมเติมขอบของข้อมูลนำเข้าโดยมักจะเติมด้วยค่าศูนย์ โดยอาจจะทำเพื่อให้ตัวกรองสามารถเลื่อนประอบข้อมูลนำเข้าได้พอดี



รูป 4 การขยับของตัวกรองเพื่อสร้างฟังก์ชันลักษณะ

ส่วนสำคัญอีกส่วนในโครงข่ายประสาทเทียมคอนโวลูชันคือการทำการรวมกัน (pooling) ซึ่งโดยปกติมักจะเลือกใช้การรวมกันด้วยค่าสูงสุด (max pooling) ที่แสดงอยู่ในรูป 5 หรือการรวมกันด้วยค่ากลาง (average pooling) ซึ่งการรวมกันเป็นการย่อขนาดของข้อมูลเพื่อทำให้สามารถมองข้อมูลในขนาดที่เปลี่ยนไปสำหรับค้นหาคุณลักษณะของข้อมูลได้โดยไม่ตัดส่วนของข้อมูลทิ้งไปเฉย ๆ แต่เลือกคุณลักษณะบางประการที่น่าจะเป็นค่าที่เหมาะสมเก็บไว้โดยขึ้นกับวิธีการเลือกการรวมกัน




รูป 5 การรวมกันด้วยค่าสูงสุด

2.3 โครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัส (Encoder-Decoder Neural Network)

โครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัสคือโครงข่ายประสาทเทียมที่ประกอบไปด้วยสองส่วนหลักคือตัวเข้ารหัส (encoder) และ ตัวถอดรหัส (decoder) ดังรูป 6 โดยเป็นเครือข่ายที่สร้างแบบจำลองที่ขนาดของข้อมูลขาออกมีขนาดเท่ากับขนาดข้อมูลขาเข้า

ตัวเข้ารหัสในโครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัสจะทำหน้าที่เข้ารหัสข้อมูลขาเข้าให้มีขนาดเล็กลงก่อนในครั้งแรกของเครือข่าย แล้วจึงจะส่งต่อให้ส่วนตัวถอดรหัสที่จะทำหน้าที่ขยายข้อมูลกลับมาให้มีขนาดเท่าเดิมในครั้งหลังของเครือข่ายโดยผลลัพธ์ที่ได้จะเป็นไปตามข้อมูลที่ถูกลำมาใช้ฝึกกับเครือข่ายนั้น ๆ เพื่อให้ได้แบบจำลองที่ต้องการสำหรับงานใดงานหนึ่ง โดยในงานวิจัยนี้ได้เลือกใช้โครงสร้างโครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัสเพื่อใช้ในการแบ่งส่วนภาพวัตถุที่สนใจภายในภาพ



รูป 6 โครงข่ายประสาทเทียมตัวเข้ารหัสตัวถอดรหัส

2.4 กลไกจุดสนใจ (Attention Mechanism)

กลไกจุดสนใจคือการหาค่าน้ำหนักให้กับข้อมูลซึ่งมีวิธีการทำได้หลายวิธี การเลือกกลไกจุดสนใจใดมาใช้ อาจต้องทดสอบกับเครือข่ายที่กำลังออกแบบอยู่เพื่อให้เกิดประสิทธิภาพสูงสุด โดยการทำกลไกจุดสนใจอาจจะทำได้ โดยการนำข้อมูลผ่านฟังก์ชัน softmax เพื่อหาค่าน้ำหนักของข้อมูลแต่ละค่าแล้วนำมาคูณกลับข้อมูลเพื่อปรับค่าของ ข้อมูลให้ค่าที่น่าสนใจหรือค่าที่สำคัญโดดเด่นขึ้นมาจากข้อมูลเดิม และส่งผ่านไปภายในเครือข่ายโดยค่าที่สำคัญ นั้นไม่สูญหายไประหว่างการคำนวณภายในเครือข่าย นอกจากนี้ฟังก์ชันข้างต้นแล้วยังมีงานวิจัยอื่น ๆ ที่เลือกใช้วิธีการ หาค่าน้ำหนักด้วยวิธีที่แตกต่างกันออกไปโดยอาจมุ่งเน้นไปที่สร้างกลไกจุดสนใจให้เป็นวิธีการที่เหมาะสมกับการใช้งาน ทั่วไป หรือเหมาะกับงานเฉพาะทางบางอย่าง โดยทั่วไปแล้วการเพิ่มกลไกจุดสนใจให้กับเครือข่ายที่ยังไม่มีกลไกจุด สนใจมักช่วยเพิ่มประสิทธิภาพให้กับเครือข่ายได้ ซึ่งพิสูจน์จากการวิจัยหลายงานทั้งในงานวิจัยด้านภาษาที่ใช้ โครงข่ายประสาทเทียมวกกลับ และงานวิจัยทางด้านภาพที่ใช้โครงข่ายประสาทเทียมคอนโวลูชัน โดยในงานวิจัยนี้ ได้เลือกใช้วิธีกลไกจุดสนใจรูปแบบหนึ่งที่จะอธิบายเพิ่มเติมในส่วนงานวิจัยที่เกี่ยวข้อง

2.5 การแต่งเติมภาพ (Image Augmentation)

การแต่งเติมภาพคือการแก้ไขภาพดั้งเดิมให้ต่างไปจากภาพดั้งเดิม หรือในทางปฏิบัติคือการเพิ่ม จำนวนรูปเพื่อใช้ในการฝึกสอนแบบจำลอง เนื่องจากประสิทธิภาพของแบบจำลองขึ้นอยู่กับปริมาณของข้อมูล ค่อนข้างมาก การแต่งเติมภาพนี้จะสามารถช่วยลดปัญหาความพอดีเกิน (overfitting) กับชุดข้อมูลได้ซึ่งเป็นปัญหา สำคัญกับแบบจำลองที่มีปริมาณข้อมูลการฝึกสอนที่มีจำนวนน้อยโดยวิธีทั่วไปที่นิยมทำมีตัวอย่างเช่น การบิด การ ตัด การหมุน การเปลี่ยนสี การปรับแสง การใส่คาร์บวอน เป็นต้น ตัวอย่างแสดงในรูป 7 ซึ่งในงานวิจัยนี้ได้้นำการ แต่งเติมภาพมาใช้เพื่อเพิ่มปริมาณข้อมูลซึ่งมีทั้ง การบิด การหมุน การเปลี่ยนสี และการปรับแสง มาใช้




รูป 7 ตัวอย่างการแต่งเติมภาพจาก [17]

2.6 การประมวลผลภาพ (Image processing)

การประมวลผลภาพคือการนำภาพมาปรับปรุงเพื่อให้ได้ภาพที่ต้องการด้วยวิธีการต่าง ๆ โดยส่วนมากมักทำเพื่อให้ภาพมีคุณภาพที่ดีขึ้น มีความคมชัดมากขึ้น หรือกำจัดสัญญาณรบกวนภายในภาพออกไป รวมไปถึงวิธีการแบ่งส่วนภาพวัตถุที่สนใจออกมาจากภาพเพื่อใช้สำหรับวิเคราะห์สำหรับใช้งานต่าง ๆ โดยวิธีที่ใช้ในงานวิจัยนี้เป็นวิธีการปรับความชัดของภาพด้วยการทำ Contrast Limited Adaptive Histogram Equalizer (CLAHE) ในกระบวนการประมวลผลภาพเบื้องต้น และจะทดสอบวิธีการอื่น ๆ เช่น วอเตอร์เชด (watershed) การขีดแบ่งไบนารี (binary threshold) การขีดแบ่งโอสุ (Otsu's threshold) เป็นต้น ต่อไป

CLAHE เป็นวิธีการที่พัฒนามาจาก Adaptive Histogram Equalizer (AHE) ซึ่งมีการขยายความคมชัดมีแบบจำกัด CLAHE ทำงานด้วยการแบ่งภาพออกเป็นส่วนด้วยค่าขนาดที่ระบุ โดยจะคำนวณค่าการแปลงความคมชัดสำหรับแต่ละส่วนแยกกัน และใช้ค่าความคมชัดจำกัดในการจำกัดการปรับค่าความคมชัด ตัวอย่างในรูป 8 โดยในการพัฒนาแบบจำลองนิยมแบ่งการประมวลผลภาพออกเป็นสองช่วงในการประมวลผลภาพดังนี้

- 1) การประมวลผลภาพเบื้องต้น (Image pre-processing) คือการปรับปรุงภาพก่อนที่จะนำข้อมูลภาพเข้าสู่เครือข่าย
- 2) การประมวลผลภาพภายหลัง (Image post-processing) คือการปรับปรุงภาพหลังจากที่ได้ผลลัพธ์จากเครือข่ายแล้ว



รูป 8 ตัวอย่างภาพต้นฉบับการภาพหลังการทำ CLAHE

[ที่มา [https://opencv-python-](https://opencv-python-tutroals.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_histograms/py_histogram_equalization/py_histogram_equalization.html)

[tutroals.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_histograms/py_histogram_equalization/py_histogram_equalization.html](https://opencv-python-tutroals.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_histograms/py_histogram_equalization/py_histogram_equalization.html) Accessed: November 6, 2019]


บทที่ 3

งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์ฉบับนี้คืองานวิจัยที่แบ่งส่วนภาพ โดยใช้แบบจำลองการเรียนรู้เชิงลึก และวิสัยทัศน์คอมพิวเตอร์ งานวิจัยแต่ละงานจะมีโครงสร้างแบบจำลอง และวิธีที่แตกต่างกัน ซึ่งจะนำเสนอด้วยตารางเรียงลำดับจากปีที่งานวิจัยถูกเผยแพร่

ก่อนที่จะเริ่มกล่าวถึงเกี่ยวกับแบบจำลองในงานที่เกี่ยวข้องกับทางเดินอาหารโดยตรง ผู้เขียนจะแนะนำรูปแบบการเรียนรู้เชิงลึกแบบดั้งเดิมที่ใช้เป็นแบบจำลองพื้นฐานในงานทางการแพทย์จำนวนมากในอดีตก่อน จากความโด่งดังในงานแข่งขัน ImageNet ในปีค.ศ. 2012 [18] แบบจำลองการเรียนรู้เชิงลึกเริ่มแพร่หลายและเป็นที่นิยมมากขึ้น

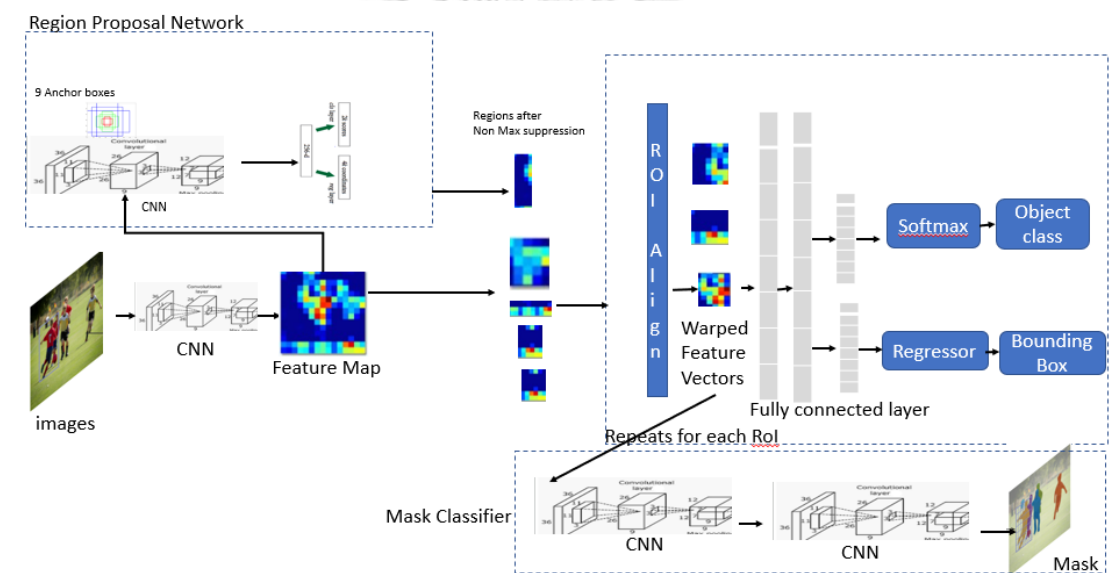
ในปีค.ศ. 2015 [9] ได้นำเสนอแบบจำลอง U-Net ซึ่งเป็นรูปแบบการเรียนรู้เชิงลึกสำหรับการแบ่งส่วนภาพทางชีวการแพทย์ แบบจำลอง U-Net แสดงอยู่ในรูป 9 แบบจำลองนี้มีการใช้ชั้นคอนโวลูชันในการเทียบคุณลักษณะแบบหลายแชนเนล แบบจำลองนี้ประกอบด้วยสองส่วน ส่วนแรกคือส่วนที่ลดขนาดของคุณลักษณะ และส่วนที่สองคือส่วนที่เพิ่มขนาดของคุณลักษณะ มักเรียกส่วนแรก และส่วนที่สองว่า "ตัวเข้ารหัส" และ "ตัวถอดรหัส" ตามลำดับ แบบจำลองมีเส้นเชื่อมระหว่างตัวเข้ารหัส และตัวถอดรหัสเพื่อให้ข้อมูลไหลเชื่อมต่อกัน แบบจำลองนี้ถูกสร้างขึ้นเพื่อใช้ในงานแบ่งส่วนภาพของเซลล์ในงานแข่งขัน ISBI (International Symposium Biomedical Imaging) ซึ่งแบบจำลองนี้ได้ให้ผลลัพธ์ที่ดีที่สุดเมื่อเปรียบเทียบกับแบบจำลองอื่นที่นำมาใช้เปรียบเทียบในงานวิจัย



รูป 9 แบบจำลอง U-Net [9]

ในปีค.ศ. 2017 [5] ได้นำเสนอระบบสำหรับการตรวจหารอยโรคของโรคหลอดเลือดเจริญผิดปกติแบบอัตโนมัติจากภาพที่ถ่ายได้จากการส่องกล้องด้วยกล้องแคปซูลแบบไร้สาย ในงานวิจัยได้ใช้การประมวลผลภาพเบื้องต้นในการเลือกพื้นที่ที่เป็นบริเวณที่น่าสนใจ และใช้การสกัด และการคัดเลือกคุณสมบัติในการจำแนกประเภทของพื้นที่ที่น่าสนใจด้วยวิธีการตัดสินใจแบบการแบ่งประเภทเพื่อตรวจหารอยโรคของโรคหลอดเลือดเจริญผิดปกติ วิธีการประมวลผลภาพเบื้องต้นที่ใช้ในงานนี้คือการทำ Histogram Equalizer (HE) Contrast Limited Adaptive Histogram Equalizer (CLAHE) [19] และการทำ RGB decorrelation stretch

ในปีค.ศ. 2017 [20] ได้เสนอแบบจำลอง Mask R-CNN ที่สามารถสร้างกล่องล้อมรอบวัตถุที่สนใจ จำแนกประเภทของวัตถุนั้น และแบ่งส่วนวัตถุนั้นได้พร้อมกัน ตัวอย่างการทำงานของ Mask R-CNN แสดงอยู่ในรูป 10 ซึ่งแบบจำลองนี้ได้ถูกพัฒนามาจากแบบจำลองตระกูล R-CNN [21-23] โดยเริ่มจากแบบจำลอง R-CNN ที่ตอนแรกนั้นสามารถสร้างกล่องล้อมรอบวัตถุ และจำแนกประเภทวัตถุนั้นได้เท่านั้น การใช้งาน Mask R-CNN ส่วนใหญ่มักถูกนำไปใช้ในการตรวจจบบั้ววัตถุทั่วไปในชีวิตประจำวัน เช่น รถยนต์ ผู้คน หมา แมว เป็นต้น อย่างไรก็ตามแบบจำลองตระกูลนี้ได้ถูกนำไปใช้ในงานทางการแพทย์และได้ผลลัพธ์ที่ดีเช่นกัน [24-26]



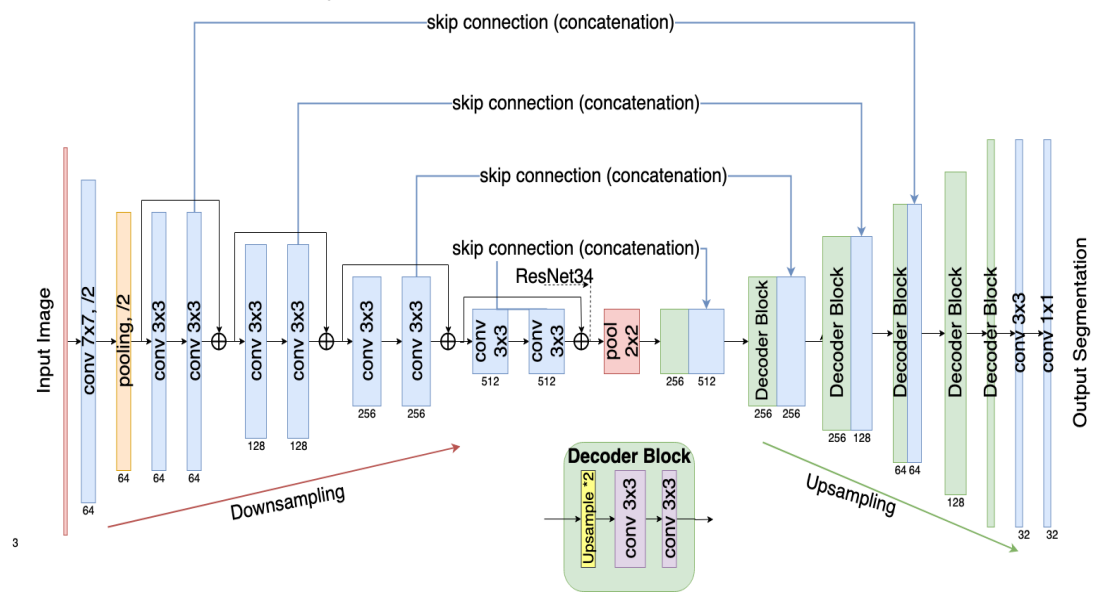
รูป 10 ตัวอย่างโครงสร้างโดยรวมของ Mask R-CNN

[ที่มา <https://towardsdatascience.com/computer-vision-instance-segmentation-with-mask-r-cnn-7983502fcad1> Accessed: April 23, 2020]

ในปีค.ศ. 2018 [27] ได้เสนอแบบจำลอง TerausNet-11 ซึ่งเป็นการดัดแปลงแบบจำลอง U-Net ซึ่งใช้ค่าน้ำหนักของชั้นในแบบจำลอง VGG ที่ผ่านการฝึกสอนมาก่อน [28] โดยค่าน้ำหนักที่ได้จากงานอื่น ๆ สามารถนำมาใช้เป็นค่าเริ่มต้นน้ำหนักของแบบจำลองใหม่เพื่อปรับปรุงประสิทธิภาพของแบบจำลองได้ [29] โดยที่น้ำหนักที่ผ่านการฝึกสอนมาล่วงหน้าที่ใช้ในงานวิจัยนำมาจากการฝึกสอนชุดข้อมูล ImageNet และ Carvana ในงานวิจัยได้เปรียบเทียบสามแบบจำลอง: 1) ไม่มีค่าน้ำหนักที่ผ่านการฝึกสอนมา 2) มีค่าน้ำหนักที่ได้รับการฝึกสอนมาแล้วจากชุดข้อมูล ImageNet และ 3) ค่าน้ำหนักที่ได้รับการฝึกสอนมาแล้วจากชุดข้อมูล Carvana ผลการวิจัยพบว่าการ


ใช้ค่าน้ำหนักที่ผ่านการฝึกสอนมาแล้วจากทั้งชุดข้อมูล ImageNet หรือ Carvana ให้ผลลัพธ์ที่ดีกว่าแบบจำลองที่ไม่มีค่าน้ำหนักที่ฝึกสอนมาก่อน

ในปีค.ศ. 2018 [12] ได้เสนอรูปแบบการเรียนรู้เชิงลึกเพื่อหารอยโรคของโรคหลอดเลือดเจริญผิดปกติ งานวิจัยใช้การดัดแปลงแบบจำลอง U-Net ด้วยการใช้ตัวเข้ารหัส ResNet-34 [30] ที่ได้รับการฝึกสอนมาก่อนซึ่งเรียกว่า AlbuNet แบบจำลอง AlbuNet แสดงอยู่ในรูป 11 โดยการทดสอบประสิทธิภาพได้วัดประสิทธิภาพบนชุดข้อมูล MICCAI 2017 งานวิจัยได้เปรียบเทียบแบบจำลองที่ได้นำเสนอในรูป 11 กับแบบจำลองแบบอื่นเพื่อแสดงว่าให้เห็นว่าแบบจำลองที่นำเสนอขึ้นดีกว่าแบบจำลองอื่น โดยที่แบบจำลองอื่นที่ใช้ในการเปรียบเทียบ ได้แก่ U-Net TernausNet-11 และ TernausNet-16 ผลการวิจัยพบว่า AlbuNet มีประสิทธิภาพสูงสุดสำหรับงานแบ่งภาพเพื่อหารอยโรคของโรคหลอดเลือดเจริญผิดปกติ



รูป 11 แบบจำลอง AlbuNet [12]

ในปีค.ศ. 2018 [31] ได้นำเสนอโมดูล Squeeze-and-excitation (SE) ซึ่งเป็นแนวคิดของกลไกจุดสนใจ [32] โดยการสร้างประตูจุดสนใจ (attention gate) ที่หาค่าน้ำหนักของข้อมูลที่ผ่านมาด้วยการใช้ชั้น Dense และนำมาคูณกลับให้แก่ตัวข้อมูลเพื่อเพิ่มค่าน้ำหนักข้อมูลให้มีจุดแตกต่างกันมากขึ้น ข้อมูลที่สำคัญจะเป็นข้อมูลที่มีค่าน้ำหนักสูงกว่า และเมื่อคูณกลับเข้าไปยังข้อมูลเดิมจะทำให้ค่าของข้อมูลเด่นออกมาโดยคาดหวังว่าค่าที่เด่นขึ้นมา นั้นจะเป็นค่าที่มีความสำคัญ โมดูล SE แสดงอยู่ในรูป 12 ผลการวิจัยพบว่าแบบจำลองที่รวมกับวิธี SE นั้นให้ประสิทธิภาพดีกว่าแบบจำลองแบบดั้งเดิมที่ไม่มีการใช้วิธี SE



รูป 12 ตัวอย่างโครงสร้างโมดูล Squeeze-and-excitation [31]

บทที่ 4

แนวคิดและแบบจำลองที่นำเสนอ

งานวิจัยนี้จะทำการสร้างแบบจำลองเพื่อแบ่งส่วนภาพเพื่อค้นหารอยโรคที่ปรากฏภายในภาพ โดยการนำงานวิจัย [12] มาปรับปรุงโดยใช้กลไกจุดสนใจ และการประมวลผลภาพ จากนั้นจึงต่อยอดแบบจำลองด้วยการสร้างแบบจำลองเรียงซ้อน และแบบจำลองร่วมกัน โดยเล็งเห็นถึงข้อดี และข้อเสียในแต่ละรูปแบบของแบบจำลอง จึงได้เลือกแบบจำลองทั้งสองรูปแบบมาเพื่อทดสอบ และประเมินประสิทธิภาพ

4.1 การเตรียมข้อมูล (Data preparation)

เนื่องจากชุดข้อมูลเป็นข้อมูลที่เกี่ยวข้องกับบุคคลซึ่งอาจนำไปสู่ปัญหาด้านความเป็นส่วนตัวได้ ถึงแม้จะเป็นชุดข้อมูลที่มาจากงานแข่งขันก็ตาม ดังนั้นก่อนที่จะได้รับชุดข้อมูลที่ใช้ในงานวิจัยนี้จึงต้องสมัครเข้าร่วมกับทางผู้จัดการแข่งขันก่อน รวมถึงลงชื่อตามเอกสารข้อตกลงที่ทางผู้จัดได้จัดทำไว้ด้วย ซึ่งหลังจากทำตามขั้นตอนที่ทางผู้จัดระบุไว้ จึงจะมีสิทธิ์เข้าถึงชุดข้อมูลได้ ซึ่งรายละเอียดสามารถตรวจสอบได้จาก [7, 14]

ชุดข้อมูลสำหรับใช้ฝึกสอนที่ได้รับมาหลังจากผ่านขั้นตอนข้างต้น จะได้รับเป็นไฟล์รูปภาพนามสกุล .jpg และ .png โดยที่รูปจะถูกแยกตามประเภท คือ ประเภทปกติ และประเภทหลุดเลือดเจริญผิดปกติ

ปัญหาที่พบเล็กน้อยคือภาพบางภาพนั้นอาจจะมีนามสกุลที่เป็นตัวพิมพ์ใหญ่ และบางภาพมีขนาดไม่เท่ากับรูปอื่นที่โดยปกติแล้วจะมีขนาด 576x576 พิกเซล แต่บางภาพมีขนาดที่ใหญ่กว่านั้น รวมถึงการที่ภาพผลเฉลยรวมอยู่กับภาพต้นฉบับโดยใช้วิธีการแยกภาพว่าภาพใดเป็นภาพผลเฉลยจากชื่อของไฟล์ภาพคือมี “_a” ต่อท้ายชื่อไฟล์ดั้งเดิม เมื่อรวมปัญหาทั้งหมดแล้ว หากไม่มีการเตรียมข้อมูลก่อนจะทำให้มีปัญหาตอนฝึกสอนแบบจำลองได้ หรือทำให้การฝึกสอนแบบจำลองมีความยุ่งยากเพิ่มขึ้นโดยไม่จำเป็น

การแก้ปัญหาข้างต้นในส่วนของตัวพิมพ์นามสกุลไฟล์สามารถใช้คำสั่งของเครื่องแก้ไขได้โดยสำหรับเครื่องระบบปฏิบัติการลินุกซ์ที่ใช้เป็นเครื่องที่ทำการทดลองนั้นสามารถใช้คำสั่ง rename ได้ เช่น rename "s/JPG/jpg/" *.JPG เป็นต้น โดยคำสั่งนี้จะเป็นคำสั่งเพื่อแก้ไขชื่อไฟล์ที่มีนามสกุล .JPG ทั้งหมดที่มีค่า JPG อยู่ในชื่อไฟล์ให้กลายเป็น jpg และในส่วนของการบันทึกของไฟล์ต้นฉบับและไฟล์ผลเฉลยสามารถจัดแยกตามใดเรกทอรีได้ด้วยวิธีการย้ายไฟล์ด้วยคำสั่ง mv *_a.jpg masks/ เพื่อย้ายไฟล์ผลเฉลยแยกกับไฟล์ต้นฉบับซึ่งจะทำให้ง่ายในการฝึกสอนแบบจำลองมากขึ้น สุดท้ายในส่วนของการปรับขนาดไฟล์ที่ไม่เท่ากันสามารถแก้ไขด้วยการเขียนคำสั่ง resize เพื่อแก้ไขขนาดของข้อมูลเข้าเพื่อให้มีขนาดเท่ากันหมดได้

ในกรณีที่มีการใช้ข้อมูลภาพทั้งหมดที่มีรอยโรค และไม่มีรอยโรคในขั้นตอนการฝึกสอน จะต้องมีการเพิ่มข้อมูลกำหนดประเภทของภาพเพื่อกำหนดว่าภาพใดเป็นภาพที่มีรอยโรค และภาพใดเป็นภาพที่ไม่มีรอยโรค ซึ่งการกำหนดประเภทของภาพนั้นสามารถตรวจสอบได้จากภาพผลเฉลยของภาพนั้น ๆ ว่ามีพิกเซลสีขาวหรือไม่ หากมีพิกเซลสีขาวก็จะกำหนดให้ภาพนั้นเป็นภาพที่มีรอยโรค และหากภาพใดไม่มีพิกเซลสีขาวในผลเฉลยก็จะกำหนดให้ภาพนั้นเป็นภาพที่ไม่มีรอยโรค โดยกำหนดให้ภาพที่มีรอยโรคมีเลขกำกับด้วย 1 และภาพที่ไม่มีรอยโรคมีเลขกำกับด้วย 0 เพื่อให้สะดวกในการสอน

4.2 ชุดข้อมูล (Dataset)


งานวิจัยนี้ใช้ชุดข้อมูล 2 ชุดที่เกี่ยวข้องกับโรคหลอดเลือดเจริญผิดปกติโดยแบ่งชุดข้อมูลที่ได้จากงานแข่งขันตามปีการจัดการแข่งขันดังนี้

4.2.1. MICCAI 2017 Endoscopic Vision Challenge: Sub-Challenge Gastrointestinal Image Analysis (GIANA): Angiodysplasia localization

ชุดข้อมูลนี้เป็นชุดข้อมูลที่รวบรวมภาพที่เกี่ยวข้องกับโรคหลอดเลือดเจริญผิดปกติที่มีขนาด 576x576 พิกเซล มีทั้งหมด 599 ภาพ ภาพถูกแบ่งออกเป็น 299 ภาพที่มีรอยโรคและ 300 ภาพที่ไม่มีรอยโรค ซึ่งจะใช้เฉพาะภาพที่มีรอยโรคเท่านั้นเพื่อฝึกสอนแบบจำลองสำหรับการทดลองเบื้องต้น และจะใช้ภาพทั้งหมดที่มีทั้งรอยโรคและไม่มีรอยโรคในการทดลองถัดไป ภาพตัวอย่างในชุดข้อมูลที่มีรอยโรคแสดงในรูป 13 และภาพตัวอย่างในชุดข้อมูลที่ไม่มีรอยโรคแสดงในรูป 14

4.2.2. MICCAI 2018 Endoscopic Vision Challenge: Sub-Challenge Gastrointestinal Image Analysis (GIANA): Angiodysplasia localization

ชุดข้อมูลนี้เป็นชุดข้อมูลที่รวบรวมภาพที่เกี่ยวข้องกับโรคหลอดเลือดเจริญผิดปกติที่มีขนาด 576x576 พิกเซล มีทั้งหมด 1,812 ภาพรวมภาพผลเฉลย ภาพถูกแบ่งออกเป็น 1,212 ภาพที่มีรอยโรคและ 600 ภาพที่ไม่มีรอยโรค สำหรับภาพที่มีรอยโรคนั้นแบ่งออกเป็นสองประเภท 1) การอักเสบ (inflammatory) 2) หลอดเลือด (vascular) ซึ่งจะใช้เฉพาะภาพที่มีรอยโรคเท่านั้นเพื่อฝึกสอนแบบจำลองสำหรับการทดลองเบื้องต้น และจะใช้ภาพทั้งหมดที่มีทั้งรอยโรคและไม่มีรอยโรคในการทดลองถัดไป ภาพตัวอย่างในชุดข้อมูลที่มีรอยโรคแสดงในรูป 13 และภาพตัวอย่างในชุดข้อมูลที่ไม่มีรอยโรคแสดงในรูป 14



รูป 13 ตัวอย่างภาพจากชุดข้อมูลที่มีรอยโรค MICCAI 2017 (บน) และ MICCAI 2018 (ล่าง)



รูป 14 ตัวอย่างภาพจากชุดข้อมูลที่ไม่มีรอยโรค MICCAI 2017 (บน) และ MICCAI 2018 (ล่าง)

4.3 การวัดผล (Evaluation)

การวัดผลจะแบ่งมาตรวัดออกเป็นสองส่วนคือมาตรวัดสำหรับงานแบ่งส่วน และมาตรวัดสำหรับงานจำแนกประเภท มาตรวัดสำหรับงานแบ่งส่วนจะใช้ค่า Dice coefficient (Dice) และ Jaccard index หรือ Intersect over union (IoU) ซึ่งเป็นตัวชี้วัดเดียวกับที่ใช้ในงานวิจัย [12] เพื่อวัดประสิทธิภาพของแบบจำลองเปรียบเทียบแบบจำลองต่าง ๆ โดยมาตรวัดดังกล่าวเป็นมาตรวัดที่ใช้สำหรับตรวจวัดการทับซ้อนกัน (overlap) ระหว่างผลที่ได้จากการทำนายกับผลเฉลย สมการทั้งสองนี้มีความใกล้เคียงกันและให้ผลลัพธ์ไปในทิศทางเดียวกัน แต่สมการ Dice มีแนวโน้มให้ค่าเป็นค่าใกล้เคียงผลเฉลี่ย (average) ในขณะที่สมการ IoU มีแนวโน้มให้ค่าเป็นค่าใกล้เคียงกรณีเลวร้ายที่สุด (worst case) สมการ Dice ถูกแสดงในสมการ (1) และ (2) สมการ IoU แสดงในสมการ (3) และ (4) และมาตรวัดสำหรับงานจำแนกประเภทจะใช้ค่า Accuracy Precision Recall และ F1 ซึ่งเป็นตัวชี้วัดที่เป็นมาตรฐานสำหรับงานจำแนกประเภทในการวัดประสิทธิภาพแบบจำลอง สมการค่า Accuracy Precision Recall และ F1 แสดงในสมการที่ (5) (6) (7) และ (8) ตามลำดับ โดยกำหนดตัวแปร TP เป็นค่าบวกจริง (true positive) FP เป็นค่าบวกเท็จ (false positive) TN เป็นค่าลบจริง (true negative) และ FN เป็นค่าลบเท็จ (false negative) ซึ่งค่าบวกจริงหมายถึงผลทำนายที่ได้ออกมาเป็นประเภทบวกและประเภทที่แท้จริงก็เป็นบวก ค่าบวกเท็จหมายถึงผลทำนายที่ได้ออกมาเป็นประเภทบวกแต่ประเภทที่แท้จริงเป็นลบ ค่าลบจริงหมายถึงผลทำนายที่ได้ออกมาเป็นประเภทลบและประเภทที่แท้จริงก็เป็นลบ ค่าลบเท็จหมายถึงผลทำนายที่ได้ออกมาเป็นประเภทลบแต่ประเภทที่แท้จริงเป็นบวก

ในการทดลองเบื้องต้นที่ใช้แบบจำลองแบ่งส่วนเพียงอย่างเดียวจะใช้มาตรวัดสำหรับงานแบ่งส่วนเพื่อวัดประสิทธิภาพแบบจำลองต่าง ๆ และในการทดลองถัดไปจะใช้มาตรวัดสำหรับงานจำแนกประเภท และงานจำแนกประเภทร่วมกัน

หากกำหนดให้มีเซต A และ B จะได้สมการ Dice ดังนี้

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \quad (1)$$

เมื่อนำไปใช้กับข้อมูลแบบไบนารี จะได้สมการ Dice ดังนี้

$$Dice = \frac{2TP}{2TP + FP + FN} \quad (2)$$

หากกำหนดให้มีเซต A และ B จะได้สมการ IoU ดังนี้

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (3)$$

เมื่อนำไปใช้กับข้อมูลแบบไบนารี จะได้สมการ IoU ดังนี้

$$IoU = \frac{TP}{TP + FP + FN} \quad (4)$$

สมการค่า Accuracy สามารถแสดงได้ดังนี้

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (5)$$

สมการค่า Precision สามารถแสดงได้ดังนี้

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

สมการค่า Recall สามารถแสดงได้ดังนี้

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

สมการค่า F1 สามารถแสดงได้ดังนี้

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

4.4 ฟังก์ชันสูญเสีย (Loss function)

งานวิจัยนี้จะใช้ฟังก์ชันสูญเสียแบบเดียวกันกับ [12] สำหรับแบบจำลองเบื้องต้นโดยฟังก์ชันการสูญเสียที่ใช้คือการรวมกันของฟังก์ชัน binary cross entropy และฟังก์ชันแจคคาร์ตจากงานวิจัย [33] สมการ binary cross entropy ถูกแสดงในสมการ (9) กับ (10) และสมการฟังก์ชันสูญเสียที่ใช้ในงานวิจัยแสดงในสมการ (11) ซึ่งเป็นฟังก์ชันสูญเสียเดี่ยว และในการทดลองถัดไปจะใช้ฟังก์ชันสูญเสียที่แสดงในสมการที่ (12) (13) และ (14) สมการของฟังก์ชัน binary cross entropy ถูกกำหนดดังนี้

$$H = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (9)$$

ฟังก์ชันที่ปรับให้เหมาะสมกับวัตถุที่ไม่ต่อเนื่องสำหรับพิกเซลในภาพจากสมการ (3) สามารถกำหนดได้ดังนี้

$$J = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i \hat{y}_i}{y_i + \hat{y}_i - y_i \hat{y}_i} \right) \quad (10)$$

สมการฟังก์ชันสูญเสียที่ใช้ถูกกำหนดดังนี้

$$L = H - \log(J) \quad (11)$$

สมการฟังก์ชันสูญเสียสำหรับแบบจำลองร่วมแบบที่ 1 ($Loss_{IOU}$) ถูกกำหนดดังนี้

$$Loss_{IOU} = L_{seg} + H_{class} \quad (12)$$

โดยที่ L_{seg} เป็นฟังก์ชันสูญเสียในสมการที่ (11) สำหรับงานแบ่งส่วน และ H_{class} เป็นฟังก์ชันสูญเสียในสมการที่ (9) สำหรับงานจำแนกประเภท

สมการฟังก์ชันสูญเสียสำหรับแบบจำลองร่วมแบบที่ 2 ($Loss_{sum}$) ถูกกำหนดดังนี้

$$Loss_{sum} = H_{seg} + H_{class} \quad (13)$$

โดยที่ H_{seg} เป็นฟังก์ชันสูญเสียในสมการที่ (9) สำหรับงานแบ่งส่วน และ H_{class} เป็นฟังก์ชันสูญเสียในสมการที่ (9) สำหรับงานจำแนกประเภท

สมการฟังก์ชันสูญเสียสำหรับแบบจำลองร่วมแบบที่ 3 ($Loss_{weight}$) ถูกกำหนดดังนี้

$$Loss_{weight} = H_{seg} + weighted H_{class} \quad (14)$$

โดยที่ H_{seg} เป็นฟังก์ชันสูญเสียในสมการที่ (9) สำหรับงานแบ่งส่วน และ $weighted H_{class}$ เป็นฟังก์ชันสูญเสียในสมการที่ (9) ที่เพิ่มค่าน้ำหนักของจำนวนตัวอย่างประเภทลบต่อจำนวนตัวอย่างประเภทบวก สำหรับงานจำแนกประเภท

4.5 การฝึกสอน (Training strategy)

การแบ่งข้อมูลสำหรับการฝึกสอนนั้น ในงานวิจัยนี้ได้เลือกใช้วิธีการทำ K-fold cross validation โดยเลือกค่า K เท่ากับ 5 ซึ่งเท่ากับงานวิจัย [12] ทำให้สามารถเปรียบเทียบประสิทธิภาพได้มีความคลาดเคลื่อนน้อย เนื่องจากการทดสอบที่เหมือนกัน นอกจากนี้วิธีการทดสอบด้วยวิธีนี้ยังเหมาะสมกับขนาดของชุดข้อมูลที่มีปริมาณน้อย เพื่อให้ผลการทดสอบครอบคลุมตัวอย่างเพิ่มขึ้นมากกว่าการเลือกแบ่งชุดข้อมูลแบบตายตัว

ในกรณีที่มีการใช้ข้อมูลทั้งหมดที่มีรอยโรค และไม่มีรอยโรคในการฝึกสอน ในงานวิจัยนี้ได้เลือกใช้วิธีการทำ Stratified K-fold cross validation โดยการแบ่งนั้นจะดูจากประเภทของภาพว่าเป็นภาพที่มีรอยโรค หรือไม่มีรอยโรคเพื่อให้ข้อมูลกระจายอย่างสมดุลที่สุดเท่าที่จะทำได้

นอกจากนี้ในงานวิจัยนี้จะเลือกวัดประสิทธิภาพจากแบบจำลองที่มีค่าสูญเสียของข้อมูลตรวจสอบน้อยที่สุดในระหว่างกระบวนการฝึกสอน ซึ่งแตกต่างจากงานวิจัย [12] ที่เลือกใช้แบบจำลองที่ถูกฝึกสอนในลำดับสุดท้ายมาใช้ในการทดสอบวัดค่าประสิทธิภาพของแบบจำลอง โดยสาเหตุที่เลือกแบบจำลองที่มีค่าสูญเสียของข้อมูลชุด


ตรวจสอบน้อยที่สุดมาใช้ในการวัดประสิทธิภาพแบบจำลองเนื่องจากการวัดประสิทธิภาพของแบบจำลองควรวัดจากการที่แบบจำลองมีค่าสูญเสียต่อชุดข้อมูลตรวจสอบน้อยที่สุด จากความเป็นจริงที่ตอนนำแบบจำลองไปใช้งานจริงแบบจำลองควรมีความทั่วไปมากที่สุดเท่าที่จะเป็นไปได้จากการฝึกสอนด้วยชุดข้อมูลหนึ่ง ๆ ซึ่งการเลือกแบบจำลองสุดท้ายจากการฝึกสอนมีโอกาสที่แบบจำลองจะมีความพอดีเกินกับชุดข้อมูลที่ใช้ฝึกสอนมากเกินไป

4.6 แบบจำลองที่นำเสนอ (Proposed models)

งานวิจัยนี้ได้ปรับใช้แบบจำลองจาก [12] โดยแยกวิธีการออกเป็นสองส่วนหลักคือ 4.6.1 การประมวลผลภาพเบื้องต้น และ 4.6.2 แบบจำลอง ในส่วนวิธีการแต่งเติมภาพนั้นได้ใช้ขั้นตอนเดิมกับงานวิจัย [12] เพื่อให้สามารถวัดประสิทธิภาพในส่วนที่นำเสนอได้โดยมีปัจจัยเปลี่ยนแปลงให้น้อยที่สุด ซึ่งปกติแล้วในการฝึกสอนแบบจำลองที่เกี่ยวข้องกับภาพมักจะมีการเติมแต่งรูปเพื่อให้แบบจำลองมีความทั่วไปมากขึ้น ไม่เกิดความเกินพอดีกับชุดข้อมูลที่ใช้ฝึกสอน และในงานวิจัยนี้ได้ใช้วิธีการเพิ่มความหลากหลายของภาพด้วยวิธีการต่าง ๆ เช่น การสุ่มกลับข้าง การสุ่มหมุน และการสุ่มสี เป็นต้น ซึ่งในงานวิจัยนี้ได้นำขั้นตอนเหล่านี้มาใช้กับภาพก่อนที่จะนำเข้าไปฝึกสอนกับแบบจำลองก่อนด้วยเช่นกัน

4.6.1 การประมวลผลภาพเบื้องต้น

การประมวลผลภาพเบื้องต้นในงานวิจัยนี้คือขั้นการปรับปรุงภาพก่อนที่จะนำเข้าไปฝึกสอนกับแบบจำลอง โดยเริ่มจากการครอบตัดส่วนขอบของภาพที่ไม่จำเป็นออก เนื่องจากภาพมีส่วนขอบที่ไม่มีข้อมูลที่จำเป็นต่อการเรียนรู้ของแบบจำลองจึงสามารถตัดส่วนที่ไม่จำเป็นนั้นออกได้จากขนาด 576x576 พิกเซล ให้เหลือ 512x512 พิกเซล ได้ จากนั้นวิธีการประมวลผลภาพเบื้องต้นลำดับถัดไปคือการใช้ CLAHE กับภาพ [5] ก่อนการฝึกสอนแบบจำลอง เพื่อเพิ่มความแตกต่างของสีภายในภาพโดยคาดหวังให้แบบจำลองสามารถเรียนรู้ได้ดีขึ้นกว่าภาพแบบดั้งเดิม ตัวอย่างผลลัพธ์จากการทำการประมวลผลภาพเบื้องต้นแสดงในรูป 15



รูป 15 ตัวอย่างภาพ CLAHE ที่นำไปใช้งานจากชุดข้อมูล MICCAI 2017 [10] (บน) และ MICCAI 2018 [11] (ล่าง)

4.6.2 แบบจำลอง

แบบจำลองที่นำเสนอมี 3 แบบ คือ แบบจำลองแบ่งส่วนเพียงอย่างเดียว (segmentation model) แบบจำลองแบ่งส่วนควบคู่จำแนกประเภทโครงสร้างเรียงซ้อน (cascading model) และแบบจำลองแบ่งส่วนควบคู่จำแนกประเภทโครงสร้างร่วมกัน (joint model)

1. แบบจำลองแบ่งส่วนเพียงอย่างเดียว

แบบจำลองแบ่งส่วนเพียงอย่างเดียวเป็นการนำแบบจำลอง AlbuNet ที่เป็นแบบจำลองที่มีการตัดแปลงมาจากแบบจำลอง U-Net โดยใช้ ResNet-34 ที่ผ่านการฝึกสอนมาแล้วเป็นตัวเข้ารหัส แบบจำลองมีความแตกต่างจาก U-Net จากการที่ตัวถอดรหัสมีขนาดของแชนแนลไม่เท่ากันกับตัวเข้ารหัสในบางชั้น โดยในการทดลองได้มีการเพิ่มชั้น SE จาก [31] ระหว่างแต่ละชั้นของตัวเข้ารหัส ตัวถอดรหัส และเส้นเชื่อมระหว่างตัวเข้ารหัสและตัวถอดรหัส ชั้น SE นี้จะช่วยเพิ่มค่าน้ำหนักให้กับข้อมูลที่ผ่านมาเครือข่ายในแต่ละชั้น แบบจำลองดังกล่าวแสดงในรูป 16

ในการทดลองนี้ได้มีแนวคิดเพิ่มชั้น SE ลงในแต่ละชั้นของตัวเข้ารหัส ตัวถอดรหัส และเส้นเชื่อมต่อ โดยได้มีการทดลองแบบจำลองดังนี้

1.1 การเพิ่มการเชื่อมข้าม

- 1) เพิ่มการเชื่อมข้ามระหว่างชั้นตัวเข้ารหัส
- 2) เพิ่มการเชื่อมข้ามระหว่างชั้นตัวถอดรหัส
- 3) เพิ่มการเชื่อมข้ามระหว่างชั้นตัวเข้ารหัส และตัวถอดรหัส

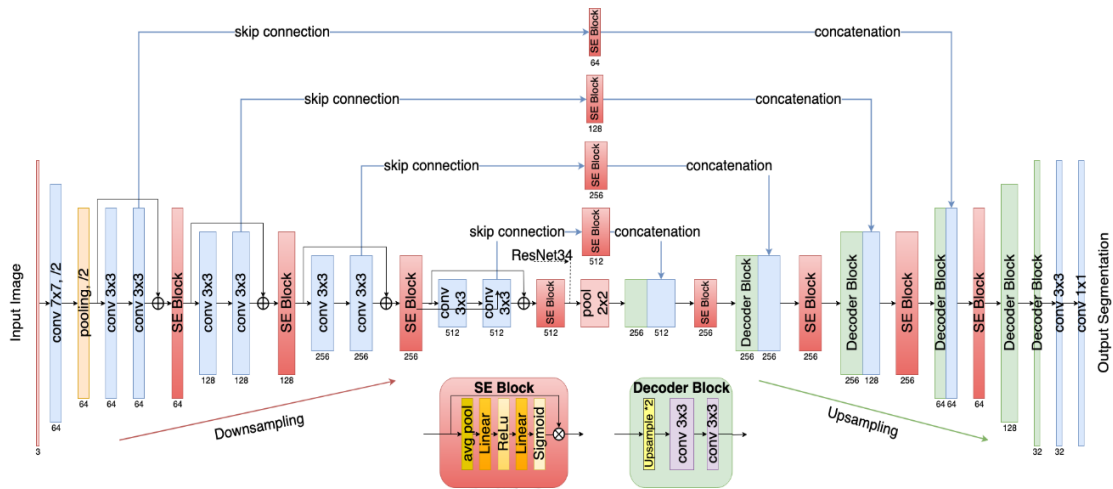
1.2. การบีบและการกระตุ้น

- 1) เพิ่มชั้น SE ระหว่างชั้นตัวเข้ารหัส
- 2) เพิ่มชั้น SE ระหว่างชั้นตัวเข้ารหัส และตัวถอดรหัส
- 3) เพิ่มชั้น SE ระหว่างชั้นตัวเข้ารหัส ตัวถอดรหัส และเส้นเชื่อมระหว่างตัวเข้ารหัสกับตัวถอดรหัส

1.3. การเลือกใช้ฟังก์ชันสูญเสีย

- 1) Binary cross entropy
- 2) Binary cross entropy ที่ถ่วงน้ำหนักด้วยค่าบวก
- 3) Binary cross entropy แบบถ่วงน้ำหนักด้วยค่า Jaccard index

จากการทดสอบเบื้องต้นพบว่า การเพิ่มการเพิ่มชั้น SE ระหว่างชั้นตัวเข้ารหัส ตัวถอดรหัส และเส้นเชื่อมระหว่างตัวเข้ารหัสกับตัวถอดรหัสกับการใช้ฟังก์ชันสูญเสียเป็น binary cross entropy แบบถ่วงน้ำหนักด้วยค่า Jaccard index เป็นแบบจำลองที่ให้ผลลัพธ์ที่ดีที่สุดเมื่อเทียบกับการผสมแบบอื่นจึงได้เลือกแบบจำลองที่กล่าวมาข้างต้นเป็นแบบจำลองใหม่เพื่อเปรียบเทียบกับแบบจำลองพื้นฐาน และใช้แบบจำลองใหม่นี้เป็นแบบจำลองพื้นฐานสำหรับเปรียบเทียบกับแบบจำลองที่นำเสนออีก 2 วิธีคือแบบจำลองเรียงซ้อน และแบบจำลองร่วมกันต่อไปด้วย



รูป 16 แบบจำลองแบ่งส่วนเพียงอย่างเดียว

แบบจำลองที่นำมาใช้เพื่อเปรียบเทียบกับแบบจำลองที่นำเสนอโดยในแต่ละแบบจำลองจะนำเข้าสู่ข้อมูลชุดเดียวกัน และปรับค่าไฮเปอร์พารามิเตอร์ให้เหมาะสมกับแต่ละแบบจำลองโดยแบบจำลองที่นำมาทดสอบเปรียบเทียบบนชุดนี้

- 1) แบบจำลอง AlbuNet
- 2) แบบจำลอง AlbuNet ร่วมกับ SE
- 3) แบบจำลอง AlbuNet ร่วมกับ SE และการประมวลผลภาพเบื้องต้น

โดยสาเหตุที่เลือกแบบจำลอง AlbuNet มาใช้เป็นแบบจำลองพื้นฐานเนื่องจากเป็นแบบจำลองที่ได้ผลลัพธ์ที่ดีที่สุดในงานเกี่ยวกับโรคหลอดเลือดเจริญผิดปกติ

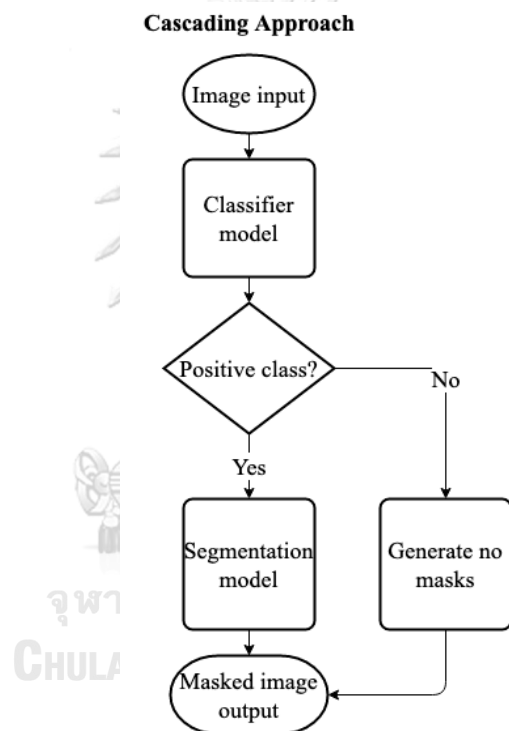
2. แบบจำลองแบ่งส่วนควบคู่กันกับประเภทโครงสร้างเรียงซ้อน

แบบจำลองแบ่งส่วนควบคู่กันกับประเภทโครงสร้างเรียงซ้อนที่นำเสนอคือการนำแบบจำลองที่ทำหน้าที่ต่างกันมาใช้งานร่วมกันโดยในงานวิจัยนี้ได้้นำแบบจำลองจำแนกประเภท และแบบจำลองแบ่งส่วนมาเรียงซ้อนกัน ในส่วนของการฝึกสอนนั้นแบบจำลองแต่ละแบบถูกฝึกสอนแยกกัน การฝึกสอนแบบจำลองจำแนกประเภทมีไว้เพื่อการแยกภาพที่มีรอยโรค และไม่มีรอยโรคออกจากกันก่อนเป็นขั้นแรกเพื่อเป็นการกรองเอาภาพที่ไม่มีรอยโรคออกไป และส่งต่อเฉพาะภาพที่มีรอยโรคต่อให้กับแบบจำลองแบ่งส่วนเพื่อค้นหาตำแหน่งที่มีรอยโรคในภาพนั้น การออกแบบวิธีสร้างแบบจำลองเรียงซ้อนกันแสดงอยู่ในรูป 17

แบบจำลองจำแนกประเภทที่ได้เลือกมาใช้ได้เลือกแบบจำลองที่มีค่าน้ำหนักจากการฝึกสอนด้วยชุดข้อมูล ImageNet โดยเลือกโครงสร้างทั่วไปที่นิยมใช้กันคือ ResNet-34 ResNet-50 และ ResNet-101 ซึ่งฝึกสอนด้วยการใช้ 5-fold cross validation และแบ่งข้อมูลที่ใช้ฝึกสอนด้วยวิธี stratified K-fold

แบบจำลองแบ่งส่วนที่นำมาใช้หลังจากภาพได้ผ่านการคัดกรองโดยแบบจำลองจำแนกประเภทคือแบบจำลองแบ่งส่วนเพียงอย่างเดียวที่ทดลองเบื้องต้นแล้วได้ประสิทธิภาพดีกว่าแบบจำลองพื้นฐานโดยสามารถตรวจสอบผลการทดลองเบื้องต้นของแบบจำลองแบ่งส่วนเพียงอย่างเดียวได้ที่หัวข้อ 5.1 การฝึกสอนแบบจำลองแบ่งส่วนได้ใช้การฝึกสอนแบบเดียวกับแบบจำลองจำแนกประเภทด้วยการใช้ 5-fold cross validation และแบ่งข้อมูลที่ใช้ฝึกสอนด้วยวิธี stratified K-fold

ข้อดีของวิธีการใช้งานแบบจำลองเรียงซ้อนคือการที่สามารถสร้างแบบจำลองแต่ละแบบแยกกันได้โดยมุ่งเน้นไปที่งานเฉพาะของแบบจำลองนั้น ๆ เพื่อให้ได้ผลลัพธ์ที่ดีที่สุดในแต่ละงาน ซึ่งในที่นี้หมายถึงงานจำแนกประเภท และงานแบ่งส่วน หากในอนาคตมีแบบจำลองที่สามารถจำแนกประเภท หรือแบ่งส่วนได้มีประสิทธิภาพกว่าแบบจำลองเดิมที่ใช้งานอยู่ สามารถเปลี่ยนแบบจำลองที่มีประสิทธิภาพที่ดีกว่านั้นได้ง่าย เนื่องจากแบบจำลองทั้งสองประเภทแยกจากกันเป็นสองส่วนชัดเจน ในส่วนของข้อเสียในวิธีแบบจำลองเรียงซ้อนนั้นมีความยุ่งยากกว่าในขั้นตอนติดตั้งสำหรับใช้งานจริง เนื่องจากการฝึกสอนแบบจำลองแต่ละแบบนั้นแยกจากกันโดยสิ้นเชิง ซึ่งหากแบบจำลองแต่ละแบบฝึกสอนมาต่างกัน การนำข้อมูลมาใช้กับแบบจำลองแต่ละแบบอาจเกิดความสับสนขึ้นได้ เช่น การที่แบบจำลองจำแนกประเภทถูกฝึกสอนด้วยภาพนำเข้าที่มีขนาด หรือการประมวลผลภาพเบื้องต้น แตกต่างกับแบบจำลองแบ่งส่วน จะทำให้การส่งต่อข้อมูลให้กับแต่ละแบบจำลองต้องมีข้อที่ต้องตรวจสอบก่อนที่จะส่งต่อให้กับแบบจำลองแต่ละแบบ เป็นต้น



รูป 17 แบบจำลองเรียงซ้อน

3. แบบจำลองแบ่งส่วนควบคู่จำแนกประเภทโครงสร้างร่วมกัน

แบบจำลองแบ่งส่วนควบคู่จำแนกประเภทโครงสร้างเรียงซ้อนที่นำเสนอคือการนำแบบจำลองที่ทำหน้าที่อย่างใดอย่างหนึ่งมาปรับปรุงเพิ่มให้สามารถทำหน้าที่เพิ่มได้อีกอย่างหนึ่งโดยในงานวิจัยนี้ได้้นำแบบจำลองแบ่งส่วนมาเพิ่มความสามารถให้สามารถจำแนกประเภทเพิ่มได้ การออกแบบวิธีสร้างแบบจำลองร่วมกันแสดงอยู่ในรูป 18

แบบจำลองแบ่งส่วนที่เลือกมาเพื่อเพิ่มความสามารถให้จำแนกประเภทเพิ่มได้คือแบบจำลองแบ่งส่วนเพียงอย่างเดียวที่ทดลองเบื้องต้นแล้วได้ประสิทธิภาพดีกว่าแบบจำลองพื้นฐานโดยสามารถตรวจสอบผลการทดลองเบื้องต้นของแบบจำลองแบ่งส่วนเพียงอย่างเดียวได้ที่หัวข้อ 5.1 รายละเอียดแบบจำลองร่วมกันที่สร้างจากแบบจำลองแบ่งส่วนเพียงอย่างเดียวแสดงอยู่ในรูป 19

การออกแบบในรายละเอียดของแบบจำลองร่วมกันมีสองส่วนหลักคือการเลือกการสร้างชั้นการจำแนกประเภท และการรวมฟังก์ชันสูญเสียของแบบจำลองร่วมกันที่เกิดจากการเพิ่มข้อมูลการจำแนกประเภท ในส่วนของการเลือกการสร้างชั้นการจำแนกประเภทได้เลือกขนาดของชั้น Dense ชั้นแรกที่ขนาด 1,024 จากการทดสอบเปรียบเทียบการปรับขนาดของชั้น Dense ชั้นแรกที่ประกอบไปด้วยขนาด 512 1,024 และ 2,048 เนื่องจากขนาดที่ได้เลือกมาใช้เพื่อทำการทดลองชั้นต่อไปนั้นมีประสิทธิภาพดีที่สุดเมื่อเทียบกับขนาดอื่น ๆ ที่ได้ทำการทดลองไป หลังจากที่ได้เพิ่มชั้นการจำแนกประเภทแล้ว ชั้นถัดไปที่ต้องปรับปรุงคือการเลือกใช้ฟังก์ชันสูญเสียที่เพิ่มขึ้นจากชั้นการจำแนกประเภท โดยฟังก์ชันสูญเสียที่เพิ่มขึ้นมานั้นต้องรวมเข้ากับฟังก์ชันสูญเสียเดิมของแบบจำลองแบ่งส่วน การออกแบบวิธีการรวมฟังก์ชันสูญเสียของแบบจำลองร่วมกันมีดังนี้

$$1) \text{Loss}_{\text{IoU}} = \text{IoU weighted BCE}_{\text{seg}} + \text{BCE}_{\text{class}}$$

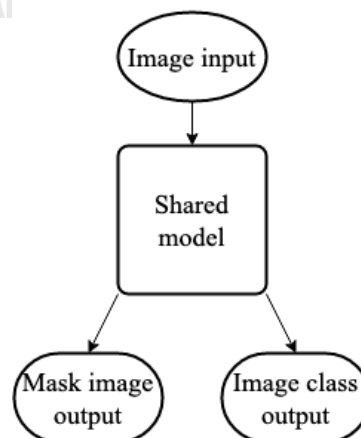
$$2) \text{Loss}_{\text{sum}} = \text{BCE}_{\text{seg}} + \text{BCE}_{\text{class}}$$

$$3) \text{Loss}_{\text{Weight}} = \text{BCE}_{\text{seg}} + \text{Weighted BCE}_{\text{class}}$$

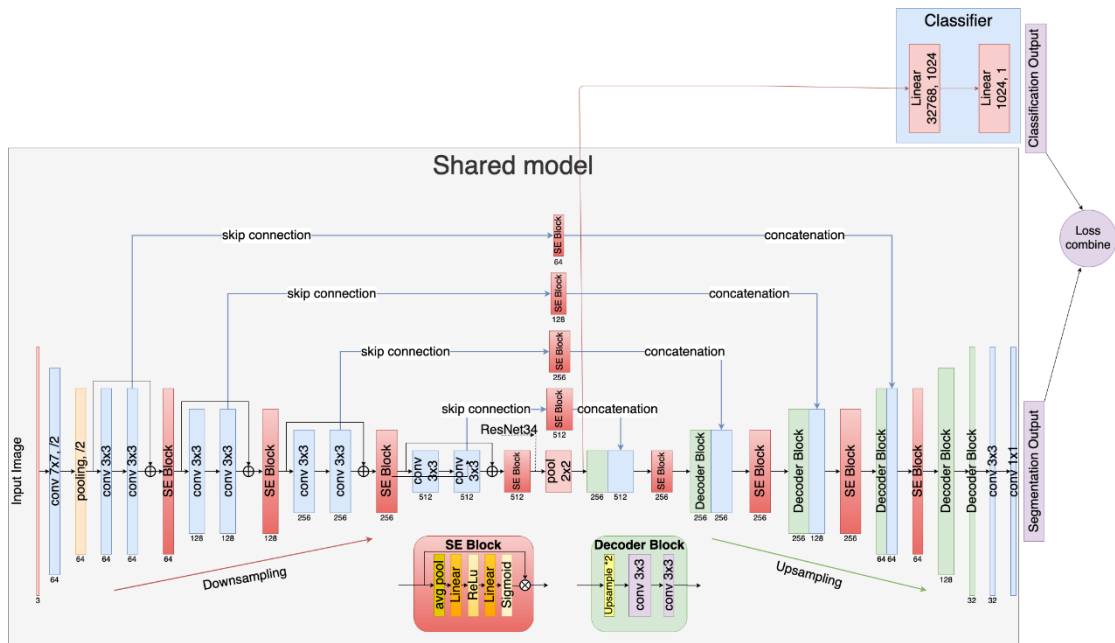
จากฟังก์ชันสูญเสียข้างต้นจะถูกใช้ทดสอบเพื่อหาผลลัพธ์ที่ดีที่สุดซึ่งให้ความสมดุลระหว่างผลลัพธ์ขาออกทั้งในส่วนการจำแนกประเภท และการแบ่งส่วน

ข้อดีของวิธีการใช้งานแบบจำลองร่วมกันคือความง่ายในการใช้งานเนื่องจากแบบจำลองร่วมกันเป็นแบบจำลองเดี่ยว (single model) ที่ให้ผลลัพธ์มากกว่าแบบจำลองเดิม โดยในงานนี้แบบจำลองร่วมสามารถทำนายประเภทของภาพ และตำแหน่งของรอยโรคในภาพได้พร้อมกัน นอกจากนี้การใช้แบบจำลองร่วมที่เป็นแบบจำลองเดี่ยวมีความเป็นไปได้ที่จะใช้ทรัพยากรของเครื่องที่ใช้ทำงานน้อยกว่าแบบจำลองเรียงซ้อนที่มีจำนวนแบบจำลองที่ต้องใช้มากกว่าหนึ่งแบบ ข้อเสียของแบบจำลองร่วมกันคือความยากในการสร้าง และฝึกสอน เนื่องจากการต่อเติมแบบจำลองเดิมให้มีความสามารถอื่นเพิ่ม อาจต้องอาศัยการทดลองในการปรับแต่งพารามิเตอร์จำนวนมาก รวมไปถึงการปรับแต่งฟังก์ชันสูญเสียในส่วนของคุณค่าขาออกที่เพิ่มขึ้นมาด้วย โดยที่การปรับแต่งนั้นมีโอกาสทำให้แบบจำลองเดิมสูญเสียประสิทธิภาพเดิมที่เคยมีได้ ทำให้ต้องใช้ระยะเวลาในการทดสอบแบบจำลองนานสำหรับการปรับค่าในแต่ละครั้ง หากแบบจำลองมีขนาดใหญ่จะทำให้ต้องใช้เวลาในการฝึกสอนนานตามไปด้วย

Joint Model Approach



รูป 18 แบบจำลองร่วมกัน



รูป 19 การนำแบบจำลองร่วมกัน มาประยุกต์ใช้กับแบบจำลองแบ่งส่วนเพียงอย่างเดียว



บทที่ 5

การทดลอง

การทดลองจะแบ่งเป็น 3 หัวข้อคือ การทดลองแบบจำลองแบ่งส่วน การทดลองเปรียบเทียบแบบจำลองเรียงซ้อนกับแบบจำลองร่วมกัน และการทดลองเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกัน โดยในบทนี้ผู้เขียนจะกำหนดการเรียกชื่อแบบจำลองให้สั้นลงเพื่อความกระชับในการอ้างอิงถึงโดยกำหนดชื่อไว้ดังตาราง 2 ตาราง 2 กำหนดชื่อแบบจำลอง

ชื่อแบบจำลองแบบเต็ม	ชื่อแบบจำลองแบบย่อ
แบบจำลองแบ่งส่วนเพียงอย่างเดียว	แบบจำลองแบ่งส่วน
แบบจำลองแบ่งส่วนควบคู่จำแนกประเภทโครงสร้างเรียงซ้อน	แบบจำลองเรียงซ้อน
แบบจำลองแบ่งส่วนควบคู่จำแนกประเภทโครงสร้างร่วมกัน	แบบจำลองร่วมกัน

5.1 การทดลองของแบบจำลองแบ่งส่วน

หัวข้อนี้จะกล่าวถึงการทดลองและผลของการทดลองของแบบจำลองแบ่งส่วนโดยผลลัพธ์ที่ได้เป็นตำแหน่งระดับพิกเซลของรอยโรคในภาพที่รับเข้ามา โดยมีมาตรวัดค่าผลลัพธ์คือคะแนน Dice และ IoU แสดงในตาราง 3 สำหรับชุดข้อมูล MICCAI 2017 และตาราง 4 สำหรับชุดข้อมูล MICCAI 2018 ภาพเปรียบเทียบการทำนายการแบ่งส่วนภาพจะแสดงในรูป 20

ข้อมูลที่ใช้ในการทดลองเบื้องต้นประกอบด้วยภาพรอยโรคของโรคหลอดเลือดเจริญเติบโตผิดปกติโดยข้อมูลจะถูกแบ่งด้วยการทำ K-fold cross validation โดยค่า K เท่ากับ 5


จากผลการทดลองที่แสดงในตาราง 3 และ ตาราง 4 วัดประสิทธิภาพด้วย Dice และ IoU พบว่าแบบจำลอง AlbuNet ที่เพิ่มขึ้น SE กับการประมวลผลภาพเบื้องต้น สามารถแบ่งส่วนภาพได้มีค่าคะแนนจากตัววัดประสิทธิภาพสูงกว่าแบบจำลองอื่นที่นำมาเปรียบเทียบด้วย

ตาราง 3 ค่า Dice และ IoU เมื่อทดสอบด้วยชุดข้อมูล MICCAI 2017 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Dice	IoU
AlbuNet	85.07%	75.63%
AlbuNet ร่วมกับ SE	86.09%	76.60%
AlbuNet ร่วมกับ SE และการประมวลผลภาพเบื้องต้น	86.17%	76.64%

ตาราง 4 ค่า Dice และ IoU เมื่อทดสอบด้วยชุดข้อมูล MICCAI 2018 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Dice	IoU
AlbuNet	62.99%	51.91%
AlbuNet ร่วมกับ SE	65.62%	54.61%
AlbuNet ร่วมกับ SE และการประมวลผลภาพเบื้องต้น	66.20%	55.11%



รูป 20 ตัวอย่างภาพที่มีรอยโรคจริง (ซ้าย) ภาพการแบ่งส่วนภาพรอยโรคจากแบบจำลอง AlbuNet (กลาง) และ ภาพการแบ่งส่วนภาพรอยโรคจากแบบจำลองแบ่งส่วนที่นำเสนอ (ขวา)

เมื่อเปรียบเทียบผลลัพธ์ของแบบจำลอง AlbuNet ร่วมกับ SE ที่มีการประมวลผลภาพเบื้องต้นกับไม่มี ด้วยวิธีการจับคู่ทีเทสต์ (paired t-test) จากตาราง 3 และตาราง 4 พบว่าผลต่างจากผลลัพธ์ของแบบจำลองทั้ง 2 แบบนี้ไม่มีความแตกต่างอย่างมีนัยสำคัญโดยมีค่า p-value ของค่า Dice และ IoU ที่ความเชื่อมั่น 95% บนชุด ข้อมูล MICCAI 2017 ที่ 0.3781 และ 0.3732 ตามลำดับ บนชุดข้อมูล MICCAI 2018 ที่ 0.1425 และ 0.1358 ตามลำดับ อาจกล่าวได้ว่าการทำการประมวลผลภาพเบื้องต้นไม่ได้เพิ่มประสิทธิภาพให้แก่แบบจำลองในชุดข้อมูลที่ ใช้ทดสอบนี้ แต่อย่างไรก็ตามหากชุดข้อมูลมีปริมาณมากขึ้น อาจมีความเป็นไปได้ที่จะมีผลต่อผลลัพธ์ที่ได้

จากผลลัพธ์ค่าคะแนนจากตารางข้างต้นเป็นผลลัพธ์จากคะแนนการวัดค่าจากภาพที่มีรอยโรคเท่านั้น เมื่อ นำแบบจำลองที่ได้ไปทดสอบกับข้อมูลที่ไม่มีรอยโรค ปรากฏว่าผลลัพธ์ที่ได้จากแบบจำลอง AlbuNet และ AlbuNet ร่วมกับ SE มีค่า Accuracy ที่ค่อนข้างต่ำอยู่ที่ 17.66% และ 8.33% ตามลำดับ เนื่องจากแบบจำลองถูก ฝึกสอนโดยการใช้ข้อมูลที่มีแต่รอยโรคเท่านั้น ทำให้เมื่อถูกทดสอบบนข้อมูลที่ไม่มีรอยโรคทำให้ผลลัพธ์ออกมาไม่ดี ดังนั้นในหัวข้อถัด ๆ ไปจะมีการนำข้อมูลที่มีรอยโรค และไม่มีรอยโรคในการใช้ฝึกสอนแบบจำลอง และจะมีการนำ แบบจำลองแบ่งส่วนไปใช้ร่วมกับแบบจำลองที่ได้นำเสน่อีกสองแบบคือแบบจำลองเรียงซ้อน และแบบจำลอง ร่วมกันซึ่งเป็นแบบจำลองที่ให้ผลลัพธ์ได้มากกว่าโดยให้ผลลัพธ์เป็นประเภทของภาพร่วมด้วยนอกเหนือจากตำแหน่ง ของรอยโรคเพียงอย่างเดียว

5.2 การทดลองเปรียบเทียบแบบจำลองเรียงซ้อนกับแบบจำลองร่วมกัน

การทดลองใช้ชุดข้อมูลที่มีทั้งหมดโดยมีทั้งภาพที่มีรอยโรค และไม่มีรอยโรค และเนื่องจากการใช้ชุดข้อมูล ที่แตกต่างจากการทดลองเบื้องต้นที่ทดลองด้วยการฝึกสอนแบบจำลองด้วยชุดข้อมูลที่มีแต่รอยโรค ในการทดลองนี้ จะนำแบบจำลองแบ่งส่วนเพียงอย่างเดียวมาฝึกสอนใหม่ด้วยชุดข้อมูลที่มีทั้งรอยโรค และไม่มีรอยโรคเพื่อที่จะ สามารถเปรียบเทียบประสิทธิภาพของแบบจำลองแบ่งส่วนกับแบบจำลองแบ่งส่วนควบคู่กันประเภทได้อย่าง ถูกต้อง ผลลัพธ์เปรียบเทียบของแบบจำลองเรียงซ้อนกับแบบจำลองร่วมกันแสดงในตาราง 5 และตาราง 6

ผลลัพธ์แสดงให้เห็นว่าแบบจำลองร่วมกันให้ผลลัพธ์ที่ดีกว่าแบบจำลองเรียงซ้อนโดยเฉพาะอย่างยิ่งในงานจำแนกประเภท เหตุผลที่แบบจำลองเรียงซ้อนให้ผลลัพธ์ที่ไม่ดีเท่าแบบจำลองร่วมกันเนื่องจากแบบจำลองเรียงซ้อนมีตัวจำแนกประเภทที่ไม่แม่นยำเพียงพอที่จะจำแนกประเภทภาพที่ถูกต้องก่อนส่งต่อไปยังตัวแบ่งส่วน ซึ่งหากตัวจำแนกประเภทมีความคลาดเคลื่อนค่อนข้างมากแล้ว จะทำให้ผลลัพธ์ที่ได้จากแบบจำลองเรียงซ้อนมีโอกาสลดลงได้อย่างมาก

ตาราง 5 ผลลัพธ์การเปรียบเทียบของแบบจำลองที่นำเสนอด้วยชุดข้อมูล MICCAI 2017 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Accuracy	Dice
แบบจำลองเรียงซ้อน – ResNet-34	84.83%	84.64%
แบบจำลองเรียงซ้อน – ResNet-50	91.16%	84.71%
แบบจำลองเรียงซ้อน – ResNet-101	92.50%	85.56%
แบบจำลองร่วมกัน – ฟังก์ชันสูญเสียแบบที่ 1	100.00%	91.76%
แบบจำลองร่วมกัน – ฟังก์ชันสูญเสียแบบที่ 2	100.00%	92.16%

ตาราง 6 ผลลัพธ์การเปรียบเทียบของแบบจำลองที่นำเสนอด้วยชุดข้อมูล MICCAI 2018 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Accuracy	Dice
แบบจำลองเรียงซ้อน – ResNet-34	91.92%	63.80%
แบบจำลองเรียงซ้อน – ResNet-50	91.79%	63.87%
แบบจำลองเรียงซ้อน – ResNet-101	91.90%	63.35%
แบบจำลองร่วมกัน – ฟังก์ชันสูญเสียแบบที่ 2	99.17%	65.58%
แบบจำลองร่วมกัน – ฟังก์ชันสูญเสียแบบที่ 3	99.28%	74.34%

5.3 การทดลองเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกัน

ผลลัพธ์การแบ่งประเภทแสดงให้เห็นว่าแบบจำลองร่วมกันสามารถจำแนกประเภทภาพที่มีรอยโรค และไม่มียโรคด้วยค่า Accuracy ที่สูงทั้งสองชุดข้อมูล และเพิ่มประสิทธิภาพการแบ่งส่วนอีกเล็กน้อย ซึ่งผลลัพธ์ที่ได้นี้น่าจะสามารถช่วยผู้เชี่ยวชาญในการตรวจสอบรอยโรคได้ ผลลัพธ์เปรียบเทียบระหว่างแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันแสดงในตาราง 7 ตาราง 8 ตาราง 9 และตาราง 10 รูปตัวอย่างผลลัพธ์แสดงในรูป 21

ตาราง 7 ผลลัพธ์มาตรฐานการจำแนกประเภทเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันด้วยชุดข้อมูล MICCAI 2017 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Accuracy	Precision	Recall	F1
AlbuNet	96.99%	94.60%	99.66%	97.06%
แบบจำลองแบ่งส่วน	97.32%	94.92%	100.00%	97.39%
แบบจำลองร่วมกัน	100.00%	100.00%	100.00%	100.00%

ตาราง 8 ผลลัพธ์มาตรฐานวัดการจำแนกประเภทเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันด้วยชุดข้อมูล MICCAI 2018 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Accuracy	Precision	Recall	F1
AlbuNet	90.50%	88.40%	98.76%	93.29%
แบบจำลองแบ่งส่วน	91.88%	90.43%	98.26%	94.18%
แบบจำลองร่วมกัน	99.28%	100.00%	98.92%	99.45%


ตาราง 9 ผลลัพธ์มาตรฐานวัดการแบ่งส่วนเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันด้วยชุดข้อมูล MICCAI 2017 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Dice	IoU
AlbuNet	89.70%	84.76%
แบบจำลองแบ่งส่วน	90.51%	85.80%
แบบจำลองร่วมกัน	92.16%	87.37%
แบบจำลองร่วมกันที่อิงผลลัพธ์การจำแนกประเภท	92.35%	87.55%


ตาราง 10 ผลลัพธ์มาตรฐานวัดการแบ่งส่วนเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันด้วยชุดข้อมูล MICCAI 2018 โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	Dice	IoU
AlbuNet	69.20%	61.97%
แบบจำลองแบ่งส่วน	70.04%	62.85%
แบบจำลองร่วมกัน	74.34%	67.03%
แบบจำลองร่วมกันที่อิงผลลัพธ์การจำแนกประเภท	68.12%	61.09%

จากตาราง 9 และตาราง 10 พบว่าหากแบบจำลองร่วมกันใช้ผลลัพธ์การจำแนกประเภทเพื่ออ้างอิงการแบ่งส่วน มีโอกาสที่ผลลัพธ์ที่ได้จากการแบ่งส่วนได้ผลลัพธ์ที่เท่าเดิม หรือดีขึ้นได้ในกรณีที่การจำแนกประเภทนั้นถูกต้องทั้งหมด ในขณะที่หากการจำแนกประเภทไม่มีความถูกต้องทั้งหมดก็มีโอกาสทำให้ผลลัพธ์ที่ได้จากการแบ่งส่วนลดลงได้ เนื่องจากการทำนายผลของการจำแนกประเภทเป็นค่าลบเท็จ



รูป 21 ตัวอย่างผลลัพธ์ที่ได้จากแบบจำลอง



รูป 22 ตัวอย่างภาพที่แบบจำลองร่วมกันทำนายผลการจำแนกประเภทผิดเป็นค่าลบเท็จ

5.4 การวิเคราะห์สำรวจข้อมูล

ในหัวข้อนี้จะเป็นการสำรวจข้อมูลเพิ่มเติมในชุดข้อมูลทั้ง 2 ชุด นอกเหนือจากจำนวนภาพในแต่ละประเภทของแต่ละชุดข้อมูลในตาราง 11 โดยจะมีการตรวจสอบจำนวนรอยแผลที่ปรากฏบนแต่ละภาพในแต่ละชุดข้อมูลว่ามีความแตกต่างกันอย่างไร ที่อาจส่งผลต่อผลลัพธ์ของแบบจำลองได้

ตาราง 11 ชุดข้อมูลแบ่งตามประเภท

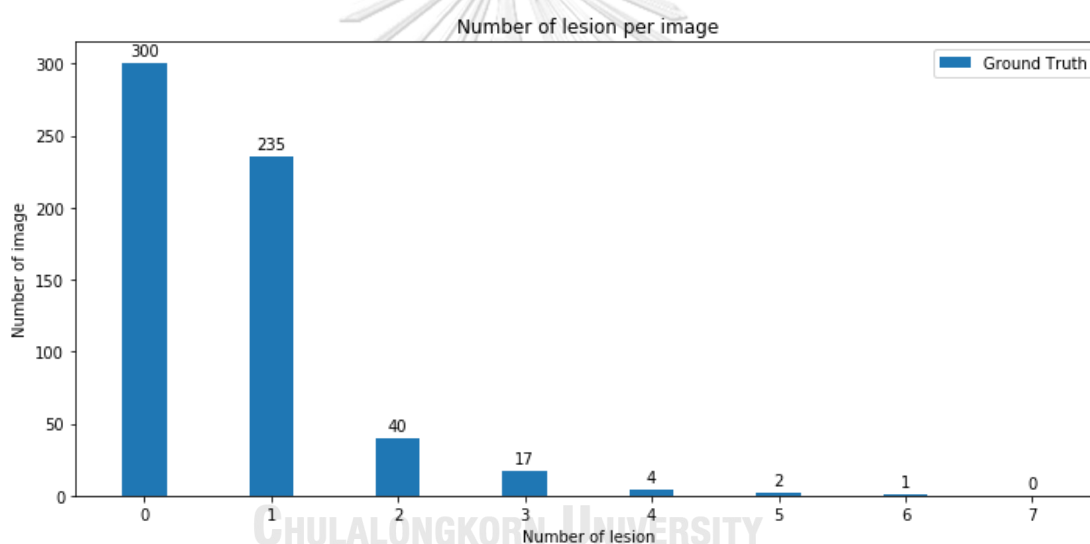
ชุดข้อมูล	ประเภทรอยโรค	ประเภทไม่มีรอยโรค	รวม
MICCAI 2017	299	300	599
MICCAI 2018	1,212	600	1,812

5.4.1 ชุดข้อมูล MICCAI 2017


ในชุดข้อมูล MICCAI 2017 นี้ นอกจากภาพที่แบ่งประเภทเป็นภาพที่มีรอยโรคจำนวน 299 ภาพ และภาพที่ไม่มีรอยโรคจำนวน 300 ภาพแล้ว จะเห็นได้ว่าภาพทั้งหมดที่แสดงในตาราง 12 นั้น รอยโรคในแต่ละภาพมีจำนวนไม่เกิน 6 รอยต่อภาพ และยิ่งจำนวนรอยโรคที่เพิ่มมากขึ้น จำนวนภาพที่มีรอยโรคที่เยอะขึ้นก็จะมีจำนวนลดลง โดยแสดงภาพรวมของจำนวนภาพต่อจำนวนรอยโรคไว้ในรูป 23 จำนวนรอยโรครวมของชุดข้อมูลนี้มีจำนวน 398 รอย นอกจากจำนวนรอยโรคต่อภาพแล้วยังมีการตรวจสอบจำนวนพิกเซลของรอยโรคต่อภาพด้วย เนื่องจากผลลัพธ์ที่ได้เป็นการทำนายที่อยู่ในระดับพิกเซลของภาพจึงอาจมีความสัมพันธ์เกี่ยวข้องกับแบบจำลองที่ได้มาโดยแสดงอยู่ในรูปของฮิสโตแกรมดังรูป 24 ซึ่งกำหนดช่วง (bins) เป็นค่าเท่ากับ 3 ซึ่งแบ่งตามขนาดของรอยโรคคือขนาดเล็ก กลาง ใหญ่ แยกตามชุดข้อมูล

ตาราง 12 จำนวนรอยแผลต่อภาพของชุดข้อมูล MICCAI 2017

จำนวนรอยแผลต่อภาพ	0	1	2	3	4	5	6
จำนวนภาพ	300	235	40	17	4	2	1



รูป 23 จำนวนภาพต่อจำนวนรอยโรคบนชุดข้อมูล MICCAI 2017



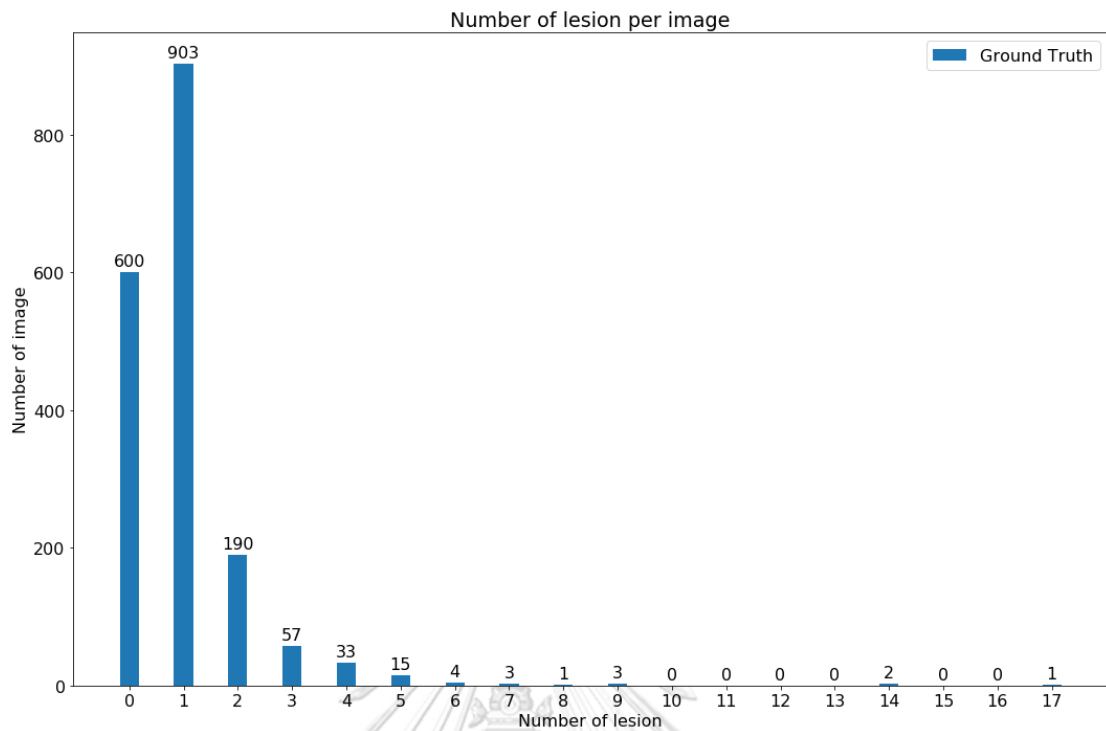
รูป 24 ฮิสโตแกรมแสดงจำนวนรอยโรคในหน่วยพิกเซลต่อภาพบนชุดข้อมูล MICCAI 2017

5.4.2 ชุดข้อมูล MICCAI 2018


ในชุดข้อมูล MICCAI 2018 นี้ นอกจากภาพที่แบ่งประเภทเป็นภาพที่มีรอยโรคจำนวน 1,212 ภาพ และภาพที่ไม่มีรอยโรคจำนวน 600 ภาพแล้ว จะเห็นได้ว่าภาพทั้งหมดที่แสดงในตาราง 13 นั้นรอยโรคในแต่ละภาพมีจำนวนไม่เกิน 17 รอยต่อภาพ และยิ่งจำนวนรอยโรคที่เพิ่มมากขึ้น จำนวนภาพที่มีรอยโรคที่เยอะขึ้นก็จะมีจำนวนลดลงเช่นเดียวกับชุดข้อมูล MICCAI 2017 โดยแสดงภาพรวมของจำนวนภาพต่อจำนวนรอยโรคไว้ในรูป 25 จำนวนรอยโรครวมของชุดข้อมูลนี้มีจำนวน 1,786 รอย นอกจากจำนวนรอยโรคต่อภาพแล้วยังมีการตรวจสอบจำนวนพิกเซลของรอยโรคต่อภาพด้วยเช่นเดียวกับชุดข้อมูล MICCAI 2017 โดยแสดงอยู่ในรูปของฮิสโตแกรมดังรูป 26 ซึ่งกำหนดช่วงเป็นค่าเท่ากับ 3 ซึ่งแบ่งตามขนาดของรอยโรคคือขนาดเล็ก กลาง ใหญ่ แยกตามชุดข้อมูล

ตาราง 13 จำนวนรอยแผลต่อภาพของชุดข้อมูล MICCAI 2018

จำนวนรอยแผลต่อภาพ	0	1	2	3	4	5	6	7	8	9	14	17
จำนวนภาพ	600	903	190	57	33	15	4	3	1	3	2	1



รูป 25 จำนวนภาพต่อจำนวนรอยโรคบนชุดข้อมูล MICCAI 2018



รูป 26 ฮิสโตแกรมแสดงจำนวนรอยโรคในหน่วยพิกเซลต่อภาพบนชุดข้อมูล MICCAI 2018

5.4.3 เปรียบเทียบชุดข้อมูล MICCAI 2017 กับ MICCAI 2018


เมื่อเปรียบเทียบข้อมูลจำนวนภาพต่อจำนวนรอยโรคของข้อมูลทั้ง 2 ชุดดังที่แสดงในตาราง 14 และรูป 27 พบว่าทิศทางปริมาณภาพที่มีจำนวนรอยโรคมกไปในทิศทางเดียวกันคือมีปริมาณภาพลดลง และภาพชุดข้อมูล MICCAI 2018 มีปริมาณของข้อมูลต่อจำนวนรอยโรคที่มากกว่าชุดข้อมูล MICCAI 2017 ซึ่งหมายความว่าชุดข้อมูล MICCAI 2018 ค่อนข้างมีความครอบคลุมมากกว่า MICCAI 2017 และมีความหลากหลายของข้อมูลมากกว่า ซึ่งอาจ

ส่งผลให้การสร้างแบบจำลองบนชุดข้อมูล MICCAI 2018 มีความยากมากกว่าส่งผลให้ผลลัพธ์บนชุดข้อมูล MICCAI 2018 แตกต่างจากผลลัพธ์บนชุดข้อมูล MICCAI 2017 ค่อนข้างมาก


ในส่วนของความแตกต่างด้านจำนวนพิกเซลของรอยโรคระหว่างชุดข้อมูลดังที่แสดงในรูป 28 พบว่าชุดข้อมูล MICCAI 2018 มีปริมาณพิกเซลของรอยโรคเป็นจำนวนที่มากกว่าชุดข้อมูล MICCAI 2017 อย่างชัดเจนเมื่อเปรียบเทียบกับช่วงขนาดของพิกเซลในแต่ละช่วง โดยชุดข้อมูล MICCAI 2018 มีขนาดพิกเซลอยู่ในช่วง 50,000 พิกเซลเป็นจำนวนมาก และขนาดพิกเซลยังกว้างไปถึงระดับ 150,000 พิกเซล ที่ถึงแม้จะมีปริมาณน้อยกว่าแต่ก็เป็นหนึ่งในความหลากหลายทางข้อมูลของชุดข้อมูล ในขณะที่ชุดข้อมูล MICCAI 2017 มีช่วงพิกเซลอยู่ในช่วงไม่เกิน 20,000 พิกเซลเท่านั้น ซึ่งเป็นช่วงที่แคบกว่าอย่างเห็นได้ชัด รวมไปถึงปริมาณข้อมูลด้วย โดยอาจส่งผลถึงผลลัพธ์ของแบบจำลองด้วยเช่นกัน

ตาราง 14 เปรียบเทียบจำนวนรอยแผลต่อภาพของชุดข้อมูล MICCAI 2017 กับ MICCAI 2018

จำนวนรอยแผลต่อภาพ	0	1	2	3	4	5	6	7	8	9	14	17
จำนวนภาพบนชุดข้อมูล MICCAI 2017	300	235	40	17	4	2	1	0	0	0	0	0
จำนวนภาพบนชุดข้อมูล MICCAI 2018	600	903	190	57	33	15	4	3	1	3	2	1



รูป 27 เปรียบเทียบจำนวนภาพต่อจำนวนรอยโรคบนชุดข้อมูล MICCAI 2017 กับ MICCAI 2018



รูป 28 เปรียบเทียบจำนวนรอยโรคในหน่วยพิกเซลต่อภาพบนชุดข้อมูล MICCAI 2017 กับ MICCAI 2018

5.4.4 เปรียบเทียบผลลัพธ์แบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017 และ MICCAI 2018

ในส่วนนี้จะเป็นการแสดงการเปรียบเทียบผลลัพธ์ที่เป็นจำนวนรอยโรคที่แบบจำลองได้ทำนายไว้โดยใช้วิธีการนับจำนวนรอยเช่นเดียวกับการนับบนชุดข้อมูลจริงก่อนหน้านี้ การเปรียบเทียบจะใช้ข้อมูลจริงบนชุดข้อมูล MICCAI 2017 และ MICCAI 2018 กับแบบจำลองแบ่งส่วน และแบบจำลองร่วมกันเพื่อเปรียบเทียบผลลัพธ์ที่ได้จากการนับรอยแผลแทนการนับด้วยมาตรวัดปกติ รายละเอียดจำนวนรอยโรคบนชุดข้อมูล MICCAI 2017 ที่ได้จากแบบจำลองแต่ละแบบแสดงในตาราง 15 ตาราง 16 และรูป 29 รายละเอียดจำนวนรอยโรคบนชุดข้อมูล MICCAI 2018 แสดงในตาราง 17 ตาราง 18 และรูป 31 โดยจากการเปรียบเทียบด้วยจำนวนรอยโรคที่แต่ละแบบจำลองได้ทำนายออกมานั้นพบว่าแบบจำลองร่วมกันมีแนวโน้มในการทำนายภาพว่าไม่มีรอยโรคมกกว่าแบบจำลองแบ่งส่วนในทั้ง 2 ชุดข้อมูล ซึ่งอาจส่งผลให้ค่าจากมาตรวัด Dice และ IoU มีค่าที่สูงกว่าตามไปด้วย และด้วยการทำนายที่มีแนวโน้มจะทำนายภาพที่มีรอยโรคไปเป็นไม่มีรอยโรคนั้น อาจส่งผลเป็นปัญหาถึงการใช้งานจริงที่จะทำให้การตรวจสอบรอยโรคบนภาพที่มีรอยโรคจริงนั้นหลุดรอดไปได้ ซึ่งถึงแม้ว่าค่ามาตรวัดที่ใช้ Dice และ IoU จะได้ค่าที่ได้มากกว่าก็ตาม ค่าที่ได้ อาจไม่สะท้อนถึงผลลัพธ์ในการใช้งานจริง

ในส่วนของการเปรียบเทียบด้วยค่าจำนวนพิกเซลของรอยโรคด้วยแบบจำลองแบ่งส่วน และแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017 และ MICCAI 2018 แสดงอยู่ในรูป 30 และรูป 32 ตามลำดับ ในรูปจะแสดงให้เห็นถึงการทำนายผลลัพธ์เป็นจำนวนพิกเซลของรอยโรค เมื่อเปรียบเทียบกันแล้วพบว่าการทำนายของแบบจำลองแบ่งส่วน และแบบจำลองร่วมกันนั้นมีการทำนายผลลัพธ์ด้วยจำนวนพิกเซลที่ใกล้เคียงกัน และหากค่าที่ได้ซ้อนทับกับผลเฉลยของชุดข้อมูลนั้น ๆ อย่างชุดข้อมูล MICCAI 2017 ก็มีโอกาสนำค่าที่ได้โดยใช้มาตรวัด Dice กับ IoU สูงตามไปด้วย ในขณะที่บนชุดข้อมูล MICCAI 2018 แบบจำลองได้ทำนายผลลัพธ์ของรอยโรคเป็นพิกเซลได้ขนาดที่น้อยกว่าในชุดข้อมูลค่อนข้างมากคืออยู่ในช่วงไม่เกิน 30,000 พิกเซลเป็นส่วนใหญ่ แต่ในชุดข้อมูลนั้นมีรอยโรคที่มีขนาดมากกว่านั้นอยู่ค่อนข้างมาก ทำให้ผลลัพธ์ที่ได้จากค่ามาตรวัด Dice และ IoU มีค่าน้อยกว่าพอสมควร

จากผลการวิเคราะห์ข้างต้นสามารถสรุปการเปรียบเทียบแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันเป็นข้อ ๆ ได้ดังนี้

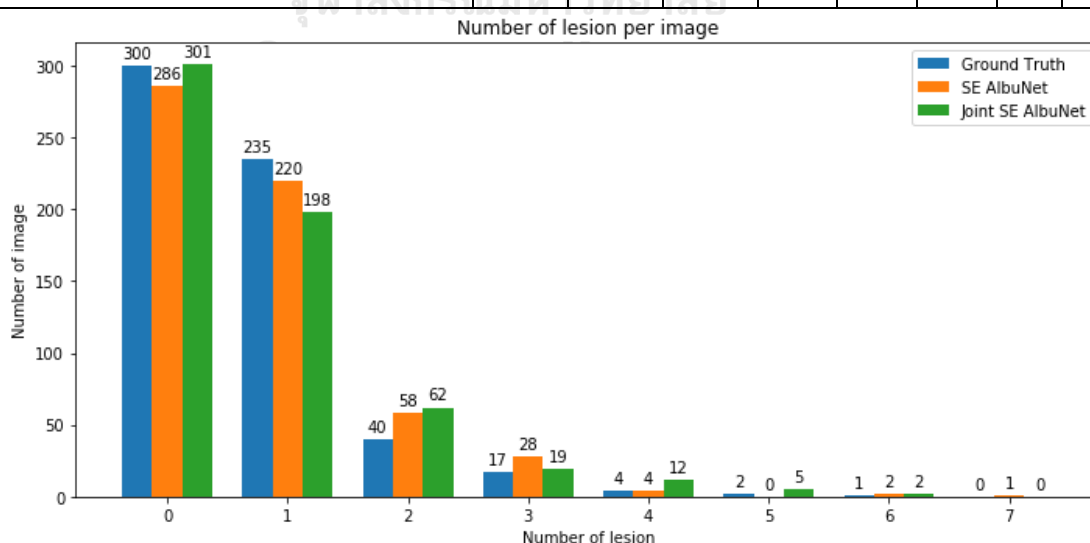
1. การเพิ่มตัวจำแนกประเภทให้กับแบบจำลองแบ่งส่วนเพียงอย่างเดียวกลายเป็นแบบจำลองร่วมกันสามารถเพิ่มประสิทธิภาพด้านการจำแนกประเภทของภาพที่มีรอยโรคกับภาพที่ไม่มีรอยโรคได้
2. เมื่อวัดประสิทธิภาพด้วยการนับจำนวนรอยโรคบนภาพโดยการจำแนกตามจำนวนรอยบนภาพพบว่าแบบจำลองแบ่งส่วนเพียงอย่างเดียวมีแนวโน้มการตรวจจับที่ดีกว่า
3. แบบจำลองทั้งสองแบบให้ค่าการทำนายจำนวนพิกเซลอยู่ในช่วงที่ค่อนข้างใกล้เคียงกัน

ตาราง 15 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017 แบบจำแนกประเภท

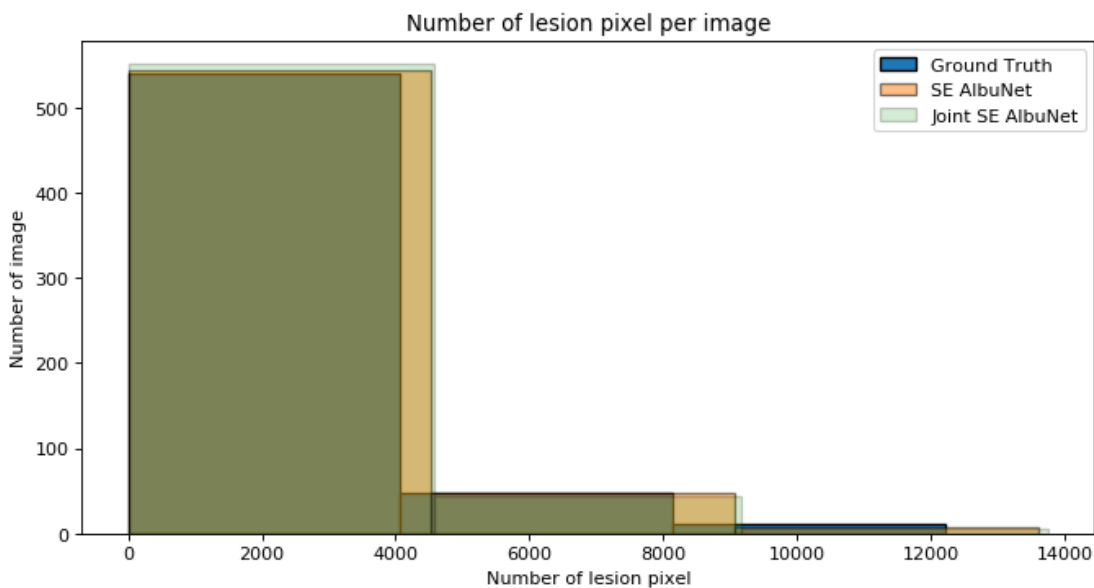
	ภาพที่ไม่มีรอยโรค	ภาพที่มีรอยโรค
จำนวนภาพบนชุดข้อมูล MICCAI 2017	300	299
จำนวนภาพที่ได้จากแบบจำลองแบ่งส่วน	286	313
จำนวนภาพที่ได้จากแบบจำลองร่วมกัน	301	298

ตาราง 16 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017 แบบแจกแจงจำนวนรอยโรค

จำนวนรอยต่อภาพ	0	1	2	3	4	5	6	7
จำนวนภาพบนชุดข้อมูล MICCAI 2017	300	235	40	17	4	2	1	0
จำนวนภาพที่ได้จากแบบจำลองแบ่งส่วน	286	220	58	28	4	0	2	1
จำนวนภาพที่ได้จากแบบจำลองร่วมกัน	301	198	62	19	12	5	2	0



รูป 29 เปรียบเทียบจำนวนภาพต่อจำนวนรอยโรคจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017



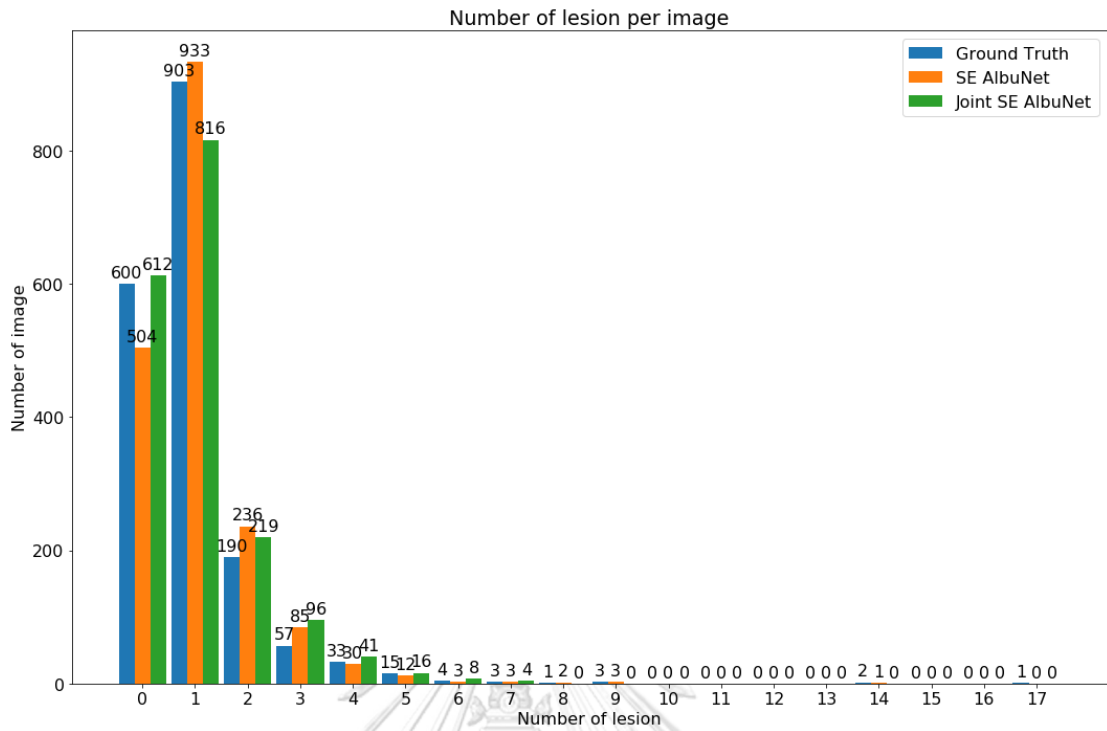
รูป 30 เปรียบเทียบจำนวนรอยโรคในหน่วยพิกเซลต่อภาพจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2017

ตาราง 17 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2018 แบบแจกแจงจำนวนรอยโรค

	ภาพที่ไม่มีรอยโรค	ภาพที่มีรอยโรค
จำนวนภาพบนชุดข้อมูล MICCAI 2018	600	1,212
จำนวนภาพที่ได้จากแบบจำลองแบ่งส่วน	504	1,308
จำนวนภาพที่ได้จากแบบจำลองร่วมกัน	612	1,200

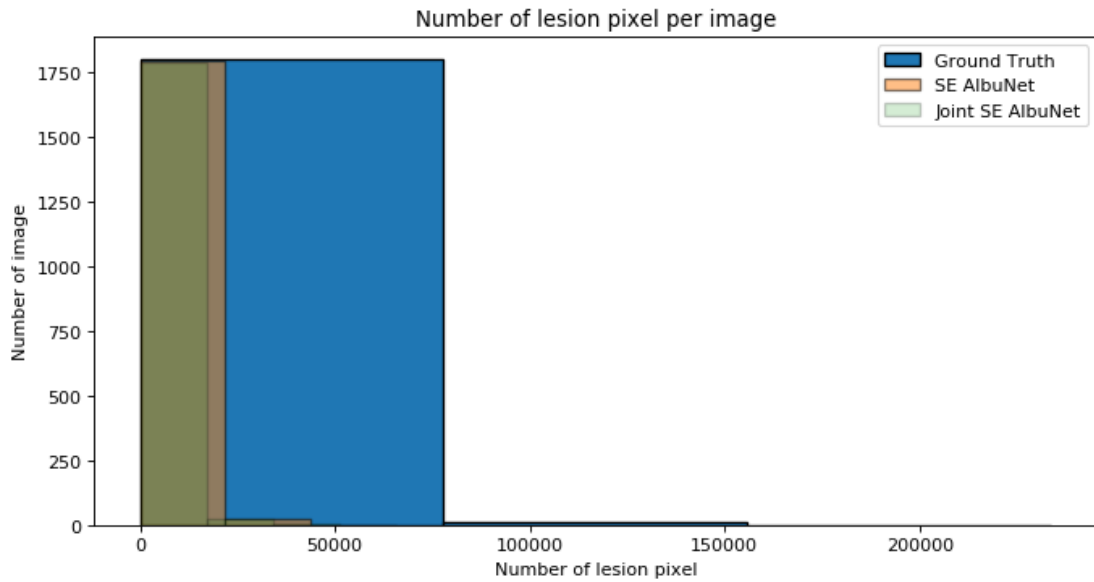
ตาราง 18 เปรียบเทียบผลลัพธ์จำนวนรอยโรคที่ได้จากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล MICCAI 2018 แบบแจกแจงจำนวนรอยโรค

จำนวนรอยแผลต่อภาพ	0	1	2	3	4	5	6	7	8	9	14	17
จำนวนภาพบนชุดข้อมูล MICCAI 2018	600	903	190	57	33	15	4	3	1	3	2	1
จำนวนภาพที่ได้จากแบบจำลองแบ่งส่วน	504	933	236	85	30	12	3	3	1	3	1	0
จำนวนภาพที่ได้จากแบบจำลองร่วมกัน	612	816	219	96	41	16	8	4	2	0	0	0



รูป 31 เปรียบเทียบจำนวนภาพต่อจำนวนรอยโรคจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุดข้อมูล

MICCAI 2018



รูป 32 เปรียบเทียบจำนวนรอยโรคในหน่วยพิกเซลต่อภาพจากแบบจำลองแบ่งส่วนกับแบบจำลองร่วมกันบนชุด

ข้อมูล MICCAI 2018

บทที่ 6

สรุปผลวิจัยและแนวทางวิจัยในขั้นถัดไป

6.1 สรุปผลการวิจัย

ในงานวิจัยนี้ได้นำเสนอวิธีแบ่งส่วนภาพงานโรคหลอดเลือดเฉื่อยเฉื่อยผิดปกติ โดยใช้แบบจำลองการเรียนรู้เชิงลึกที่เป็นโครงข่ายตัวเข้ารหัสตัวถอดรหัสที่มีการเพิ่มประสิทธิภาพด้วยการเพิ่มกลไกจุดสนใจ และการประมวลผลภาพเบื้องต้น และได้พัฒนาเพิ่มเติมโดยการนำแบบจำลองที่ได้ปรับปรุงแล้วมาสร้างแบบจำลองอีกสองแบบคือแบบจำลองเรียงซ้อน และแบบจำลองร่วมกันเพื่อ โดยมุ่งเน้นที่ประสิทธิภาพด้านความถูกต้องแม่นยำที่รวมถึงการตรวจจับภาพที่ปกติได้อย่างถูกต้อง จากผลลัพธ์ในการทดลองแสดงให้เห็นว่าแบบจำลองร่วมกันสามารถจำแนกประเภทภาพที่มีรอยโรค และไม่มีรอยโรคได้ด้วยค่า Accuracy Precision Recall F1 Dice และ IoU ที่สูงกว่าแบบจำลองที่นำมาเปรียบเทียบกับจากทั้งสองชุดข้อมูล โดยค่าที่ได้บนชุดข้อมูล MICCAI 2017 มีค่า Accuracy Precision Recall F1 ที่ 100% ทั้งหมด ในส่วน Dice มีค่า 92.16% และ IoU มีค่า และ 87.37% ค่าที่ได้บนชุดข้อมูล MICCAI 2018 มีค่า Accuracy ที่ 99.28% ค่า Precision ที่ 100% ค่า Recall ที่ 98.82% ค่า F1 ที่ 99.45% ค่า Dice ที่ 74.34% และค่า IoU ที่ 67.03% เมื่อเทียบค่าที่ได้ระหว่างชุดข้อมูลสองชุดค่า Dice และ IoU บนชุดข้อมูล MICCAI 2018 มีค่าที่ได้ลดลงพอสมควร สาเหตุจากการหลากหลายทางข้อมูลของชุดข้อมูล MICCAI 2018 ที่มีมากกว่า MICCAI 2017 ส่งผลให้ค่าคะแนนที่ได้จากมาตรวัดนั้นมีค่าที่ลดลง

การนำวิธีการสร้างแบบจำลองร่วมกันไปปรับใช้ในงานอื่นนั้นจำเป็นต้องคำนึงถึงการปรับค่าจำนวนชั้นสำหรับส่วนขอกออกการจำแนกประเภท และฟังก์ชันสูญเสียที่เพิ่มเติมขึ้นจากแบบจำลองต้นแบบซึ่งจะขึ้นอยู่กับงานที่ทำโดยตรง ซึ่งในงานนี้ได้ใช้ฟังก์ชันสูญเสียที่เป็น binary cross entropy ทั้งขาออกของข้อมูลทั้งสองข้าง ทำให้การรวมฟังก์ชันสูญเสียทำได้ไม่ยากนัก เนื่องจากเป็นฟังก์ชันสูญเสียประเภทที่ใกล้เคียงกัน และตรงกันกับที่ต้องทำ หากฟังก์ชันสูญเสียในแต่ละขาออกของแบบจำลองไม่สัมพันธ์กัน หรือมีช่วงค่าที่ต่างกันมาก อาจจำเป็นต้องปรับเปลี่ยนวิธีการรวมค่าฟังก์ชันสูญเสีย หรือต้องทดลองหาฟังก์ชันสูญเสียที่เหมาะสมกับแบบจำลองด้วยการทดลองที่มากขึ้น

6.2 แนวทางวิจัยถัดไป

แนวทางที่น่าสนใจสำหรับงานถัดไปเป็นงานทางด้านที่พัฒนาแบบจำลองร่วมกับการใช้งานจริงในโรงพยาบาล ซึ่งหากได้รับความอนุเคราะห์ในการร่วมมือให้ทดสอบแบบจำลองกับงานที่ทางโรงพยาบาลมีการใช้จริงจะสามารถพัฒนาแบบจำลอง หรือแอปพลิเคชันที่เป็นประโยชน์ต่อบุคคลากรที่เกี่ยวข้องกับงานทางด้านนี้ได้ นอกจากนี้การได้รับความคิดจากการใช้งานจริง หรือข้อเสนอแนะเพิ่มเติมจากผู้เชี่ยวชาญโดยตรงนั้นย่อมเป็นประโยชน์ต่อการพัฒนางานโดยตรง รวมถึงความเป็นไปได้ที่จะได้รับชุดข้อมูลใหม่ ๆ ที่สามารถนำมาพัฒนาแบบจำลองได้ดียิ่งขึ้นด้วย

นอกจากนี้ในส่วนของการวิเคราะห์สำรวจข้อมูลในเรื่องที่เกี่ยวกับการทำนายผลเป็นจำนวนพิกเซลรอยโรคต่อภาพนั้นยังพบว่าผลทำนายจากแบบจำลองมีค่าที่ใกล้เคียงกันซึ่งอาจเป็นผลมาจากการใช้ backbone ที่เหมือนกันคือ ResNet-34 และเป็นข้อจำกัดของแบบจำลองซึ่งหากปรับปรุงแล้วอาจได้ผลลัพธ์ที่แตกต่างจากเดิมได้

บรรณานุกรม

1. Hussein Al-Hamid, M.F., Department of Gastroenterology, Providence Hospital. *Angiodysplasia of the Colon*. 2019; Available from: <https://emedicine.medscape.com/article/170719-overview>.
2. Kim, S.H., et al., *Successful treatment of central retinal artery occlusion using hyperbaric oxygen therapy*. *Clinical and experimental emergency medicine*, 2018. **5**(4): p. 278-281.
3. Medical Advisory, S., *Wireless capsule endoscopy: an evidence-based analysis*. Ontario health technology assessment series, 2003. **3**(2): p. 1-35.
4. Fernandez-Urien, I., et al., *Capsule endoscopy capture rate: has 4 frames-per-second any impact over 2 frames-per-second?* *World journal of gastroenterology*, 2014. **20**(39): p. 14472-14478.
5. Noya, F., M.A. Álvarez-González, and R. Benitez. *Automated angiodysplasia detection from wireless capsule endoscopy*. in *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2017.
6. Sophie M. Balzora, M. *What's scarier than a colonoscopy?* 2013, May 27; Available from: <https://www.kevinmd.com/blog/2013/05/whats-scarier-colonoscopy.html>.
7. MICCAI 2018 Endoscopic Vision Challenge. *ANGIODYSPLASIA DETECTION AND LOCALIZATION*. 2018; Available from: <https://giana.grand-challenge.org/WCE/>.
8. Bernal, J., S-nchez, F. J., Fern-ndez-Esp-rach. G and Rodríguez, C., *CVC-ClinicDB*.
9. Ronneberger, O., P. Fischer, and T. Brox. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. 2015. Cham: Springer International Publishing.
10. Oktay, O., et al., *Attention U-Net: Learning Where to Look for the Pancreas*. 2018.
11. Mohammed, A.K., et al., *Y-Net: A deep Convolutional Neural Network for Polyp Detection*. *CoRR*, 2018. **abs/1806.01907**.
12. Shvets, A.A., et al. *Angiodysplasia Detection and Localization Using Deep Convolutional Neural Networks*. in *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*. 2018.
13. Mo, X., et al. *An Efficient Approach for Polyps Detection in Endoscopic Videos Based on Faster R-CNN*. arXiv e-prints, 2018.
14. MICCAI 2017 Endoscopic Vision Challenge. *ANGIODYSPLASIA DETECTION AND LOCALIZATION*. 2017; Available from: <https://endovissub2017-giana.grand-challenge.org/Angiodysplasia-ETISDB/>.

15. Dray, X., et al., *CAD-CAP: une base de données française à vocation internationale, pour le développement et la validation d'outils de diagnostic assisté par ordinateur en vidéocapsule endoscopique du grêle*. Vol. 50. 2018.
16. R. Leenhardt, C.L., J.P. Le Mouel, G. Rahmi, J.C. Saurin, F. Cholet, C. Leandri, S. Leclaire, X. Amiot, J.M. Delvaux, C. Duburque, R. Gérard, F. Mesli, G. Vanbiervliet, I. Nion Larmurier, S. Sacher- Huvelin, C. Simon-Chane, O. Romain , A. Histace, X. Dray, *CAD-CAP: a 25000 Images Database Serving the Development of Artificial Intelligence for Capsule Endoscopy*. Endoscopy international Open, 2020 (in press).
17. Pawara, P., et al., *Data Augmentation for Plant Classification*. 2017.
18. Krizhevsky, A., I. Sutskever, and G. Hinton, *ImageNet Classification with Deep Convolutional Neural Networks*. Neural Information Processing Systems, 2012. **25**.
19. Zuiderveld, K., *Contrast limited adaptive histogram equalization*, in *Graphics gems IV*, S.H. Paul, Editor. 1994, Academic Press Professional, Inc. p. 474-485.
20. He, K., et al. *Mask R-CNN*. in *2017 IEEE International Conference on Computer Vision (ICCV)*. 2017.
21. Girshick, R., et al., *Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2013.
22. Girshick, R., *Fast R-CNN*, in *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)*. 2015, IEEE Computer Society. p. 1440–1448.
23. Ren, S., et al., *Faster R-CNN: towards real-time object detection with region proposal networks*, in *Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 1*. 2015, MIT Press: Montreal, Canada. p. 91–99.
24. Johnson, J.W. *Adapting Mask-RCNN for Automatic Nucleus Segmentation*. arXiv e-prints, 2018.
25. Qadir, H.A., et al. *Polyp Detection and Segmentation using Mask R-CNN: Does a Deeper Feature Extractor CNN Always Perform Better?* arXiv e-prints, 2019.
26. Kang, J. and J. Gwak, *Ensemble of Instance Segmentation Models for Polyp Segmentation in Colonoscopy Images*. IEEE Access, 2019. **7**: p. 26440-26447.
27. Iglovikov, V. and A. Shvets, *TernausNet: U-Net with VGG11 Encoder Pre-Trained on ImageNet for Image Segmentation*. 2018.
28. Simonyan, K. and A. Zisserman, *Very Deep Convolutional Networks for Large-Scale Image Recognition*. arXiv 1409.1556, 2014.
29. Yosinski, J., et al., *How transferable are features in deep neural networks?*, in *Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume*

2. 2014, MIT Press: Montreal, Canada. p. 3320-3328.
30. He, K., et al. *Deep Residual Learning for Image Recognition*. in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016.
31. Hu, J., L. Shen, and G. Sun. *Squeeze-and-Excitation Networks*. in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2018.
32. Xu, K., et al., *Show, attend and tell: neural image caption generation with visual attention*, in *Proceedings of the 32nd International Conference on International Conference on Machine Learning - Volume 37*. 2015, JMLR.org: Lille, France. p. 2048-2057.
33. Iglovikov, V., S. Mushinskiy, and V. Osin, *Satellite Imagery Feature Detection using Deep Convolutional Neural Network: A Kaggle Competition*. 2017.





จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล

สิริชาติ กอบประดิษฐ์

วัน เดือน ปี เกิด

20 มีนาคม 2533

ที่อยู่ปัจจุบัน

88/17 ซอยรามอินทรา 13 ถนนรามอินทรา แขวงอนุสาวรีย์ เขตบางเขน
กรุงเทพมหานคร 10220



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY