



การปรับปรุงความแม่นยำในการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อแผลโดยการฝึกแบบเน้นเจาะจง
พื้นที่



โดย
นายชนก ปฐมเพทาย

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาเทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญาโทมหาบัณฑิต
ภาควิชาคอมพิวเตอร์

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

ปีการศึกษา 2563

ลิขสิทธิ์ของบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร



การปรับปรุงความแม่นยำในการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อแผลโดยการฝึกแบบเน้น
เจาะจงพื้นที่



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาเทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญาโทมหาบัณฑิต
ภาควิชาคอมพิวเตอร์
บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร
ปีการศึกษา 2563
ลิขสิทธิ์ของบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

ACCURACY IMPROVEMENT FOR SEGMENTATION AND CLASSIFICATION OF
WOUND TISSUES THROUGH REGION-FOCUS TRAINING



A Thesis Submitted in Partial Fulfillment of the Requirements
for Master of Science (INFORMATION TECHNOLOGY)
Department of COMPUTER SCIENCE
Graduate School, Silpakorn University
Academic Year 2020
Copyright of Graduate School, Silpakorn University

หัวข้อ การปรับปรุงความแม่นยำในการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อ
ผลโดยการฝึกแบบเน้นเจาะจงพื้นที่

โดย ชนก ปฐมเพทาย

สาขาวิชา เทคโนโลยีสารสนเทศ แผนก ก แบบ ก 2 ระดับปริญญา
มหาบัณฑิต

อาจารย์ที่ปรึกษาหลัก ผู้ช่วยศาสตราจารย์ ดร. ภิญโญ แท้ประสาทสิทธิ์

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร ได้รับพิจารณาอนุมัติให้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรวิทยาศาสตรมหาบัณฑิต

..... คณบดีบัณฑิตวิทยาลัย
(รองศาสตราจารย์ ดร.จุไรรัตน์ นันทานิช)

พิจารณาเห็นชอบโดย

..... ประธานกรรมการ
(อาจารย์ ดร.อภิรักษ์ หุ่นหล่อ)

..... อาจารย์ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.ภิญโญ แท้ประสาทสิทธิ์)

..... ผู้ทรงคุณวุฒิภายใน
(ผู้ช่วยศาสตราจารย์ ดร.สุนีย์ พงษ์พินิจภิญโญ)

..... ผู้ทรงคุณวุฒิภายใน
(อาจารย์ ดร.รัชดาพร คณาวงษ์)

60309203 : เทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญาโทบัณฑิต

คำสำคัญ : การแยกพื้นที่ภาพ, การเพิ่มปริมาณข้อมูล, การเรียนรู้เชิงลึก, การเรียนรู้ของเครื่อง,
โครงข่ายประสาทเทียม

นาย ชนก ปฐมเพทาย: การปรับปรุงความแม่นยำในการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อ
แผลโดยการฝึกแบบเน้นเจาะจงพื้นที่ อาจารย์ที่ปรึกษาวิทยานิพนธ์ : ผู้ช่วยศาสตราจารย์ ดร. ภิญโญ
แท้ประสาทสิทธิ์

การทำพื้นที่บาดแผลเรื้อรังจากภาพถ่ายทำให้ติดตามผลการรักษาได้โดยไม่ต้องสัมผัส
กับแผลและไม่สร้างปัญหาเสี่ยงติดเชื้อเมื่อเทียบกับวิธีลอกกลาย รวมถึงมีความแม่นยำที่เพิ่มมากขึ้นกว่า
การใช้ไม้บรรทัดกะประมาณขนาด อย่างไรก็ตามเนื้อเยื่อแผลมีหลายชนิดและสัดส่วนของเนื้อเยื่อ
สำคัญต่อการเลือกการรักษา เพื่ออำนวยความสะดวกในการเลือกการรักษา งานวิจัยนี้มีวัตถุประสงค์
เพื่อเพิ่มความแม่นยำในการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อแผลจากภาพถ่ายโดยการฝึกตัวแบบรู้จำ
เชิงลึกกับตัวอย่างที่มีความท้าทายให้มากขึ้น ซึ่งตัวอย่างที่ท้าทายนี้เป็นการคัดเลือกพื้นที่ย่อยภายใน
ออกมาจากความละเอียดสูง เนื้อเยื่อแผลที่ต้องการจำแนกมี 3 ประเภทคือ 1.เนื้อเยื่อเนื้อแดง
(Granulation) 2.เนื้อเยื่อหนอง (Slough) และ 3.เนื้อเยื่อเนื้อตาย (Necrosis)

งานวิจัยนี้ใช้วิธีการแบ่งภาพออกเป็นภาพย่อย (Sub-images) และให้ตัวแบบแยกพื้นที่
ในภาพย่อย จากนั้นจะรวมข้อมูลการแยกพื้นที่จากภาพย่อยให้มีขนาดสอดคล้องกับภาพต้นฉบับ จาก
ผลการแยกพื้นที่ในความละเอียดของภาพต้นฉบับ วิธีการที่นำเสนอจะค้นหาตัวอย่างที่มีความท้าทาย
และเน้นฝึกไปในพื้นที่เหล่านี้ (Region-Focus Training) การค้นหาพื้นที่ที่ท้าทายดำเนินการจากแผน
ที่ความร้อนแสดงความผิดพลาดของการทำนาย (Error Heatmap) ซึ่งกระบวนการสร้างชุดข้อมูล
ฝึกสอนเพิ่มเติมแบบเน้นตามพื้นที่นี้สามารถสร้างภาพย่อยเพิ่มเติมขึ้นมาได้เป็นจำนวนมาก แต่ทว่า
สัดส่วนของภาพที่สร้างขึ้นกับภาพย่อยดั้งเดิมมีผลต่อความแม่นยำ งานวิจัยนี้จึงศึกษาหาสัดส่วนที่
เหมาะสมและมีการเปรียบเทียบกับวิธีที่ไม่ได้เพิ่มพื้นที่ภาพแบบเน้นฝึกไปในพื้นที่ ผลการทดลองสรุป
ได้ว่าการเพิ่มตัวอย่างด้วยวิธีนี้ให้ความแม่นยำที่มากขึ้นกว่าวิธีการดั้งเดิมเสมอ โดยความแม่นยำ
เพิ่มขึ้นมากที่สุดเมื่อเพิ่มจำนวนตัวอย่างด้วยวิธีเน้นฝึกไปในพื้นที่เป็นจำนวนร้อยละ 75 ของชุดข้อมูล
แบบดั้งเดิมและสามารถเพิ่มค่า F1-score ได้ 0.0107, 0.0216 และ 0.1284 ในการทำนายเนื้อเยื่อ
เนื้อแดง เนื้อเยื่อหนองและเนื้อเยื่อเนื้อตายตามลำดับ นอกจากนี้ยังสามารถเพิ่มความแม่นยำใน
ตัวชี้วัด Intersection over Union (IoU) ได้ 4.2% และในตัวชี้วัด Dice Similarity Coefficient
(DSC) ได้ 4.11% อีกทั้งยังสามารถลดค่าความผิดพลาดในการวัดขนาดพื้นที่ได้ 38.01% และ
59.12% สำหรับการแยกพื้นที่แบบระบุเนื้อเยื่อและการแยกพื้นที่บาดแผลโดยไม่ระบุเนื้อเยื่อ

ตามลำดับ



60309203 : Major (INFORMATION TECHNOLOGY)

Keyword : image segmentation, data augmentation, deep learning, machine learning, neural network

MR. CHANOK PATHOMPATAI : ACCURACY IMPROVEMENT FOR SEGMENTATION AND CLASSIFICATION OF WOUND TISSUES THROUGH REGION-FOCUS TRAINING THESIS
ADVISOR : ASSISTANT PROFESSOR PINYO TAEPRASARTSIIT, Ph.D.

Segmentation of chronic wound regions from an image aids in following up a wound-healing process without a wound contact. Unlike a wound tracing method, the image-based method imposes no risk of infection. This method is also more accurate than using a scale to assess the wound size. However, there are several wound-tissue types and the proportion of these tissue types is important for selecting a proper wound-treatment method. To that end, our research goal is to increase the accuracy of wound-tissue segmentation and classification in images by training a deep neural network model with more challenging samples. These challenging samples are the selection of sub-areas from high resolution. We separate the wound tissue into 3 types: (1) Granulation, (2) Slough and (3) Necrosis.

To segment wound areas from an image, we divide an input image into sub-images and segment each sub-region. Next, we combine segmentation outputs from sub-images into an image whose size is the same as the original one. From results in original image resolution, the proposed method finds challenging regions and focuses model training on these areas. It creates an error heatmap and produces additional training samples from regions with high segmentation errors. The process of producing additional training sub-images based on the proposed method can create a large number of additional sub-images. However, the ratio of the number of created images and the number of original sub-images has an impact on accuracy. This work also finds a suitable ratio and compares it with a baseline method that does not rely on challenging samples. The results indicated that our proposed method was always more accurate than the traditional one. Accuracy increased the most when adding samples produced by proposed Region-Focus Training by 75% of the original sub-images. This improved F1-scores by 0.0107, 0.0216 and 0.1284 in

segmentation of granulation, slough and necrosis tissues, respectively. It improved the accuracy in terms of Intersection over Union (IoU) by 4.2% and Dice Similarity Coefficient (DSC) by 4.11%. Also, it reduced area-measurement errors by 38.01% and 59.12% in tissue and wound segmentations.



กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงได้ด้วยคามอนุเคราะห์จาก ผศ.ดร. ภิญโญ แท้ประสาทสิทธิ์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ท่านให้ความรู้ คำปรึกษา คำแนะนำและกำลังใจ โดยเฉพาะอย่างยิ่งท่านช่วยค้นหาฐานข้อมูลและแอปพลิเคชันซึ่งเป็นประโยชน์อย่างมากในการทำวิจัย อีกทั้งช่วยตรวจสอบและแสดงให้เห็นถึงข้อผิดพลาดต่าง ๆ ขณะทำวิจัยและเขียนวิทยานิพนธ์ ท่านใส่ใจในการดูแลและให้คำปรึกษาเป็นอย่างดี ขอกราบขอบพระคุณท่านเป็นอย่างสูง นอกจากนี้ผู้วิจัยขอกราบขอบคุณเว็บไซต์ <http://medetec.co.uk> และโรงพยาบาลรามาริธิดีอย่างสูงที่ให้ข้อมูลภาพบาดแผลต่าง ๆ ที่ใช้เพื่อทำงานวิจัย ซึ่งมีส่วนสำคัญอย่างมากที่ทำให้วิทยานิพนธ์นี้สำเร็จลุล่วง นอกจากนี้ขอกราบขอบพระคุณผู้ป่วยซึ่งอนุญาตให้ถ่ายภาพบาดแผลและให้นำภาพบาดแผลเหล่านั้นมาวิจัยได้

ผู้วิจัยขอกราบขอบพระคุณบุพการีและสาขาเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากรที่มอบโอกาสในการศึกษาจนประสบความสำเร็จ ขอขอบคุณอาจารย์และเพื่อนทุกท่านที่ช่วยเหลือ ให้กำลังใจและสนับสนุนจนผู้วิจัยซึ่งทำให้สามารถทำวิทยานิพนธ์สำเร็จลุล่วง

ท้ายที่สุดผู้วิจัยหวังเป็นอย่างยิ่งว่าวิทยานิพนธ์นี้จะเป็นประโยชน์ต่อผู้ที่สนใจซึ่งสามารถนำไปประยุกต์ใช้และต่อยอดการเรียน การสอนและการทำงานได้อย่างมีประสิทธิภาพและเกิดประสิทธิผลมากที่สุด หากมีข้อผิดพลาดประการใดผู้วิจัยขออภัยมา ณ ที่นี้ด้วย



ชนก ปฐมเพทาย

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	ฉ
กิตติกรรมประกาศ.....	ช
สารบัญ.....	ฅ
สารบัญตาราง.....	ฉ
สารบัญภาพ.....	ฐ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	4
1.3 สมมติฐานของงานวิจัย.....	4
1.4 ขอบเขตของการวิจัย.....	4
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	4
บทที่ 2 งานวิจัยที่เกี่ยวข้อง.....	5
2.1 A Unified Framework for Automatic Wound Segmentation and Analysis with Deep Convolutional Neural Networks [3].....	5
2.2 U-net: Convolutional Networks for Biomedical Image Segmentation [8].....	7
2.3 Deep convolutional neural networks for automatic segmentation of left ventricle cavity from cardiac magnetic resonance images [9].....	9
2.4 Deep Residual Learning for Image Recognition [10].....	12
บทที่ 3 ทฤษฎีที่เกี่ยวข้อง.....	19
3.1 การให้ความหมายแต่ละพิกเซล (Semantic Segmentation).....	19
3.2 การเรียนรู้เชิงลึก (Deep Learning).....	19

3.3 การสร้างภาพผลเฉลย	19
3.4 การสร้างภาพย่อย (Sub-images).....	21
3.5 การประเมินผล (Evaluation).....	21
บทที่ 4 วิธีการดำเนินงานวิจัย	24
4.1 การจัดเตรียมข้อมูล (Data Preparation).....	25
4.2 สถาปัตยกรรมของโครงข่ายประสาทเทียม	30
4.3 กลไกการฝึกสอนตัวแบบรู้จำเชิงลึก.....	31
4.4 การแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผล	32
4.5 Region-Focus Training [2].....	33
4.6 ภาพรวมของระบบการทดลอง.....	37
บทที่ 5 ผลการดำเนินการวิจัย.....	39
5.1 การฝึกสอนตัวแบบรู้จำเชิงลึก	39
5.2 Region-Focus Training.....	41
5.3 การประเมินผล (Evaludation).....	44
บทที่ 6 สรุปผลการดำเนินงานวิจัยและข้อเสนอแนะ	52
รายการอ้างอิง	54
ประวัติผู้เขียน.....	57

สารบัญตาราง

	หน้า
ตารางที่ 1 ผลลัพธ์ของวิธีการ SVM [7] และ Convolutional Network (ConvNet).....	6
ตารางที่ 2 ผลลัพธ์ของการตรวจหาการติดเชื้อ.....	6
ตารางที่ 3 ผลลัพธ์ของการทำนายจำนวนวันในการรักษาในอนาคต.....	7
ตารางที่ 4 ผลการแข่งขัน ISBI cell tracking challenge 2015.....	8
ตารางที่ 5 ความแตกต่างของการทดลอง.....	10
ตารางที่ 6 ผลลัพธ์การเปรียบเทียบการทดลองในหน่วย IoU(DM).....	10
ตารางที่ 7 ผลลัพธ์การแข่งขัน MICCAI 2009 LV Challenge.....	11
ตารางที่ 8 ผลลัพธ์ Top-1 error (% , 10-crop testing) จากชุดข้อมูลตรวจสอบ (ImageNet validation set).....	14
ตารางที่ 9 ผลลัพธ์ Error rates (% , 10-crop testing) ทดสอบกับชุดข้อมูลตรวจสอบ (ImageNet validation set).....	15
ตารางที่ 10 ผลลัพธ์ Error rates (%) ของ single model ทดสอบกับชุดข้อมูลตรวจสอบ (ImageNet validation set).....	16
ตารางที่ 11 ผลลัพธ์ Error rates (%) ทดสอบกับชุดข้อมูลทดสอบ (ImageNet testing set).....	16
ตารางที่ 12 ผลลัพธ์ Classification error ทดสอบกับชุดข้อมูลทดสอบ (CIFAR-10 testing set) โดยทดลองทั้งหมด 5 ครั้งและแสดงผลลัพธ์ในรูปแบบ best(mean±std).....	17
ตารางที่ 13 ผลลัพธ์ของงาน Object Detection ในหน่วย mAP(%) ทดสอบกับชุดข้อมูลทดสอบ (PASCAL VOC 2007/2012 testing set).....	18
ตารางที่ 14 ผลลัพธ์ของงาน Object Detection ในหน่วย mAP(%) ทดสอบกับชุดข้อมูลตรวจสอบ (MS COCO validation set).....	18
ตารางที่ 15 การแสดงผลของ Confusion Matrix.....	22
ตารางที่ 16 จำนวนภาพต้นฉบับของแต่ละชุดข้อมูล.....	28
ตารางที่ 17 จำนวนตัวอย่างในชุดข้อมูลฝึกสอนและตรวจสอบ.....	29

ตารางที่ 18 ตัวอย่างการสร้างตัวแทนของพิกเซลได้จากการทับซ้อนกันของภาพย่อย 4 ภาพ..... 33

ตารางที่ 19 ผลลัพธ์ทดสอบกับชุดข้อมูลภาพต้นฉบับ..... 40

ตารางที่ 20 จำนวนข้อมูลในชุดข้อมูลใหม่ที่ได้จากวิธีการ Region-Focus Training 41

ตารางที่ 21 ค่า precision, recall และ F1-score ของการทำนายพื้นหลัง (background)..... 45

ตารางที่ 22 ข้อมูลผลเฉลย (จำนวนพิกเซล) 45

ตารางที่ 23 ค่า precision, recall และ F1-score ของการทำนายเนื้อเยื่อเนื้อแดง (granulation)..... 46


ตารางที่ 24 ค่า precision, recall และ F1-score ของการทำนายเนื้อเยื่อหนอง (slough)..... 46

ตารางที่ 25 ค่า precision, recall และ F1-score ของการทำนายเนื้อเยื่อเนื้อตาย (necrosis)..... 47

ตารางที่ 26 ผลลัพธ์การแยกพื้นที่เฉลี่ยแต่ละเนื้อเยื่อโดยไม่รวมพื้นหลัง..... 48

ตารางที่ 27 ผลลัพธ์การแยกพื้นที่ในหน่วย RSE แบบแยกชนิดเนื้อเยื่อและแบบขาดแผล 49

ตารางที่ 28 ค่าสหสัมพันธ์ (correlation) ระหว่างอัตราส่วนของขาดแผลในภาพกับค่า RSE แบบรวมบนชุดข้อมูลทดสอบ (testing set)..... 51



สารบัญภาพ

หน้า

ภาพที่ 1 ตัวอย่างเนื้อเยื่อเนื้อแดง (Granulation) (ภาพจาก Medetec Medical image database [1]).....	1
ภาพที่ 2 ตัวอย่างเนื้อเยื่อหนอง (Slough) (ภาพจาก Medetec Medical image database [1])... 2	
ภาพที่ 3 ตัวอย่างเนื้อเยื่อเนื้อตาย (Necrosis) (ภาพจาก Medetec Medical image database [1])	2
ภาพที่ 4 ตัวอย่างบาดแผลเรื้อรังที่ประกอบไปด้วยเนื้อเยื่อเนื้อแดง เนื้อเยื่อหนองและเนื้อเยื่อเนื้อตาย (ภาพจาก Medetec Medical image database [1]).....	3
ภาพที่ 5 ภาพรวมของระบบอัตโนมัติเพื่อวิเคราะห์ภาพบาดแผล (ภาพจาก [3])	5
ภาพที่ 6 สถาปัตยกรรมของโครงข่ายประสาทเทียม (Convolutional encoder-decoder network) (ภาพจาก [3]).....	5
ภาพที่ 7 สถาปัตยกรรมของโครงข่ายประสาทเทียม (ภาพจาก [8]).....	8
ภาพที่ 8 สถาปัตยกรรมของ Regression Model (ภาพจาก [9]).....	9
ภาพที่ 9 ภาพรวมของระบบการแยกพื้นที่ LV cavity (ภาพจาก [9])	9
ภาพที่ 10 Residual learning: a building block (ภาพจาก [10]).....	12
ภาพที่ 11 สถาปัตยกรรม VGG-19 (ภาพซ้าย), Plain Network (ภาพกลาง) และ Residual Network (ภาพขวา) (ภาพจาก [10]).....	13
ภาพที่ 12 สถาปัตยกรรมต่าง ๆ ในงานชิ้นนี้ โดย shortcut อยู่ที่เครื่องหมายช่วงปิด (ภาพจาก [10])	14
ภาพที่ 13 กราฟแสดงผลการฝึกสอนโดยเส้นบางได้จากข้อมูลฝึกสอน (training set) และเส้น หนาได้จากข้อมูลตรวจสอบ (validation set).....	14
ภาพที่ 14 นำเข้ารูปภาพสู่โปรแกรม MultiMarker v1.1	20
ภาพที่ 15 ระบุพื้นที่เป้าหมาย (พื้นที่สีเขียว).....	20
ภาพที่ 16 ตัวอย่างภาพผลเฉลย (ภาพขวา).....	20

ภาพที่ 17 ตัวอย่างการสร้างภาพย่อย (Sub-images) ในที่นี้เลือกภาพย่อยขนาด 256x256 โดยมีการทับซ้อนกันของภาพย่อย (overlapping).....	21
ภาพที่ 18 ภาพตัวอย่างจาก Medetec Medical image database [1].....	25
ภาพที่ 19 ภาพตัวอย่างจากโรงพยาบาลรามาริบัติ	26
ภาพที่ 20 ตัวอย่างการสร้างภาพผลเฉลยจากภาพต้นฉบับ (ภาพผลเฉลยประกอบไปด้วยค่า 0, 1, 2 และ 3 ซึ่งแทนชนิดเนื้อเยื่อบาดแผล)	27
ภาพที่ 21 ตัวอย่างการประยุกต์ใช้วิธีการสร้างภาพย่อย (Sub-images).....	29
ภาพที่ 22 Residual learning: shortcut.....	30
ภาพที่ 23 สถาปัตยกรรมโครงข่ายประสาทเทียม U-Net ที่ประยุกต์กับ ResNet.....	31
ภาพที่ 24 ภาพรวมของระบบการแยกพื้นที่และจำแนกเนื้อเยื่อบาดแผลเรื้อรัง	32
ภาพที่ 25 ตัวอย่างการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผล	35
ภาพที่ 26 ตัวอย่างแผนที่ความไม่ถูกต้อง (ภาพซ้าย) โดยค่าทั้งหมดเป็น 0 หรือ 1 และตัวอย่างของแผนที่ความมั่นใจ (ภาพขวา) โดยค่าทั้งหมดอยู่ในช่วง [0, 1].....	35
ภาพที่ 27 ตัวอย่างแผนที่ความผิดพลาด (Error Heatmap) แสดงความมั่นใจในการทำนายพิกเซลที่ทำนายไม่ถูกต้อง	35
ภาพที่ 28 ค่า training loss และ validation loss	39
ภาพที่ 29 ค่า training IoU, training dice, validation IoU และ validation dice.....	39
ภาพที่ 30 ค่า training accuracy และ validation accuracy	40
ภาพที่ 31 กราฟแสดงค่า training loss.....	42
ภาพที่ 32 กราฟแสดงค่า validation loss	42
ภาพที่ 33 กราฟแสดงค่า training IoU.....	43
ภาพที่ 34 กราฟแสดงค่า validation IoU	43
ภาพที่ 35 ตัวอย่างภาพที่ให้ค่า RSE แบบบาดแผลมากผิดปกติโดยค่า RSE ของภาพบน ภาพกลาง และภาพล่างมีค่า 440.771, 654.627 และ 270.111 ตามลำดับ	50

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

บาดแผลเรื้อรัง (Chronic wound) หมายถึงบาดแผลที่ไม่สามารถรักษาให้หายได้ตามลำดับ และทันเวลาภายในระยะเวลา 4-6 สัปดาห์ ซึ่งสาเหตุที่ส่งผลให้ไม่สามารถรักษาให้หายได้ทันเวลาอาจมาจากปัจจัยด้วยผู้ป่วยหรือปัจจัยด้านสิ่งแวดล้อม การรักษาตัวที่ล่าช้าเป็นปัญหาที่พบบ่อยในผู้ป่วยโรคเบาหวาน ผู้ป่วยอัมพาตที่มีปัญหาเกี่ยวกับการเคลื่อนไหวและผู้สูงอายุ บาดแผลเรื้อรังมักพบเป็นภาวะแทรกซ้อนในผู้ป่วยที่ต้องนอนโรงพยาบาลเป็นเวลานาน บาดแผลเรื้อรังเกิดจากการมีเลือดมาเลี้ยงเนื้อเยื่อบาดแผลไม่เพียงพอ การกดทับหลอดเลือด หลอดเลือดอักเสบหรือเส้นประสาทรับความรู้สึกอักเสบ สาเหตุการบาดแผลเรื้อรังแบ่งออกเป็น 4 ประเภทคือบาดแผลเรื้อรังจากแผลโรคเบาหวาน (Diabetic ulcers) บาดแผลเรื้อรังจากแผลกดทับ (Pressure ulcers) บาดแผลเรื้อรังจากภาวะหลอดเลือดตีบ (Venous and arterial ulcers) และบาดแผลเรื้อรังจากบาดแผลที่เกิดกับผู้ป่วยสูงอายุ (Elderly ulcers) เนื้อเยื่อบาดแผลเรื้อรังแบ่งออกเป็น 3 ประเภทคือ เนื้อเยื่อเนื้อแดง (Granulation) เนื้อเยื่อหนอง (Slough) และเนื้อเยื่อเนื้อตาย (Necrosis)



ภาพที่ 1 ตัวอย่างเนื้อเยื่อเนื้อแดง (Granulation) (ภาพจาก Medetec Medical image database [1])



ภาพที่ 2 ตัวอย่างเนื้อเยื่อหนอง (Slough) (ภาพจาก Medetec Medical image database [1])



ภาพที่ 3 ตัวอย่างเนื้อเยื่อเน่าตาย (Necrosis) (ภาพจาก Medetec Medical image database [1])

ภาพที่ 1 คือภาพตัวอย่างของบาดแผลเรื้อรังที่มีเนื้อเยื่อเนื้อแดง เนื้อเยื่อเนื้อแดงเป็นเนื้อเยื่อที่ถูกสร้างขึ้นใหม่และมีลักษณะเป็นสีแดง เนื้อเยื่อประเภทนี้บ่งบอกถึงกระบวนการฟื้นตัวของบาดแผล ภาพที่ 2 คือภาพตัวอย่างของบาดแผลเรื้อรังที่มีเนื้อเยื่อหนอง เนื้อเยื่อหนองมีลักษณะเป็นสีเหลือง ซึ่งประกอบไปด้วยไฟบริน หนองและโปรตีน ภาพที่ 3 คือภาพตัวอย่างของบาดแผลเรื้อรังที่มีเนื้อเยื่อเน่าตาย เนื้อเยื่อเน่าตายมีลักษณะเป็นสีดำ บ่งบอกว่ามีเลือดมาเลี้ยงเนื้อเยื่อไม่เพียงพอ อาจมีสาเหตุจากอาการเส้นเลือดตีบหรืออุดตัน บาดแผลเรื้อรังสามารถมีเนื้อเยื่อหลายชนิดอยู่รวมกันในบาดแผลเดียว ซึ่งตัวอย่างบาดแผลเรื้อรังที่มีหลายเนื้อเยื่อรวมกันถูกแสดงอยู่ในภาพที่ 4



ภาพที่ 4 ตัวอย่างบาดแผลเรื้อรังที่ประกอบไปด้วยเนื้อเยื่อเนื้อแดง เนื้อเยื่อหนองและเนื้อเยื่อเนื้อตาย
(ภาพจาก Medetec Medical image database [1])

การรักษาบาดแผลเรื้อรังสร้างปัญหามากมายให้กับผู้ป่วย ผู้ป่วยที่มีบาดแผลเรื้อรังได้รับความเจ็บปวด ทรมานและบอบช้ำทั้งทางด้านร่างกายและจิตใจ นอกจากนี้ยังสร้างความลำบากให้กับผู้ป่วยที่ต้องเดินทางมาสถานพยาบาลเพื่อเข้ารับการรักษาเป็นประจำหรือกับผู้ป่วยที่อาศัยอยู่ในพื้นที่ห่างไกลจากสถานพยาบาล เช่น ผู้ป่วยเป็นผู้สูงอายุ ผู้พิการหรือผู้ป่วยมีบาดแผลบริเวณเท้าที่ไม่สามารถเดินทางมาสถานพยาบาลได้ด้วยตนเอง เป็นต้น

การรักษาบาดแผลที่ล่าช้าส่งผลให้ผู้ป่วยอาจต้องเดินทางเข้าพบแพทย์บ่อยครั้งมากขึ้น สาเหตุอาจเกิดจากคุณภาพของการรักษาที่ต่ำกว่ามาตรฐาน ในปัจจุบันการประเมินบาดแผลใช้เทคนิคการประเมินด้วยตัวแพทย์เพื่อระบุและอธิบายรูปทรง พื้นที่ผิว ความลึก ขนาดและลักษณะทางชีววิทยาของเนื้อเยื่อผิวหนังในแต่ละชั้นของบาดแผล จากนั้นจึงเลือกยาและวิธีการในการรักษา ซึ่งเทคนิคการประเมินดังกล่าวยังขาดความแม่นยำและต้องอาศัยความเชี่ยวชาญของแพทย์เพื่อประเมินบาดแผล เมื่อรวมปัจจัยนี้เข้ากับปัจจัยอื่น ๆ ที่มีผลต่อการรักษาทำให้คาดคะเนระยะเวลาการรักษาได้ยากมากขึ้น

เนื่องจากปัญหาของเทคนิคการประเมินบาดแผลที่มีคุณภาพต่ำกว่ามาตรฐาน การสร้างตัวแบบรู้จำชนิดเนื้อเยื่อของบาดแผลที่นำไปสู่ระบบสำหรับประเมินบาดแผลและสามารถใช้ข้อมูลที่ได้รับจากตัวแบบรู้จำเพื่อเทียบเคียงกับคู่มือการรักษาสากล ทำให้สามารถเลือกยาและวิธีการรักษาที่เหมาะสมได้โดยสะดวก งานส่วนนี้จะช่วยให้แพทย์สามารถประเมินบาดแผลได้ดีมากขึ้นและสามารถเลือกยาและวิธีการรักษาได้สอดคล้องกับมาตรฐานสากลมากขึ้นโดยเป็นไปอย่างมีประสิทธิภาพ

1.2 วัตถุประสงค์ของงานวิจัย

ในปัจจุบันมีตัวแบบรู้จำเชิงลึก (Deep Learning model) ที่รู้จำชนิดเนื้อเยื่อบาดแผลจากภาพมากมายและหลายงานมีปัญหาเกี่ยวกับภาพที่มีขนาดไม่เท่ากัน ซึ่งการแก้ปัญหามีอยู่หลายวิธีแต่สองวิธีที่เป็นที่นิยมคือการปรับขนาดของภาพให้มีขนาดเท่ากันและการแบ่งภาพออกเป็นภาพย่อยเพื่อทำนายแต่ละพื้นที่ย่อย แต่ยังไม่มิตัวแบบใดที่มีความแม่นยำเพียงพอให้นำมาประยุกต์ใช้งานจริงกับการรักษาบาดแผล ผู้วิจัยคิดหาวิธีเพิ่มความแม่นยำของตัวแบบรู้จำเชิงลึกที่ใช้วิธีการแบ่งภาพออกเป็นภาพย่อยโดยมุ่งเน้นไปที่พื้นที่ที่ท้าทาย [2] จึงเป็นสาเหตุให้ผู้วิจัยนำวิธีการดังกล่าวมาประยุกต์ใช้เพื่อสร้างตัวแบบรู้จำเชิงลึกที่สามารถเพิ่มประสิทธิภาพในการรักษาบาดแผลเรื้อรัง

1.3 สมมติฐานของงานวิจัย

เราสามารถเพิ่มความแม่นยำของตัวแบบรู้จำเชิงลึกได้โดยเพิ่มตัวอย่างในบริเวณที่ตัวแบบทำนายได้ไม่ดี กล่าวคือการฝึกสอนตัวแบบด้วยตัวอย่างที่ท้าทายให้มากขึ้นจะสามารถเพิ่มความแม่นยำของตัวแบบได้

1.4 ขอบเขตของการวิจัย

- รูปภาพที่ใช้ในงานวิจัยนี้ทั้งหมดเป็นภาพบาดแผลเรื้อรังจาก 2 ฐานข้อมูล ดังนี้
 - Medetec Medical image database [1]
 - โรงพยาบาลรามาริบัติ
- ตัวแบบรู้จำในงานวิจัยนี้ใช้แยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลเรื้อรัง โดยแบ่งออกเป็น 4 ชนิด ดังนี้
 - พื้นหลัง (Background)
 - เนื้อเยื่อเนื้อแดง (Granulation)
 - เนื้อเยื่อหนอง (Slough)
 - เนื้อเยื่อเนื้อตาย (Necrosis)

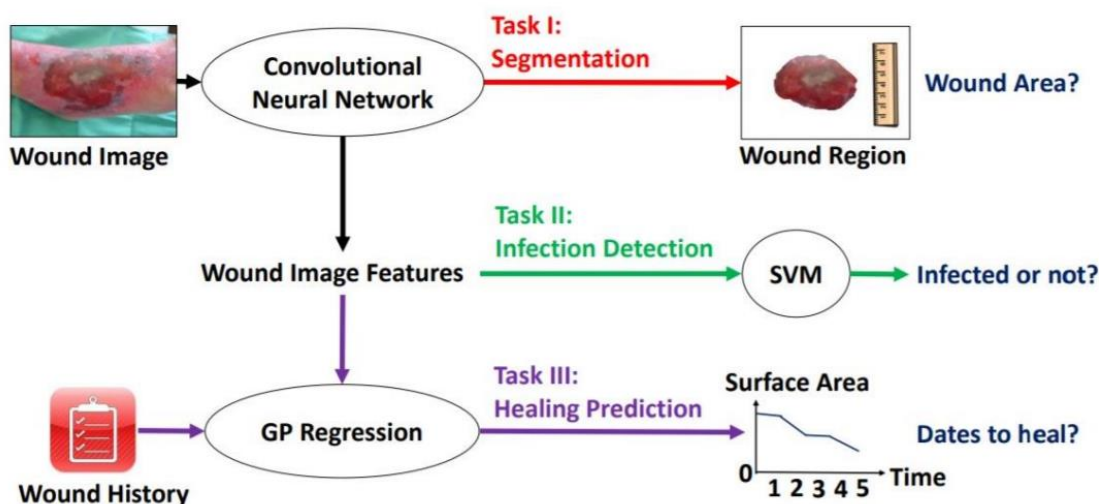
1.5 ประโยชน์ที่คาดว่าจะได้รับ

สามารถแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลเรื้อรังจากภาพบาดแผลเรื้อรังได้และนำไปสู่การคำนวณขนาดพื้นที่แต่ละพื้นที่

บทที่ 2 งานวิจัยที่เกี่ยวข้อง


2.1 A Unified Framework for Automatic Wound Segmentation and Analysis with Deep Convolutional Neural Networks [3]

Changhan et al. นำเสนอระบบอัตโนมัติเพื่อแยกพื้นที่และวิเคราะห์สภาพบาดแผลจากภาพด้วยการสร้างตัวแบบรู้จำเชิงลึก โดยแบ่งงานออกเป็น 3 ส่วนคือส่วนแยกพื้นที่บาดแผลและวัดขนาดพื้นที่ ส่วนตรวจหาการติดเชื้อและส่วนทำนายจำนวนวันที่ต้องใช้ในการรักษาในอจาาคต ซึ่งภาพรวมของระบบถูกแสดงไว้ที่



ภาพที่ 5 ภาพรวมของระบบอัตโนมัติเพื่อวิเคราะห์สภาพบาดแผล (ภาพจาก [3])

2.1.1 การแยกพื้นที่บาดแผลและวัดขนาดพื้นที่ (Wound Segmentation and Surface Area Estimation)



ภาพที่ 6 สถาปัตยกรรมของโครงข่ายประสาทเทียม (Convolutional encoder-decoder network) (ภาพจาก [3])

วิธีการที่เลือกใช้เพื่อแยกพื้นที่บาดแผลคือการสร้างตัวแบบรู้จำเชิงลึกโดยสถาปัตยกรรมถูกแสดงไว้ในภาพที่ 6 ซึ่งเป็นสถาปัตยกรรมที่ประกอบไปด้วยชั้นการเข้ารหัส 5 ชั้น ชั้นการถอดรหัส 4 ชั้นและชั้นสร้างแผนที่ความน่าจะเป็น 1 ชั้น ชั้นการเข้ารหัสแต่ละชั้นเป็น convolutional layer โดยมี activation function คือ Rectified Linear Unit (ReLU) [4] ต่อด้วย spatial pooling layer และ normalizing layer ชั้นการถอดรหัสแต่ละชั้นประกอบไปด้วย upsampling operations [5] โดยมี activation function คือ ReLU และชั้นการสร้างแผนที่ความน่าจะเป็นคือ softmax layer ในการทำนายแต่ละพิกเซลใช้ค่า threshold คือ 0.5 การวัดขนาดพื้นที่ใช้ Hough Transform [6] เพื่อหาอัตราส่วนการแปลงและคำนวณขนาดพื้นที่จากจำนวนพิกเซลที่ถูกจำแนกว่าเป็นบาดแผลทั้งหมดหารด้วยอัตราส่วนการแปลงยกกำลังสอง หน่วยในการประเมินของงานในส่วนนี้คือความถูกต้องของการทำนายแต่ละพิกเซล (Pixel Accuracy) และ Intersection over Union (IoU) ซึ่ง IoU เป็นหน่วยที่ใช้วัดความคล้ายคลึงกันของพื้นที่ที่เครื่องทำนายกับพื้นที่ผลเฉลย

ตารางที่ 1 ผลลัพธ์ของวิธีการ SVM [7] และ Convolutional Network (ConvNet)

	Pixel Accuracy	Mean IoU
SVM (RGB)	77.6%	26.4%
ConvNet	95.0%	47.3%

2.1.2 การตรวจหาการติดเชื้อ (Wound Infection Detection)

ในงานส่วนนี้เป็นการทำนายการติดเชื้อจากภาพบาดแผล วิธีการที่ใช้คือ SVM [7] และโมเดลสีที่เลือกใช้คือ RGB เช่นเดียวกับกับส่วนการแยกพื้นที่บาดแผลและวัดขนาดพื้นที่

ตารางที่ 2 ผลลัพธ์ของการตรวจหาการติดเชื้อ

	p	Accuracy	Recall	Precision	F1-score	AUC
Random guessing	10%	86.9%	10%	3.83%	0.055	50%
	50%	50%	50%	3.83%	0.071	
	100%	3.83%	100%	3.83%	0.074	
Linear SVM		95.3%	23.1%	33.3%	0.273	76.3%
Kernel SVM		95.6%	30.8%	40.0%	0.348	84.7%

2.1.3 การทำนายจำนวนวันที่ต้องใช้ในการรักษาในอนาคต (Healing Progress Prediction)

ข้อมูลที่นำมาใช้ในการทำนายคือชุดข้อมูลของภาพบาดแผล (Wound sequence) โดยภาพในแต่ละชุดจะเป็นภาพที่ได้จากบาดแผลเดียวกันแต่ถูกถ่ายในเวลาที่แตกต่างกัน ข้อมูลแต่ละชุดถูกแบ่งออกเป็น 2 ส่วนคือครึ่งหน้าและครึ่งหลัง ข้อมูลครึ่งหน้าถูกใช้เป็นข้อมูลนำเข้าและข้อมูลครึ่งหลังถูกใช้เป็นผลเฉลยในการสร้างตัวแบบ Gaussian process regression (GPR) ในการประเมินการทำนายจะทำงานกว่าพื้นที่ของบาดแผลจะมีขนาดเป็น 10% 5% และ 0% จากขนาดผลเริ่มต้น โดยใช้หน่วย mean absolute error (MAE_{time}) เป็นหน่วยในการประเมิน


ตารางที่ 3 ผลลัพธ์ของการทำนายจำนวนวันในการรักษาในอนาคต

	MAE_{time} (10%)	MAE_{time} (10%)	MAE_{time} (10%)	Avg. MAE_{area}
Linear	8.84	18.64	3.30	6.06%
Polynomial (3-order)	16.70	5.11	3.81	6.07%
GP	10.07	2.94	2.17	3.95%

2.2 U-net: Convolutional Networks for Biomedical Image Segmentation [8]

Ronneberger et al. นำเสนองานวิจัยที่ชนะการแข่งขัน ISBI cell tracking challenge 2015 ที่ต้องการแยกพื้นที่ของเซลล์เป้าหมายจากภาพถ่ายเซลล์ที่ได้จากกล้องจุลทรรศน์โดยพื้นที่ที่ต้องการแยกมี 2 ประเภทคือพื้นที่เซลล์เป้าหมายและพื้นที่หลัง โดยเลือกใช้วิธีการสร้างตัวแบบรู้จำเชิงลึก ซึ่งสถาปัตยกรรมของโครงข่ายประสาทเทียมถูกแสดงไว้ที่ภาพที่ 7 และใช้วิธีการแบ่งภาพออกเป็นภาพย่อยซึ่งแต่ละภาพย่อยมีขนาดเท่ากันและมีการทับซ้อนกัน (Overlapping)

สถาปัตยกรรม U-Net (ภาพที่ 7) ประกอบไปด้วยชั้นการเข้ารหัส 4 ชั้น ชั้นการถอดรหัส 4 ชั้นและชั้นสร้างแผนที่ความน่าจะเป็น ชั้นการเข้ารหัสแต่ละชั้นประกอบไปด้วย convolutional layer โดยมี activation function คือ ReLU ทั้งหมด 2 ชั้นและ max pooling layer 1 ชั้น ชั้นการถอดรหัสแต่ละชั้นประกอบไปด้วย up-scaling layer รวมกับผลลัพธ์จากชั้นการถอดรหัสที่ตรงกันและ convolutional layer ซึ่ง activation function คือ ReLU ทั้งหมด 2 ชั้น ชั้นสร้างแผนที่ความน่าจะเป็นคือ convolutional layer ที่มี activation function คือ softmax ซึ่งการสอดแทรกผลลัพธ์จากชั้นการเข้ารหัสเข้ามาในชั้นการถอดรหัสนั้นทำให้ U-Net มีประสิทธิภาพอย่างมาก



ภาพที่ 7 สถาปัตยกรรมของโครงข่ายประสาทเทียม (ภาพจาก [8])

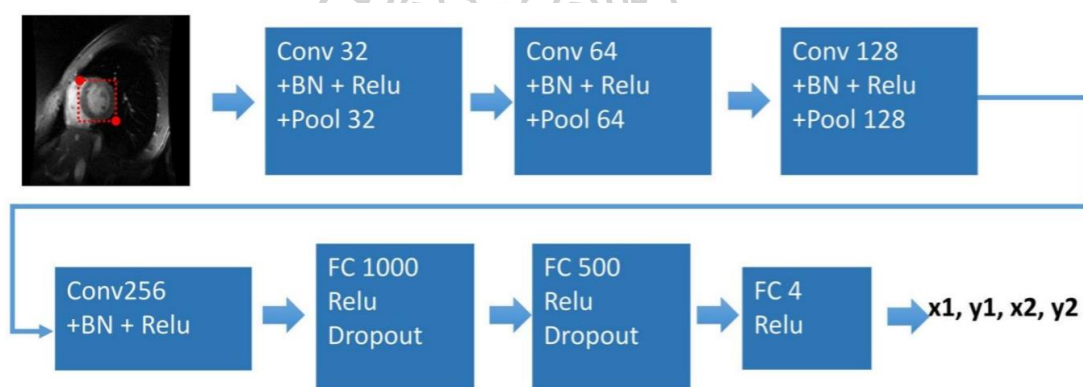
ผลลัพธ์ที่ถูกต้องแสดงไว้ในตารางที่ 1 คือผลลัพธ์ของ U-Net ในการแข่งขัน ISBI cell tracking challenge 2015 ซึ่งมีชุดข้อมูล 2 ชุดคือ PhC-U373 และ DIC-HeLa สังเกตว่า U-Net ให้ผลลัพธ์ที่ดีกว่าผู้แข่งขันอื่นอย่างมาก ซึ่งเป็นเครื่องพิสูจน์ว่า U-Net นั้นมีประสิทธิภาพสูง

ตารางที่ 4 ผลการแข่งขัน ISBI cell tracking challenge 2015


Name	PhC-U373 (IoU)	DIC-HeLa (IoU)
IMCB-SG (2014)	0.2669	0.2935
KTH-SE (2014)	0.7953	0.4607
HOUS-US (2014)	0.5323	-
Second-best 2015	0.83	0.46
U-Net (2015)	0.9203	0.7756

2.3 Deep convolutional neural networks for automatic segmentation of left ventricle cavity from cardiac magnetic resonance images [9]

Xulei Yang et al. นำเสนองานวิจัยที่มีจุดประสงค์เพื่อแยกพื้นที่ของ left ventricle cavity (LV cavity) จากภาพ cardiac magnetic resonance (CMR) ในฐานข้อมูลจาก York University และ MICCAI 2009 LV Challenge โดยวิธีการสร้างตัวแบบรู้จำเชิงลึก 2 ตัวแบบ ตัวแบบแรกคือตัวแบบรู้จำเพื่อหาตำแหน่งของ LV cavity ซึ่งเป็น Regression Model (ภาพที่ 8) โดยรับข้อมูลเข้าเป็นภาพ CMR และให้ผลลัพธ์เป็นตำแหน่ง $x1, y1, x2, y2$ ตัวแบบที่สองเป็นตัวแบบที่ใช้สถาปัตยกรรม U-Net (ภาพที่ 7) เพื่อแยกพื้นที่ของ LV cavity โดยใช้ตัวแบบแรกเป็นตัวภาพออกมา โดยเรียกขั้นตอนนี้ว่า Localization จากนั้นให้ตัวแบบที่สองเพื่อแยกพื้นที่ โดยภาพรวมของระบบถูกแสดงไว้ในภาพที่ 9



ภาพที่ 8 สถาปัตยกรรมของ Regression Model (ภาพจาก [9])



ภาพที่ 9 ภาพรวมของระบบการแยกพื้นที่ LV cavity (ภาพจาก [9])

งานวิจัยนี้ใช้ Dice loss function ซึ่งดัดแปลงมาจากหน่วยในการวัดความคล้ายคลึงกันของพื้นที่ซึ่งคล้ายกับ IoU ที่มีชื่อว่า Dice Metric (DM) โดยคำนวณจากสมการต่อไปนี้

$$\text{loss}(A, G) = 1 - \text{DM}(A, G) = 1 - \frac{2(A \cap G)}{A + G}$$

โดย A แทนเซตของพิกเซลในพื้นที่ที่เครื่องทำนายว่าเป็นวัตถุเป้าหมาย
 G แทนเซตของพิกเซลในพื้นที่ผลเฉลย

งานวิจัยนี้แบ่งการทดลองออกเป็น 4 การทดลองโดยแต่ละการทดลองจะมีความแตกต่างกันเล็กน้อยดังนี้

ตารางที่ 5 ความแตกต่างของการทดลอง

Name	Loss function	Localization
U-Net	Binary	-
U-Net-D	Dice	-
U-Net-L	Binary	Yes
U-Net-DL	Dice	Yes

ตารางที่ 6 ผลลัพธ์การเปรียบเทียบการทดลองในหน่วย IoU(DM)


ID	U-Net	U-Net-D	U-Net-L	U-Net-DL
Subject #01	0.83(0.90)	0.86(0.91)	0.85(0.91)	0.87(0.92)
Subject #08	0.73(0.80)	0.74(0.81)	0.74(0.81)	0.77(0.84)
Subject #10	0.79(0.87)	0.83(0.90)	0.82(0.89)	0.82(0.88)
Subject #11	0.72(0.79)	0.78(0.84)	0.91(0.95)	0.90(0.94)
Subject #12	0.84(0.91)	0.84(0.91)	0.87(0.92)	0.88(0.93)
Subject #28	0.89(0.94)	0.89(0.94)	0.90(0.95)	0.90(0.95)
Summary				
Mean±Stdev	0.80±0.07 (0.87±0.06)	0.82±0.05 (0.89±0.05)	0.85±0.06 (0.91±0.05)	0.86±0.05 (0.91±0.04)

ผลลัพธ์ของการทดลองถูกแสดงไว้ในตารางที่ 6 และเห็นได้ชัดว่า U-Net-D และ U-Net-L นั้นมีประสิทธิภาพใกล้เคียงกัน U-Net มีประสิทธิภาพต่ำที่สุดและ U-Net-DL มีประสิทธิภาพสูงที่สุด ดังนั้นงานวิจัยนี้จึงเลือก U-Net-DL ไปแข่งขันใน MICCAI 2009 LV Challenge ซึ่งผลลัพธ์การแข่งขันถูกแสดงไว้ในตารางที่ 7

ตารางที่ 7 ผลลัพธ์การแข่งขัน MICCAI 2009 LV Challenge

	Run time per frame, s	DM (mean±std)	APD (mean±std), mm	Good contours, %
U-Net-DL	0.08	0.93±0.03	1.46±0.23	100
P.V. Tran 2016	0.06	0.92±0.03	1.73±0.35	99.2±2.2
Yang et al.	0.20	0.88±0.03	2.41±0.38	93.1±6.3
Avendi et al.	-	0.94±0.02	1.81±0.44	-
Hu et al. 2014	10.96	0.89±0.04	2.30±0.36	92.7±6.9
Queiros et al.	0.06-0.09	0.90±0.05	1.76±0.45	92.7±9.5
Ngo et al.	-	0.90±0.03	2.08±0.40	97.9±6.2
Hu et al. 2013	8.92	0.89±0.03	2.24±0.40	91.1±9.4
Constantinides et al. 2012	-	0.86±0.05	2.44±0.56	80±16
Uzunbas et al. 2012	2.25	0.82±0.06	2.98±0.88	-
Liu et al. 2012	-	0.88±0.03	2.36±0.39	91.2±8.50
Huang et al. 2011	-	0.89±0.04	2.16±0.46	79.2±19.0

2.4 Deep Residual Learning for Image Recognition [10]



ภาพที่ 10 Residual learning: a building block (ภาพจาก [10])

Kaiming He et al. นำเสนองานวิจัยเพื่อเพิ่มความแม่นยำของตัวแบบรู้จำเชิงลึกโดยใช้ผลลัพธ์ของชั้นก่อนหน้าสอดแทรกเข้าไป (shortcut) ตัวอย่างของการสอดแทรกถูกแสดงไว้ในภาพที่ 10 งานวิจัยนี้เปรียบเทียบผลลัพธ์ของสถาปัตยกรรม Plain Network (ภาพกลางในภาพที่ 11) และสถาปัตยกรรม Residual Network (ภาพขวาในภาพที่ 11) ซึ่งพัฒนามาจาก Plain Network โดยการเพิ่มการสอดแทรกเข้าไป

วิธีการในการสอดแทรกเป็นไปดังภาพที่ 10 โดยมีงานวิจัยนี้นิยมวิธีการสอดแทรกสองแบบคือแบบ building block และแบบ linear projection ซึ่งคำนวณจากสมการดังต่อไปนี้

Building block:

$$y = F(x, \{W_i\}) + x$$

Linear projection:


$$y = F(x, \{W_i\}) + W_S x$$

โดย F แทนฟังก์ชันการฝึกสอนของ Residual mapping

W_i แทนค่าน้ำหนักในชั้นที่ i

W_S แทน *projection matrix* ของค่าน้ำหนักชั้นที่ i

x แทนผลลัพธ์จากชั้นก่อนหน้า




ภาพที่ 11 สถาปัตยกรรม VGG-19 (ภาพซ้าย), Plain Network (ภาพกลาง) และ Residual Network (ภาพขวา) (ภาพจาก [10])

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10 ⁹	3.6×10 ⁹	3.8×10 ⁹	7.6×10 ⁹	11.3×10 ⁹

ภาพที่ 12 สถาปัตยกรรมต่าง ๆ ในงานชิ้นนี้ โดย shortcut อยู่ที่เครื่องหมายวงปิด (ภาพจาก [10])

2.4.1 ImageNet Classification

ในส่วนนี้ใช้ Plain Network (Plain) 2 ตัวแบบคือแบบ 18 layers และแบบ 34 layers (ภาพที่ 12) และ Residual Network (ResNet) 2 ตัวแบบคือแบบ residual 18 layers และแบบ residual 34 layers (ภาพที่ 12) ซึ่งดัดแปลงมาจาก Plain Network ก่อนหน้า



ภาพที่ 13 กราฟแสดงผลการฝึกสอนโดยเส้นบางได้จากข้อมูลฝึกสอน (training set) และเส้นหนาได้จากข้อมูลตรวจสอบ (validation set)

ตารางที่ 8 ผลลัพธ์ Top-1 error (% , 10-crop testing) จากชุดข้อมูลตรวจสอบ (ImageNet validation set)

	Plain	ResNet
18 layers	27.94	27.88
34 layers	28.54	25.03

ผลลัพธ์ของการทดลองที่แสดงไว้ในภาพที่ 13 และตารางที่ 8 จะเห็นว่ามีความสำคัญ 3 สิ่งคือ

1. ค่า validation error ของ Plain และ ResNet นั้นสวนทางกันกล่าวคือ plain-18 มีค่า validation error น้อยกว่า plain-34 แต่ ResNet-18 มีค่า validation error มากกว่า ResNet-34 ถึง 2.8%
2. ค่า validation error ของ ResNet-34 มีค่าน้อยกว่า plain-34 ถึง 3.5% กล่าวคือเราสามารถเพิ่มความแม่นยำได้สำเร็จ
3. ค่า validation error ของ ResNet-18 และ plain-18 มีค่าใกล้เคียงกันแต่การฝึกสอน ResNet-18 สามารถเข้าสู่จุดที่ดีที่สุดได้ค่อนข้างเร็วกว่า plain-18 กล่าวคือในกรณีที่ ResNet ไม่สามารถเพิ่มความแม่นยำได้แต่ยังสามารถทำให้การฝึกสอนตัวแบบเข้าสู่จุดที่ดีที่สุดได้เร็วขึ้น

ตารางที่ 9 ผลลัพธ์ Error rates (% , 10-crop testing) ทดสอบกับชุดข้อมูลตรวจสอบ (ImageNet validation set)

model	top-1 err.	top-5 err.
VGG-16	28.07	9.33
GoogLeNet	-	9.15
PReLU-Net	24.27	7.38
plain-34	28.54	10.02
ResNet-34 A	25.03	7.76
ResNet-34 B	24.52	7.46
ResNet-34 C	24.19	7.40
ResNet-50	22.85	6.71
ResNet-101	21.75	6.05
ResNet-152	21.43	5.71

งานวิจัยนี้เปรียบเทียบสถาปัตยกรรม ResNet ที่มีความแตกต่างกันเล็กน้อยทั้งหมด 3 แบบ โดยมีความแตกต่างดังต่อไปนี้

- (A) ใช้ zero-padding shortcut เพื่อขยายมิติและแต่ละ shortcut ไม่มีพารามิเตอร์
- (B) ใช้ projection shortcut เพื่อขยายมิติและแต่ละ shortcut มีเอกลักษณ์ของตัวเอง
- (C) ทุก shortcut เป็น projection shortcut

ผลลัพธ์ในตารางที่ 9 แสดงผลลัพธ์การเปรียบเทียบระหว่าง plain-34, ResNet-34 A, ResNet-34 B และ ResNet-34 C ซึ่ง ResNet ให้ผลลัพธ์ที่ดีกว่า plain และยังเห็นว่า ResNet-34 B ดีกว่า ResNet-34 A เล็กน้อย ตัวแบบ ResNet-34 C ดีกว่า ResNet-34 B เล็กน้อย ผู้วิจัยของงานวิจัยนี้คิดว่าความแตกต่างระหว่างสถาปัตยกรรม ResNet แบบ A, B และ C เกิดจากพารามิเตอร์จำนวนมากและไม่เห็นผลอย่างชัดเจน ดังนั้นงานวิจัยนี้จึงไม่เลือกใช้สถาปัตยกรรมแบบ C เนื่องจากต้องการลดปริมาณของหน่วยความจำ (memory) และเวลาในการฝึกสอน งานวิจัยนี้เลือกใช้สถาปัตยกรรมแบบ B ในการทดลองที่เหลือทั้งหมด

ตารางที่ 10 ผลลัพธ์ Error rates (%) ของ single model ทดสอบกับชุดข้อมูลตรวจสอบ (ImageNet validation set)

method	top-1 err.	top-5 err.
VGG (ILSVRC' 14)	-	8.43
GoogLeNet (ILSVRC' 14)	-	7.89
VGG (v5)	24.4	7.1
PReLU-Net	21.59	5.71
BN-inception	21.99	5.81
ResNet-34 B	21.84	5.71
ResNet-34 C	21.53	5.60
ResNet-50	20.74	5.25
ResNet-101	19.87	4.60
ResNet-152	19.38	4.49

ตารางที่ 11 ผลลัพธ์ Error rates (%) ทดสอบกับชุดข้อมูลทดสอบ (ImageNet testing set)

method	top-5 err. (test)
VGG (ILSVRC' 14)	7.32
GoogLeNet (ILSVRC' 14)	6.66
VGG (v5)	6.8
PReLU-Net	4.94
BN-inception	4.82
ResNet (ILSVRC' 15)	3.57

ผลลัพธ์ในตารางที่ 10 เป็นการเปรียบเทียบสถาปัตยกรรม ResNet กับวิธีการในปัจจุบัน จะเห็นว่า ResNet-34 ให้ผลลัพธ์ที่ใกล้เคียงกับวิธีการที่มีมาก่อนหน้าและ ResNet-152 ให้ผลลัพธ์ที่ดีกว่า ResNet-34 อย่างมาก ผลลัพธ์ของ ResNet-152 ที่แสดงไว้ในตารางที่ 11 โดดเด่นมากและสามารถชนะการแข่งขัน ILSVRC' 2015 ได้สำเร็จ

2.4.2 CIFAR-10 and Analysis

ผลลัพธ์ในตารางที่ 12 แสดงให้เห็นว่าสถาปัตยกรรม ResNet ให้ผลลัพธ์ที่ดีกว่า FitNet และ Highway ซึ่งเป็นวิธีการที่ดีที่สุดในตอนนั้น โดยให้ค่า classification error อยู่ที่ 6.43%

ตารางที่ 12 ผลลัพธ์ Classification error ทดสอบกับชุดข้อมูลทดสอบ (CIFAR-10 testing set) โดยทดลองทั้งหมด 5 ครั้งและแสดงผลในรูปแบบ best(mean±std)

method			error(%)
Maxout			9.38
NIN (Network In Network)			8.81
DSN (Deeply-Supervised Nets)			8.22
	#layers	#params	
FitNet	19	2.5M	8.39
Highway	19	2.3M	7.54(7.72±0.16)
Highway	32	1.25M	8.80
ResNet	20	0.27M	8.75
ResNet	32	0.46M	7.51
ResNet	44	0.66M	7.17
ResNet	56	0.85M	6.97
ResNet	110	1.7M	6.43(6.61±0.16)
ResNet	1202	19.4M	7.93

2.4.3 Object Detection on PASCAL and MS COCO

ผลลัพธ์ที่แสดงไว้ในตารางที่ 13 คือผลลัพธ์การทดสอบกับ PASCAL VOC 2007 และ 2012 โดยฝึกสอนด้วยชุดข้อมูล "07+12" ซึ่งประกอบไปด้วย VOC 2007 5k train-val + VOC 2012 16k train-val และชุดข้อมูล "07++12" ซึ่งประกอบไปด้วย VOC 2007 10k train-val-test + VOC 2012 16k train-val

ตารางที่ 14 คือผลลัพธ์ที่ทดสอบกับชุดข้อมูลตรวจสอบ (Validation set) ของ MS COCO ซึ่งถูกแสดงไว้ในหน่วยเดียวกับ PASCAL VOC นั่นคือหน่วย $mAP@IoU=0.5$ ($mAP@.5$) และหน่วย $mAP@IoU=0.5:0.05:0.95$ ($mAP@[.5, .95]$) ซึ่งเป็นหน่วยมาตรฐานของ MS COCO

ผลลัพธ์ที่แสดงไว้ในตารางที่ 13 และตารางที่ 14 เห็นได้ว่าผลลัพธ์ของ ResNet-101 ดีกว่า VGG-16 อย่างมากในงานตรวจจับวัตถุ (Object Detection) ซึ่งมากกว่าถึง 6% ใน MS COCO ($mAP@[.5, .95]$)

ตารางที่ 13 ผลลัพธ์ของงาน Object Detection ในหน่วย $mAP(\%)$ ทดสอบกับชุดข้อมูลทดสอบ (PASCAL VOC 2007/2012 testing set)

Training data	07+12	07++12
Testing data	VOC 07 test	VOC 12 test
VGG-16	73.2	70.4
ResNet-101	76.4	73.8

ตารางที่ 14 ผลลัพธ์ของงาน Object Detection ในหน่วย $mAP(\%)$ ทดสอบกับชุดข้อมูลตรวจสอบ (MS COCO validation set)

model \ metric	$mAP@.5$	$mAP@[.5, .95]$
VGG-16	41.5	21.2
ResNet-101	48.4	27.2

บทที่ 3

ทฤษฎีที่เกี่ยวข้อง

3.1 การให้ความหมายแต่ละพิกเซล (Semantic Segmentation)

การให้ความหมายแต่ละพิกเซลหรือ Semantic Segmentation คือการแยกพื้นที่ภาพในระดับพิกเซล โดยเทคนิคที่นิยมใช้ในปัจจุบันคือ Fully Convolutional Neural Network ซึ่งเป็นเทคนิคการเรียนรู้เชิงลึกแบบหนึ่ง เทคนิคนี้ประสบความสำเร็จอย่างมากในงานแยกพื้นที่ภาพ ทางผู้วิจัยจึงเลือกใช้เทคนิคนี้มาประยุกต์เพื่อแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลเรื้อรังในภาพบาดแผลเรื้อรัง

3.2 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึกหรือ Deep Learning เป็นสาขาหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเป็นการสร้างสถาปัตยกรรมโครงข่ายประสาทเทียม เพื่อเรียนรู้และจดจำความหมายของข้อมูล โดยสถาปัตยกรรมประกอบไปด้วยชั้นของประสาทเทียมหลายชั้นและแต่ละชั้นมักมีการเปลี่ยนแปลงไม่เชิงเส้นผ่าน activation function ตัวอย่างการประยุกต์ใช้ เช่น การสร้างตัวแบบรู้จำใบหน้าบุคคลหรือรู้จำรูปร่างของสัตว์ เป็นต้น การเรียนรู้เชิงลึกมีประสิทธิภาพสูงในการจัดการกับฟีเจอร์สำหรับการเรียนรู้แบบไม่มีผู้สอน (unsupervised learning) หรือการเรียนรู้แบบกึ่งมีผู้สอน (semi supervised learning) ซึ่งในงานชิ้นนี้เลือกใช้สถาปัตยกรรม U-Net [8] โดยประยุกต์ใช้กับ ResNet [10]

3.3 การสร้างภาพผลเฉลย

ผู้วิจัยใช้โปรแกรม MultiMarker v1.1 ในการสร้างภาพผลเฉลยให้กับภาพบาดแผลเรื้อรัง ซึ่งโปรแกรมดังกล่าวถูกพัฒนาโดยห้องแล็บของภาควิชาคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร ซึ่งใช้ Livewire Algorithm [11] เป็นอัลกอริทึมเพื่อช่วยให้สามารถสร้างภาพผลเฉลยได้อย่างสะดวกและรวดเร็ว การใช้งานโปรแกรม MultiMarker v1.1 มีดังนี้

- นำเข้าภาพ (ภาพที่ 14)
- ลากเส้นเพื่อระบุพื้นที่เป้าหมาย (ภาพที่ 15)
- บันทึกภาพผลเฉลย (ภาพที่ 16)



ภาพที่ 14 นำเข้ารูปภาพสู่โปรแกรม MultiMarker v1.1



ภาพที่ 15 ระบุพื้นที่เป้าหมาย (พื้นที่สีเขียว)



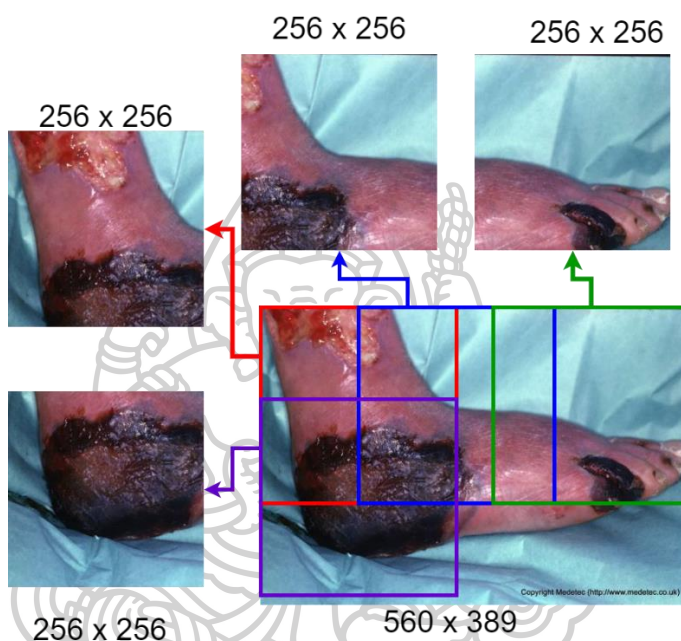
Original

GroundTruth

ภาพที่ 16 ตัวอย่างภาพผลเฉลย (ภาพขาว)

3.4 การสร้างภาพย่อย (Sub-images)

การสร้างภาพย่อยจากภาพต้นฉบับคือการสุ่มเลือกพื้นที่จากภาพต้นฉบับออกมา โดยไม่จำเป็นต้องมีขนาดเท่ากันและภาพย่อยสามารถทับซ้อนกันได้ (overlapping) แต่ต้องมีวิธีการนำภาพย่อยเหล่านั้นมาสร้างภาพที่สอดคล้องกับขนาดภาพต้นฉบับได้เสมอ ซึ่งตัวอย่างของวิธีการดังกล่าวถูกแสดงไว้ในภาพที่ 17 ซึ่งเป็นตัวอย่างที่ใช้ในงานวิจัยนี้



ภาพที่ 17 ตัวอย่างการสร้างภาพย่อย (Sub-images) ในที่นี้เลือกภาพย่อยขนาด 256x256 โดยมีการทับซ้อนกันของภาพย่อย (overlapping)

3.5 การประเมินผล (Evaluation)

งานวิจัยนี้ใช้หน่วยในการประเมินการแยกพื้นที่ที่นิยมใช้ทั่วไปเพื่อประเมินงานแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลจากภาพบาดแผลเรื้อรัง งานวิจัยนี้เลือกใช้หน่วยการประเมินทั้งหมด 4 หน่วย ได้แก่ Confusion matrix, Intersection over Union (IoU), Dice Similarity Index และ Region-size error (RSE)

3.5.1 Confusion Matrix

Confusion Matrix คือการแสดงผลการทำนายของเครื่องเทียบกับผลเฉลยที่ได้จากมนุษย์ โดยตัวอย่างการแสดงผลถูกแสดงอยู่ในตารางที่ 15 ซึ่งแสดงค่า 4 ค่าดังต่อไปนี้

- True Positive (TP) แทนสิ่งที่ทำนายว่าเป็นจริงและผลเฉลยเป็นจริง
- True Negative (TN) แทนสิ่งที่ทำนายว่าเป็นเท็จและผลเฉลยเป็นเท็จ
- False Positive (FP) แทนสิ่งที่ทำนายว่าเป็นจริงแต่ผลเฉลยเป็นเท็จ
- False Negative (FN) แทนสิ่งที่ทำนายว่าเป็นเท็จแต่ผลเฉลยเป็นจริง

ตารางที่ 15 การแสดงผลของ Confusion Matrix

		ทำนาย	
		จริง	เท็จ
ผลเฉลย	จริง	TP	FN
	เท็จ	FP	TN

สามารถนำค่าจากแสดงผลในตารางที่ 15 มาคำนวณค่า Precision ซึ่งเป็นค่าที่บอกว่าทำนายว่าจริงถูกต้องเท่าไรและค่า Recall ซึ่งเป็นค่าที่บอกว่าทำนายว่าจริงเป็นอัตราส่วนเท่าไรของจริงทั้งหมด ค่า Precision และ Recall ใช้คำนวณค่า F1-score ซึ่งเป็นค่าที่ใช้ประเมินประสิทธิภาพของการทำนาย โดยคำนวณได้จากสมการต่อไปนี้

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

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

$$F1(Precision, Recall) = 2 * \frac{Precision * Recall}{Precision + Recall}$$

- โดย TP แทนสิ่งที่ทำนายว่าเป็นจริงและผลเฉลยเป็นจริง (True Positive)
 TN แทนสิ่งที่ทำนายว่าเป็นเท็จและผลเฉลยเป็นเท็จ (True Negative)
 FP แทนสิ่งที่ทำนายว่าเป็นจริงแต่ผลเฉลยเป็นเท็จ (False Positive)
 FN แทนสิ่งที่ทำนายว่าเป็นเท็จแต่ผลเฉลยเป็นจริง (False Negative)

3.5.2 Intersection over Union และ Dice Similarity Index

Intersection over Union (IoU) และ Dice Similarity Index (Dice Similarity Coefficient, DSC) [9] เป็นค่าที่ใช้เปรียบเทียบความคล้ายคลึงของพื้นที่ที่เครื่องทำนายว่าเป็นวัตถุเป้าหมายกับพื้นที่ผลเฉลย โดยคำนวณจากสมการต่อไปนี้

$$IoU(CS, GT) = \frac{|CS \cap GT|}{|CS \cup GT|}$$

$$DSC(CS, GT) = \frac{2|CS \cap GT|}{|CS| + |GT|}$$

โดย CS แทนเซตของพิกเซลในพื้นที่ที่เครื่องทำนายว่าเป็นวัตถุเป้าหมาย (Computer Segmented)

GT แทนเซตของพิกเซลในพื้นที่ผลเฉลย (Ground Truth)

3.5.3 Region-size error

Region-size error คือค่าที่ใช้เปรียบเทียบขนาดของพื้นที่ที่เครื่องทำนายว่าเป็นวัตถุเป้าหมายกับพื้นที่ผลเฉลยโดยคำนวณจากสมการต่อไปนี้

$$RSE(CS, GT) = \frac{abs(|GT| - |CS|)}{|GT|}$$

โดย CS แทนเซตของพิกเซลในพื้นที่ที่เครื่องทำนายว่าเป็นวัตถุเป้าหมาย (Computer Segmented)

GT แทนเซตของพิกเซลในพื้นที่ผลเฉลย (Ground Truth)

3.5.4 ค่าสหสัมพันธ์ (Correlation Coefficient)

ค่าสหสัมพันธ์หรือ Correlation Coefficient เป็นค่าที่บอกความสัมพันธ์ของชุดข้อมูลสองชุดว่ามีความสัมพันธ์กันในแบบใดโดยคำนวณได้จากสมการต่อไปนี้

$$r_{xy} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}}$$

โดย r_{xy} แทนค่าสหสัมพันธ์ของชุดข้อมูล x และชุดข้อมูล y
 x แทนชุดข้อมูล (เวกเตอร์ของจำนวนจริง)
 y แทนชุดข้อมูล (เวกเตอร์ของจำนวนจริง)



บทที่ 4

วิธีการดำเนินงานวิจัย

4.1 การจัดเตรียมข้อมูล (Data Preparation)



งานวิจัยนี้แบ่งขั้นตอนในการจัดเตรียมข้อมูลออกเป็น 4 ขั้นตอนดังนี้ 1. การสร้างภาพผลเฉลย 2. การแบ่งชุดข้อมูลภาพต้นฉบับ 3. การสร้างภาพย่อย 4. การแบ่งชุดข้อมูลฝึกสอน โดยจะอธิบายอย่างละเอียดต่อไป

4.1.1 ฐานข้อมูลภาพ Medetec Medical image database [1] และโรงพยาบาลรามาริบัติ

ภาพบาดแผลเรื้อรังจาก Medetec Medical image database [1] และภาพบาดแผลเรื้อรังจากโรงพยาบาลรามาริบัติมีความแตกต่างกันเล็กน้อย โดยภาพบาดแผลจาก Medetec Medical image database [1] แต่ละภาพมีขนาดไม่เท่ากัน ทุกภาพมีเครดิตของฐานข้อมูลอยู่บริเวณมุมภาพ ภาพจากโรงพยาบาลรามาริบัติแต่ละภาพมีขนาดไม่เท่ากันและทุกภาพมีกรอบสีขาวครอบบาดแผล ภาพจากฐานข้อมูล Medetec มีขนาดเล็กกว่าภาพจากโรงพยาบาลรามาริบัติแต่อัตราส่วนของบาดแผลต่อพื้นหลังมีมากกว่า ตัวอย่างของภาพจากฐานข้อมูล Medetec และโรงพยาบาลรามาริบัติ ถูกแสดงไว้ในภาพที่ 18 และภาพที่ 19 ตามลำดับ



ภาพที่ 18 ภาพตัวอย่างจาก Medetec Medical image database [1]



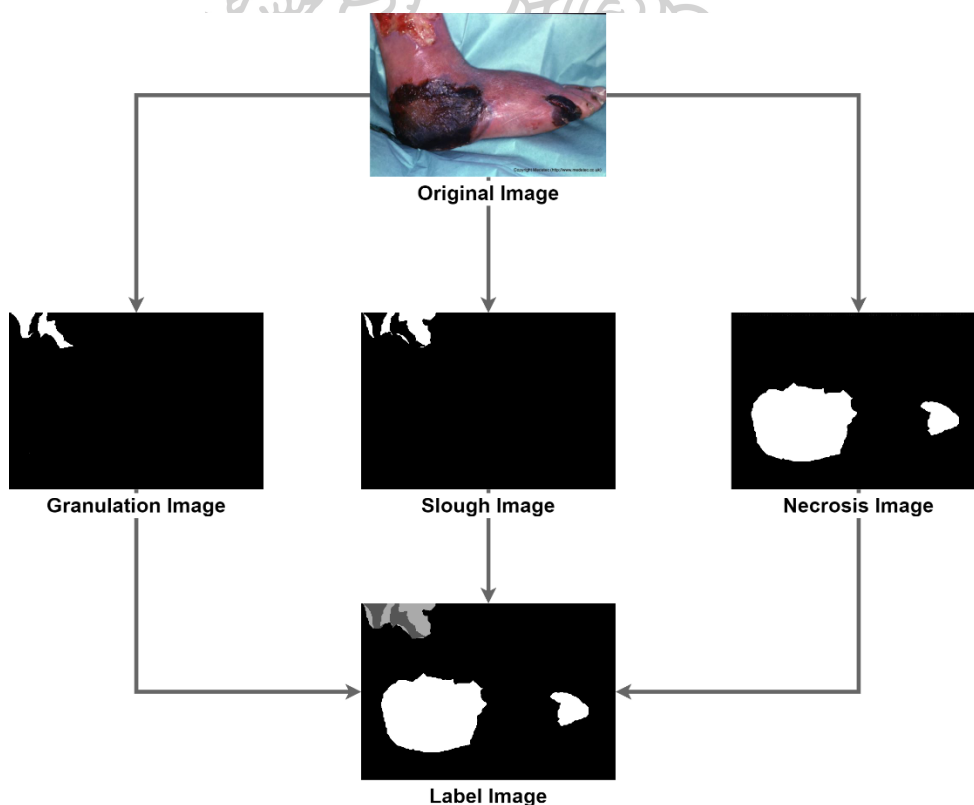
ภาพที่ 19 ภาพตัวอย่างจากโรงพยาบาลรามธิบดี

4.1.2 การสร้างภาพผลเฉลย

จุดประสงค์ของงานวิจัยนี้คือต้องการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลเรื้อรังจากภาพบาดแผลเรื้อรัง โดยแบ่งชนิดเนื้อเยื่อบาดแผลออกเป็น 3 ชนิดคือ เนื้อเยื่อเนื้อแดง (granulation) เนื้อเยื่อหนอง (slough) และเนื้อเยื่อเนือตาย (necrosis) ภาพหนึ่งไม่จำเป็นต้องมีเนื้อเยื่อทุกเนื้อเยื่อ และภาพส่วนใหญ่มีพิกเซลที่ไม่ใช่เนื้อเยื่อบาดแผลเรียกว่าพื้นหลัง (background) กำหนดค่าแทนชนิดเนื้อเยื่อบาดแผลในรูปภาพในภาพผลเฉลยดังนี้

1. ให้ 0 แทนพื้นหลัง (background)
2. ให้ 1 แทนเนื้อเยื่อเนื้อแดง (granulation)
3. ให้ 2 แทนเนื้อเยื่อหนอง (slough)
4. ให้ 3 แทนเนื้อเยื่อเนือตาย (necrosis)

โปรแกรม MultiMarker v1.1 สามารถใช้สร้างภาพผลเฉลยของแต่ละเนื้อเยื่อได้ โดยสร้างภาพผลเฉลยของแต่ละเนื้อเยื่อแยกจากกัน จากนั้นให้นำภาพเนื้อเยื่อแต่ละภาพประกอบกันให้เป็นภาพผลเฉลยของภาพต้นฉบับ ตัวอย่างการสร้างภาพผลเฉลยถูกแสดงไว้ในภาพที่ 20



ภาพที่ 20 ตัวอย่างการสร้างภาพผลเฉลยจากภาพต้นฉบับ (ภาพผลเฉลยประกอบไปด้วยค่า 0, 1, 2 และ 3 ซึ่งแทนชนิดเนื้อเยื่อบาดแผล)

4.1.3 การแบ่งชุดข้อมูลภาพต้นฉบับ

งานวิจัยนี้แบ่งชุดข้อมูลจากภาพบาดแผลจากทั้งสองฐานข้อมูลออกเป็น 3 ชุด โดยแต่ละชุดจะมีจำนวนภาพจากทั้งสองฐานข้อมูลเป็นอัตราส่วนที่ใกล้เคียงกัน โดยทั้งสามชุดข้อมูลคือชุดข้อมูลฝึกสอน (training set) ชุดข้อมูลตรวจสอบ (validation set) และชุดข้อมูลทดสอบ (testing set) โดยแต่ละชุดข้อมูลมีจำนวนภาพดังที่แสดงไว้ในตารางที่ 16

ตารางที่ 16 จำนวนภาพต้นฉบับของแต่ละชุดข้อมูล


ฐานข้อมูล	ทั้งหมด	ฝึกสอน (training set)	ตรวจสอบ (validation set)	ทดสอบ (testing set)
Medetec	148	88	30	30
โรงพยาบาลรามธิบดี	227	152	30	45

4.1.4 การสร้างภาพย่อย (Sub-images)

หลังจากแบ่งภาพต้นฉบับออกเป็น 3 ชุดดังที่แสดงไว้ในส่วนก่อนหน้าแล้วผู้วิจัยสร้างชุดข้อมูลใหม่จากชุดข้อมูลฝึกสอนต้นฉบับโดยใช้วิธีการแบ่งภาพออกเป็นภาพย่อยเพื่อนำภาพย่อยเหล่านี้เป็นข้อมูลฝึกสอนตัวแบบรู้จำเชิงลึกเพื่อแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลแต่ละพื้นที่ย่อย งานวิจัยนี้ออกแบบวิธีการสร้างภาพย่อยอย่างเป็นระบบดังนี้

- ภาพย่อยแต่ละภาพมีขนาด 256x256
- ภาพย่อยแรกเป็นมีจุดมุมซ้ายบนตรงกับตำแหน่ง $(0,0)$ ของภาพต้นฉบับ
- กำหนดค่า stride เป็น $(128, 128)$ กล่าวคือให้เลื่อนตำแหน่งไปทางขวาครั้งละ 128 พิกเซลและเลื่อนไปด้านล่างครั้งละ 128 พิกเซล
- เมื่อเลื่อนตำแหน่งจนไม่สามารถเลื่อนได้อีกและเหลือขอบพื้นที่ ให้คำนวณตำแหน่งที่ทำให้เมื่อวางกรอบขนาด 256x256 แล้วพอดีขอบพอดี

ตัวอย่างการสร้างภาพย่อย (ภาพที่ 21) เป็นการสร้างภาพย่อยจากภาพต้นฉบับขนาด 560x389 โดยในขั้นแรกให้เริ่มที่ตำแหน่ง $(0, 0)$ และให้เลื่อนไปด้วยค่า stride เท่ากับ $(128, 128)$ ทำให้ได้เซตของ x คือ $\{0, 128, 256, 384\}$ และเซตของ y คือ $\{0, 128, 256\}$ แต่ยังมีพื้นที่ที่ยังไม่ถูกเลือกอยู่ทางด้านขวาและด้านล่างของภาพต้นฉบับอยู่ ให้เพิ่มค่า 304 (ได้จาก $560-256$) เข้าไปใน x และเพิ่มค่า 133 (ได้จาก $389-256$) เข้าไปใน y และให้ตำแหน่งของมุมซ้ายบนแต่ละตำแหน่งคือ (x_i, y_i) จากนั้นใช้ตำแหน่งเดียวกันสร้างภาพย่อยจากภาพผลเฉลย



256 x 256

560 x 389

ภาพที่ 21 ตัวอย่างการประยุกต์ใช้วิธีการสร้างภาพย่อย (Sub-images)

4.1.5 การแบ่งชุดข้อมูลฝึกสอน

เนื่องจากงานวิจัยนี้เลือกใช้การฝึกสอนตัวแบบรู้จำเชิงลึกแบบแบ่งภาพออกเป็นภาพย่อย ดังนั้นต้องสร้างชุดข้อมูลฝึกสอนของตัวแบบ (ภาพย่อย) จากชุดข้อมูลฝึกสอน (ภาพต้นฉบับ) และใช้การหมุนและกลับภาพเพื่อขยายชุดข้อมูลทำให้ชุดข้อมูลมีจำนวนตัวอย่าง (ภาพย่อย) มีจำนวนตัวอย่างเพิ่มขึ้น 8 เท่า จำนวนตัวอย่างของชุดข้อมูลแสดงไว้ในตารางที่ 17

ตารางที่ 17 จำนวนตัวอย่างในชุดข้อมูลฝึกสอนและตรวจสอบ

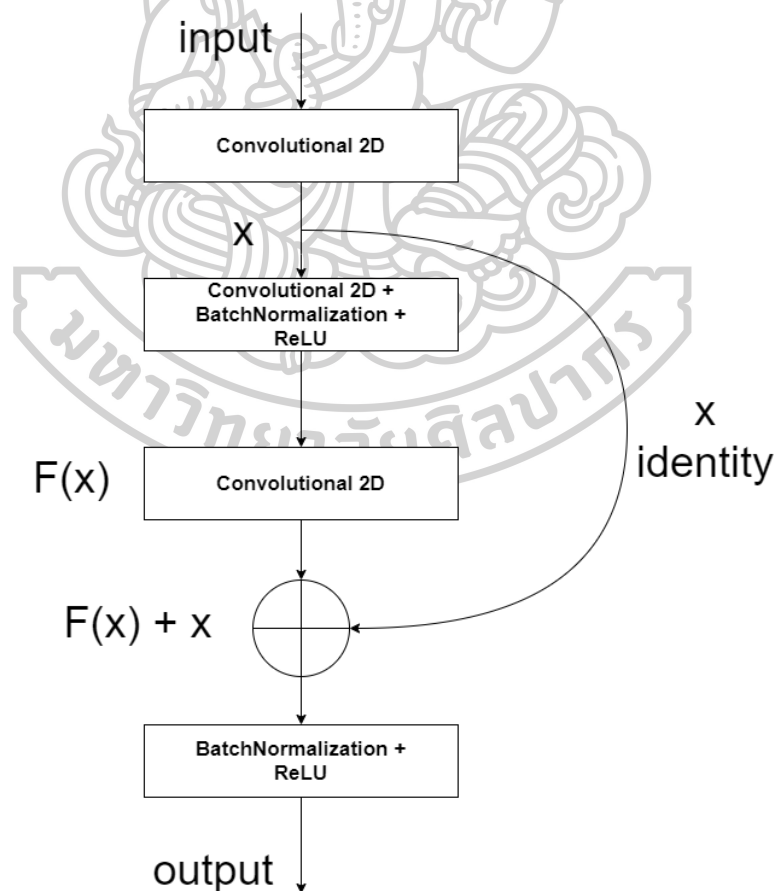
ชุดข้อมูล	ฝึกสอน (training set)	ตรวจสอบ (validation set)
รูปภาพต้นฉบับ	240	60
รูปภาพย่อย	21,160	6,447

4.2 สถาปัตยกรรมของโครงข่ายประสาทเทียม

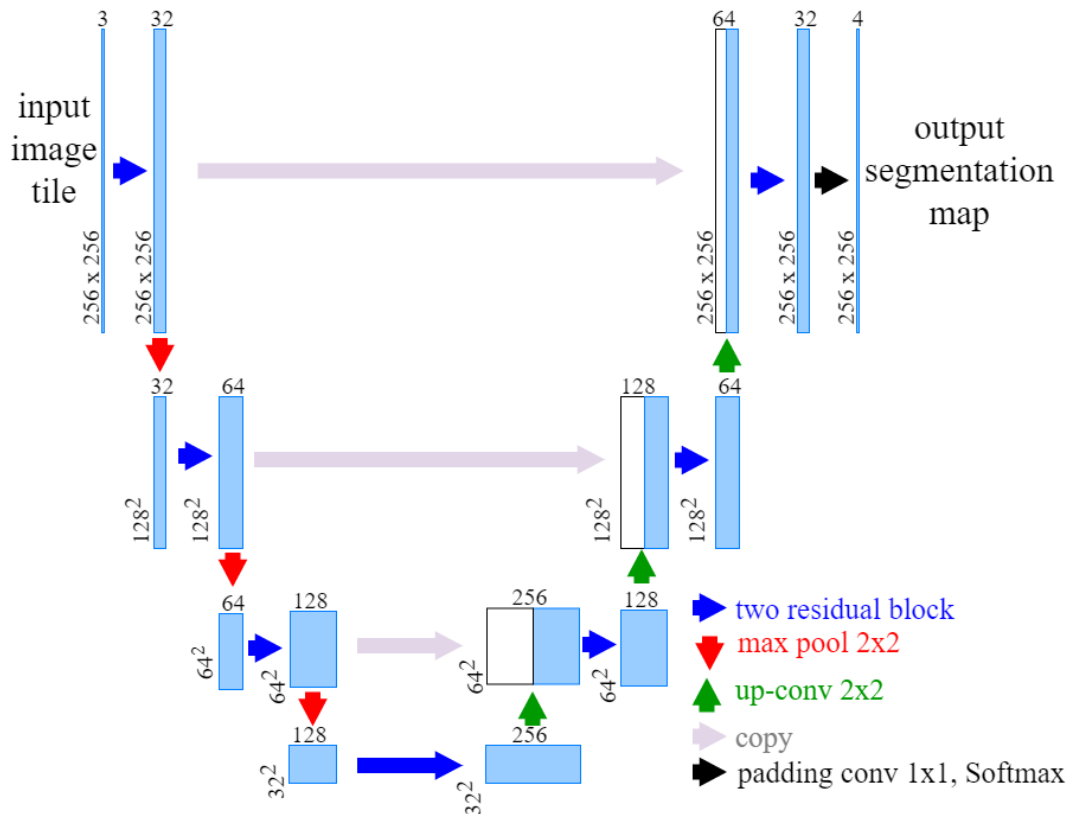
งานวิจัยนี้เลือกใช้สถาปัตยกรรม U-Net [8] ซึ่งเป็นสถาปัตยกรรมที่มีประสิทธิภาพในงานแยกพื้นที่และเป็นสถาปัตยกรรมที่สามารถประยุกต์ใช้งานได้ง่าย งานวิจัยนี้ใช้สถาปัตยกรรม U-Net โดยประยุกต์ใช้กับ ResNet [10] ซึ่งเป็นสถาปัตยกรรมที่สามารถเพิ่มความแม่นยำให้กับตัวแบบรู้จำเชิงลึกได้ โครงสร้างสถาปัตยกรรมโครงข่ายประสาทเทียมถูกแสดงไว้ในภาพที่ 22 และภาพที่ 23 ซึ่งนิยามของการสอดแทรก (shortcut) ที่ใช้ในงานวิจัยนี้เป็นไปดังสมการต่อไปนี้

$$y = F(x, \{W_i\}) + x$$

โดย F แทนฟังก์ชันการฝึกสอนของ Residual mapping
 W_i แทนค่าน้ำหนักในชั้นที่ i
 x แทนผลลัพธ์จากชั้นก่อนหน้า



ภาพที่ 22 Residual learning: shortcut



ภาพที่ 23 สถาปัตยกรรมโครงข่ายประสาทเทียม U-Net ที่ประยุกต์กับ ResNet

สถาปัตยกรรมโครงข่ายของการสอดแทรก (ภาพที่ 22) เป็นสถาปัตยกรรมที่ผู้วิจัยดัดแปลงจาก ResNet ให้มีความซับซ้อนมากขึ้น สถาปัตยกรรมโครงข่าย U-Net (ภาพที่ 23) ดัดแปลงมาจาก U-Net โดยเปลี่ยนชั้น convolutional layers เป็น shortcut (ภาพที่ 22) โดยสถาปัตยกรรมนี้มีจำนวนพารามิเตอร์ทั้งหมด 5,087,332 พารามิเตอร์


4.3 กลไกการฝึกสอนตัวแบบรู้จำเชิงลึก

การฝึกสอนตัวแบบรู้จำเชิงลึกให้มีความแม่นยำจำเป็นต้องทดลองหลายครั้งด้วยค่าพารามิเตอร์หลายค่าและใช้สถาปัตยกรรมที่หลากหลาย ผู้วิจัยทำการทดลองกับสถาปัตยกรรมหลายสถาปัตยกรรม เช่น Convolutional Networks หรือ U-Net แบบดั้งเดิม โดยใช้ค่าพารามิเตอร์มากมาย เพื่อความไม่สับสนในจุดประสงค์ของงานวิจัย ผู้วิจัยจึงเลือกใช้สถาปัตยกรรมและค่าพารามิเตอร์ที่เหมือนกันทั้งหมดในทุกการทดลอง โดยจะเปลี่ยนเพียงชุดข้อมูลฝึกสอนเท่านั้น โดยรายละเอียดการฝึกสอนต่าง ๆ มีดังต่อไปนี้

- ข้อมูลนำเข้าคือเมทริกซ์ขนาด $256 \times 256 \times 3$ ที่ได้จากภาพ RGB ขนาด 256×256
- ผลเฉลยคือเมทริกซ์ขนาด $256 \times 256 \times 4$ ที่ได้จากภาพผลเฉลยที่ถูกแยกออกเป็น 4 มิติตามชนิดเนื้อเยื่อบาดแผล
- Loss function คือ Dice loss function [9]
- Optimizer คือ Adam Optimizer [12]
- จำนวนรอบในการฝึกสอนคือ 300 รอบ
- ค่า Learning rate เริ่มต้นคือ 0.0001 (10^{-4}) และลดลง 10 เท่าทุก ๆ 100 รอบ
- Batch size คือ 16

4.4 การแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผล

งานวิจัยนี้ใช้วิธีการแบ่งภาพออกเป็นภาพย่อย ดังนั้นต้องสามารถนำภาพย่อยมาสร้างภาพที่สอดคล้องและมีขนาดเท่ากับภาพต้นฉบับได้ วิธีการสร้างภาพที่สอดคล้องกับภาพต้นฉบับในงานชิ้นนี้ใช้วิธีการประกอบรูปภาพย่อย (stitch) วิธีการแบ่งภาพออกเป็นภาพย่อยของงานวิจัยนี้มีการทับซ้อนกันของภาพย่อย (overlapping) ทำให้ผู้วิจัยสร้างเวกเตอร์ตัวแทนจากเวกเตอร์ที่เกิดจากการทับซ้อนกันของภาพย่อยในแต่ละพิกเซลและใช้ค่ามากสุดในเวกเตอร์เพื่อระบุชนิดเนื้อเยื่อของพิกเซลนั้น ในกรณีที่พิกเซลไม่มีการทับซ้อนกันของภาพย่อยเวกเตอร์ที่ได้จากตัวแบบรู้จำจะเป็นเวกเตอร์ตัวแทนภาพรวมของระบบการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลเรื้อรังถูกแสดงไว้ในภาพที่ 24



ภาพที่ 24 ภาพรวมของระบบการแยกพื้นที่และจำแนกเนื้อเยื่อบาดแผลเรื้อรัง

4.4.1 การประกอบภาพย่อย (Stitch)

จากการทับซ้อนกันของภาพย่อย (overlapping) ผู้วิจัยเลือกค่าเฉลี่ยแต่ละเนื้อเยื่อของ พิกเซลเป็นตัวแทนผลการทำนายของพิกเซลนั้น ผลลัพธ์ที่ได้จากตัวแบบรู้จำคือแผนที่ความน่าจะเป็น (Output Segmentation Map) ที่มีมิติเป็น $256 \times 256 \times 4$ และเป็นผลลัพธ์จาก softmax layer ทำให้ตัวแทนของแต่ละพิกเซลเป็นเวกเตอร์ขนาด 1×4 จากการทับซ้อนกันของภาพย่อยทำให้บางพิกเซล มีตัวแทนมากกว่าหนึ่งเวกเตอร์ทำให้ผู้วิจัยเลือกค่านวนค่าเฉลี่ยของแต่ละตำแหน่งในเวกเตอร์เพื่อ สร้างเวกเตอร์ตัวแทนของพิกเซลนั้น ๆ ดังตัวอย่างที่แสดงไว้ในตารางที่ 18 ซึ่งแสดงการสร้างตัวแทน ของพิกเซลที่เกิดจากพิกเซล ๆ หนึ่งมีการทับซ้อนกันของภาพย่อย 4 ภาพโดยใช้ค่าเฉลี่ยของแต่ละ เนื้อเยื่อ ในตัวอย่างนี้พิกเซลถูกระบุว่าเป็นเนื้อเยื่อเนื้อตายเพราะว่าค่ามากที่สุดที่ในเวกเตอร์ตัวแทนคือ ค่าของเนื้อเยื่อเนื้อตายกล่าวคือพิกเซลถูกระบุว่าเห็นเนื้อเยื่อเนื้อตายด้วยความมั่นใจ 0.525

ตารางที่ 18 ตัวอย่างการสร้างตัวแทนของพิกเซลได้จากการทับซ้อนกันของภาพย่อย 4 ภาพ

ภาพย่อย	พื้นหลัง	เนื้อเยื่อเนื้อแดง	เนื้อเยื่อหนอง	เนื้อเยื่อเนื้อตาย
1	0.0	0.3	0.2	0.5
2	0.1	0.2	0.3	0.4
3	0.0	0.2	0.2	0.6
4	0.2	0.1	0.1	0.6
ตัวแทน (ค่าเฉลี่ย)	0.075	0.2	0.2	<u>0.525</u>

4.5 Region-Focus Training [2]

Chanok Pathompatai et al. นำเสนองานวิจัยที่สามารถเพิ่มความแม่นยำของตัวแบบรู้จำเชิงลึกในงานแยกพื้นที่ขาดผลโดยใช้วิธีการแบ่งภาพออกเป็นภาพย่อย วิธีการดังกล่าวคือการเพิ่มข้อมูลที่ท้าทายให้เครื่องเรียนรู้มากขึ้นโดยข้อมูลที่ท้าทายคำนวณจากแผนที่ความผิดพลาดที่ได้จากการทำนายของตัวแบบรู้จำที่ฝึกสอนไว้ก่อนแล้ว โดยกำหนดค่า k ซึ่งเป็นค่าที่บอกปริมาณข้อมูลที่ท้าทายที่ต้องการเพิ่มเข้าไปในชุดข้อมูลฝึกสอนโดยทำให้ชุดข้อมูลฝึกสอนใหม่มีปริมาณเป็น $k + 1$ เท่าของปริมาณข้อมูลเดิม ในงานวิจัยนี้ประยุกต์ใช้วิธีการ Region-Focus Training เพื่อเพิ่มตัวอย่างที่มีความท้าทายโดยมีขั้นตอนดังต่อไปนี้

- สร้างแผนที่ความผิดพลาด
- คำนวนค่าความผิดพลาดของแต่ละพื้นที่ย่อย
- คำนวนปริมาณข้อมูลที่ท้าทายที่ต้องการเพิ่มเข้าไปในชุดข้อมูลฝึกสอน

4.5.1 แผนที่ความผิดพลาด (Error Heatmap)


ใช้ตัวแบบรู้จำที่ฝึกสอนมาแล้ว 300 รอบแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลจากชุดข้อมูลฝึกสอน จากตัวอย่างของการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผล (ภาพที่ 25) สามารถสร้างแผนที่ความไม่ถูกต้อง (Wrong Prediction Map) (ภาพซ้ายในภาพที่ 26) และแผนที่ความมั่นใจ (Confidence Map) (ภาพขวาในภาพที่ 26) ได้ จากนั้นใช้แผนที่ดังกล่าวสร้างแผนที่ความผิดพลาด (Error Heatmap) (ภาพที่ 27) ซึ่งมีขั้นตอนดังต่อไปนี้

- สร้างแผนที่ความไม่ถูกต้อง (Wrong Prediction Map) (ภาพซ้ายในภาพที่ 26)
- สร้างแผนที่ความมั่นใจ (Confidence Map) (ภาพขวาในภาพที่ 26)
- สร้างแผนที่ความผิดพลาด (Error Heatmap) (ภาพที่ 27)

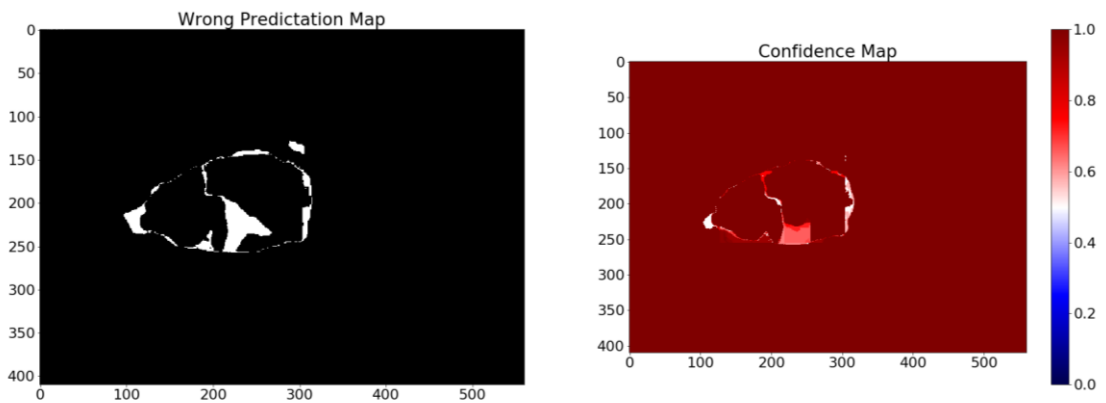
แผนที่ความไม่ถูกต้อง (ภาพซ้ายในภาพที่ 26) คือแผนที่ที่เกิดจากภาพผลเฉลยและภาพที่ได้จากการทำนายของเครื่องโดยค่าในแผนที่ความไม่ถูกต้องเป็น 0 หรือ 1 เท่านั้นโดย 0 หมายความว่าเครื่องทำนาย 픽เซลผิดและ 1 หมายความว่าเครื่องทำนายถูก แผนที่ความมั่นใจ (ภาพขวาในภาพที่ 26) คือแผนที่ที่แสดงความมั่นใจในการทำนายแต่ละ 픽เซลโดยค่าในแต่ละ 픽เซลได้จากค่ามากที่สุด ในเวกเตอร์ตัวแทนของ 픽เซลนั้น ตัวอย่างเช่น 픽เซลหนึ่งในภาพมีเวกเตอร์ตัวแทนคือเวกเตอร์ในตารางที่ 18 ซึ่งเครื่องทำนายว่าเป็นเนื้อตายด้วยค่าความมั่นใจ 0.525 ซึ่งเป็นค่าที่มากที่สุดในเวกเตอร์ตัวแทนนั้น แผนที่ความผิดพลาด (ภาพที่ 27) คือแผนที่ที่แสดงความมั่นใจในการทำนายไม่ถูกต้องในแต่ละ 픽เซลโดยคำนวณจากแผนที่ความไม่ถูกต้องและแผนที่ความมั่นใจ ตัวอย่างเช่น 픽เซลหนึ่งในภาพมีเวกเตอร์ตัวแทนคือเวกเตอร์ในตารางที่ 18 ซึ่งเครื่องทำนายว่าเป็นเนื้อตายด้วยค่าความมั่นใจ 0.525 แต่ผลเฉลยบอกว่า 픽เซลนั้นเป็นเนื้อเยื่อเนื้อแดงทำให้ค่าของ 픽เซลนั้นในแผนที่ความผิดพลาดคือ 0.525 กล่าวคือค่าความมั่นใจใน 픽เซลที่เครื่องทำนายผิดเป็นค่าความผิดพลาดของ 픽เซลนั้นแต่ถ้าเครื่องทำนายถูกค่าของ 픽เซลนั้นจะเป็น 0 ซึ่งแผนที่ความผิดพลาดคำนวณได้จากสมการต่อไปนี้

$$H_e(W, C) = W \odot C$$

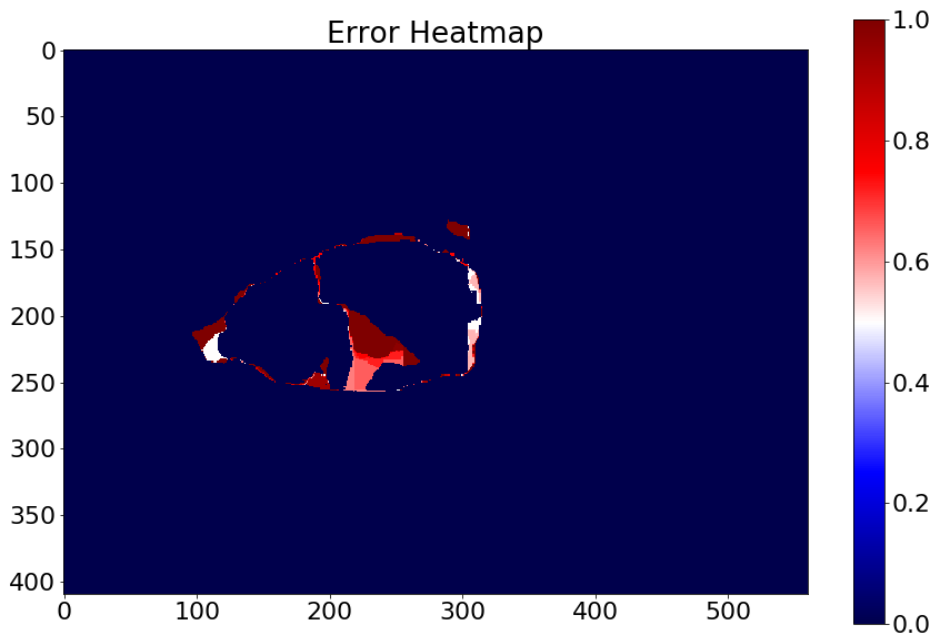
- โดย H_e แทนฟังก์ชันแผนที่ความร้อนแสดงความผิดพลาด
 W แทนแผนที่ความไม่ถูกต้อง (Wrong Prediction Map)
 C แทนแผนที่ความมั่นใจ (Confidence Map)
 \odot แทนการคูณแบบตำแหน่งต่อตำแหน่ง (element-wise multiplication)



ภาพที่ 25 ตัวอย่างการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดเจ็บแผล



ภาพที่ 26 ตัวอย่างแผนที่ความไม่ถูกต้อง (ภาพซ้าย) โดยค่าทั้งหมดเป็น 0 หรือ 1 และตัวอย่างของแผนที่ความมั่นใจ (ภาพขวา) โดยค่าทั้งหมดอยู่ในช่วง $[0, 1]$



ภาพที่ 27 ตัวอย่างแผนที่ความผิดพลาด (Error Heatmap) แสดงความมั่นใจในการทำนายพิกเซลที่ทำนายไม่ถูกต้อง

4.5.2 ค่าความผิดพลาดของพื้นที่ย่อย

เนื่องจากข้อมูลฝึกสอนเกิดจากการแบ่งภาพออกเป็นภาพย่อยขนาด 256×256 ทำให้พื้นที่ที่ทำทนายมีขนาด 256×256 เช่นเดียวกัน ผู้วิจัยใช้วิธีการแบ่งภาพออกเป็นภาพย่อย (Sub-images) โดยใช้ค่า stride เท่ากับ (1, 1) และเรียงลำดับภาพย่อยแต่ละภาพแบบสุ่ม ค่าความผิดพลาดของพื้นที่ย่อยคือผลรวมในภาพย่อยที่ได้จากแผนที่ความผิดพลาด การคำนวณค่าความผิดพลาดให้คำนวณภาพย่อยตามลำดับที่เรียงไว้ก่อนหน้าโดยหลังจากคำนวณภาพย่อยแล้วให้ลดค่าของความผิดพลาดในแผนที่ความผิดพลาดลง 0.5 เท่าและให้เรียงลำดับภาพย่อยตามค่าความผิดพลาด

เหตุผลที่ทำให้ต้องลดค่าความผิดพลาดในแผนที่ความผิดพลาดลงหลังจากคำนวณค่าความผิดพลาดของพื้นที่ย่อยคือบริเวณที่มีค่าความผิดพลาดมากในแผนที่มักเป็นบริเวณที่ใกล้เคียงกันทำให้ภาพย่อยที่ได้จากบริเวณดังกล่าวมีค่าความผิดพลาดมาก เนื่องจากขั้นตอนการแบ่งภาพย่อยงานวิจัยนี้เลือกใช้ค่า stride เท่ากับ (1, 1) ทำให้พื้นที่ย่อยที่ใกล้กันมีลักษณะที่คล้ายกันมากและมีค่าความผิดพลาดที่ใกล้เคียงกันกล่าวคือภาพย่อยที่อยู่ใกล้กันมักมีค่าความผิดพลาดที่ใกล้เคียงกัน งานวิจัยนี้ต้องการเลือกพื้นที่ที่ทำทนายที่มีความแตกต่างกัน ดังนั้นถ้าเราไม่ลดค่าในแผนที่หลังจากที่คำนวณค่าความผิดพลาดของพื้นที่ย่อยจะทำให้เมื่อเราเลือกพื้นที่ที่ทำทนายเราจะได้พื้นที่บริเวณที่ใกล้กันซึ่งไม่ส่งผลต่อการฝึกสอนตัวแบบรู้จำ

4.5.3 การเพิ่มปริมาณข้อมูล

งานวิจัยนี้คำนวณจำนวนตัวอย่างที่ต้องการเพิ่มเข้าไปต่อภาพต้นฉบับเพื่อความเสมอภาคของปริมาณข้อมูลที่ต้องการเพิ่มเข้าไปในชุดข้อมูลฝึกสอนจึงทำให้จำนวนข้อมูลในชุดข้อมูลฝึกสอนใหม่มีขนาดไม่เท่ากับ $k + 1$ เท่าของจำนวนข้อมูลเดิมพอดีแต่มีขนาดที่ใกล้เคียงกันซึ่งไม่ส่งผลต่อการทดลองเพราะว่าข้อมูลมีปริมาณมาก งานวิจัยนี้ใช้วิธีการเพิ่มปริมาณข้อมูลด้วยการหมุนและกลับภาพทำให้สามารถเพิ่มข้อมูลเป็น 8 เท่าจากจำนวนข้อมูลเดิมและผู้วิจัยเลือกใช้วิธีการเดียวกันกับการเพิ่มข้อมูลด้วย Region-Focus Training ซึ่งจำนวนข้อมูลสามารถคำนวณได้จากสมการต่อไปนี้

$$\text{จำนวนตัวอย่างในชุดข้อมูลใหม่} \approx (k + 1) * \text{จำนวนตัวอย่างเดิม}$$

$$\text{จำนวนตัวอย่างที่ต้องการเพิ่มต่อภาพต้นฉบับ} = \left[\frac{k * \text{จำนวนตัวอย่างทั้งหมด}}{8 * \text{จำนวนภาพต้นฉบับทั้งหมด}} \right]$$

โดย k คือจำนวนจริงที่กำหนดจำนวนข้อมูลที่ต้องการเพิ่ม

4.6 ภาพรวมของระบบการทดลอง

งานวิจัยนี้ต้องการเพิ่มความแม่นยำในการแบ่งแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลโดยสร้างตัวแบบรู้จำเชิงลึกที่ฝึกสอนจากภาพย่อย สถาปัตยกรรมโครงข่ายประสาทเทียมของงานวิจัยนี้คือสถาปัตยกรรม U-Net ที่ประยุกต์กับ ResNet และใช้วิธีการเพิ่มปริมาณข้อมูลด้วย Region-Focus Training และการหมุนและกลับภาพ งานวิจัยนี้แบ่งการทดลองออกเป็น 9 การทดลอง โดยขั้นตอนการทดลองเป็นไปดังต่อไปนี้

- เก็บข้อมูลภาพบาดแผลเรื้อรัง
 - Medetec Medical image database [1]
 - โรงพยาบาลรามาริบัติ
- สร้างภาพผลเฉลย
 - ใช้โปรแกรม MultiMarker v1.1
 - แบ่งวัตถุเป้าหมายออกเป็น 4 ประเภท
 - พื้นหลัง (background)
 - เนื้อเยื่อเนื้อแดง (granulation)
 - เนื้อเยื่อหนอง (slough)
 - เนื้อเยื่อเนื้อตาย (necrosis)
- แบ่งชุดข้อมูลออกเป็น 3 ชุด
 - ชุดข้อมูลฝึกสอน (training set)
 - ชุดข้อมูลตรวจสอบ (validation set)
 - ชุดข้อมูลทดสอบ (testing set)
- สร้างชุดข้อมูลฝึกสอน (ภาพย่อย)
 - สร้างจากชุดข้อมูลฝึกสอน
 - ใช้วิธีการแบ่งภาพออกเป็นภาพย่อย
 - ภาพย่อยขนาด 256x256
 - ให้ stride เท่ากับ (128, 128)
 - หมุนและกลับภาพ
- ผู้สอนตัวแบบรู้จำ (pre-trained model)
 - จำนวนรอบเท่ากับ 300 รอบ
 - ค่า learning rate เริ่มต้นคือ $0.0001(10^{-4})$
 - ลดค่า learning rate ลง 10 เท่าทุก ๆ 100 รอบ

- สร้างชุดข้อมูลฝึกสอนใหม่ด้วย Region-Focus Training
 - ใช้ตัวแบบรู้จำที่ฝึกสอนไว้ก่อนหน้า (pre-trained model)
 - กำหนด $k=0, 0.125, 0.25, 0.375, 0.5, 0.625, 0.75, 0.875$ และ 1.0
- ฝึกสอนตัวแบบรู้จำใหม่โดยใช้ชุดข้อมูลใหม่
 - ฝึกสอนต่อจาก pre-trained model
 - ใช้ค่า Learning rate คือ $0.000001 (10^{-6})$
 - จำนวนรอบเท่ากับ 100 รอบ
- ประเมินและสรุปผล

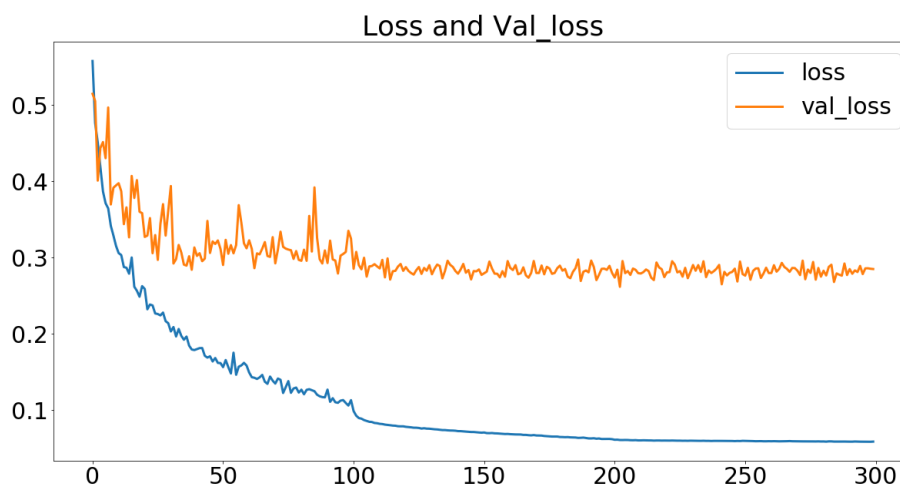


บทที่ 5

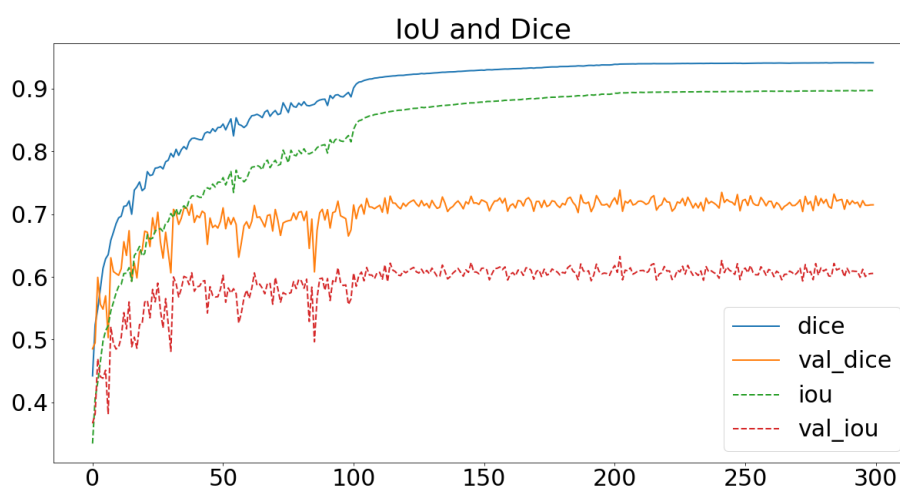
ผลการดำเนินการวิจัย

5.1 การฝึกสอนตัวแบบรู้จำเชิงลึก


ในส่วนนี้แสดงผลลัพธ์ของการฝึกสอนตัวแบบรู้จำ (pre-trained model) ซึ่งถูกฝึกสอนมา 300 รอบ โดยจะแสดงกราฟของ training loss, validation loss, training IoU, validation IoU, training dice, validation dice, accuracy และ validation accuracy นอกจากนี้ยังแสดงผลลัพธ์ในหน่วย dice (DSC), IoU และ region-size error (RSE) ซึ่งทดสอบกับชุดข้อมูลฝึกสอน (training set) ชุดข้อมูลตรวจสอบ (validation set) และชุดข้อมูลทดสอบ (testing set) โดยมีผลลัพธ์ดังต่อไปนี้



ภาพที่ 28 ค่า training loss และ validation loss



ภาพที่ 29 ค่า training IoU, training dice, validation IoU และ validation dice



ภาพที่ 30 ค่า training accuracy และ validation accuracy

ตารางที่ 19 ผลลัพธ์ทดสอบกับชุดข้อมูลภาพต้นฉบับ

	IoU(%)	DSC(%)	RSE Tissue (%) (แยกเนื้อเยื่อ)	RSE Wound (%) (บาดแผล)
ชุดข้อมูลฝึกสอน Training set	79.18	85.85	50.90	76.65
ชุดข้อมูลตรวจสอบ Validation set	54.14	65.37	172.54	143.35
ชุดข้อมูลทดสอบ Testing set	52.76	65.46	139.80	113.71

ผลลัพธ์ของตัวแบบรู้จำในภาพที่ 28 ภาพที่ 29 และภาพที่ 30 แสดงให้เห็นว่าตัวแบบรู้จำมีเสถียรภาพและอิมตัวแล้ว ผู้วิจัยใช้ตัวแบบรู้จำนี้เป็นตัวแบบรู้จำพื้นฐานเพื่อสร้างชุดข้อมูลใหม่ด้วย Region-Focus Training และใช้เป็นตัวแบบรู้จำเพื่อนำไปฝึกสอนในขั้นต่อไป ผลลัพธ์ที่ทดสอบด้วยชุดข้อมูลภาพต้นฉบับ (ตารางที่ 19) พบว่าในชุดข้อมูลตรวจสอบและชุดข้อมูลทดสอบให้ค่า dice และ IoU ที่มากกว่า 50% ค่า RSE ทั้งแบบแยกเนื้อเยื่อและแบบบาดแผลมีค่ามากกว่า 100% ซึ่งถือว่ามีความ

5.2 Region-Focus Training

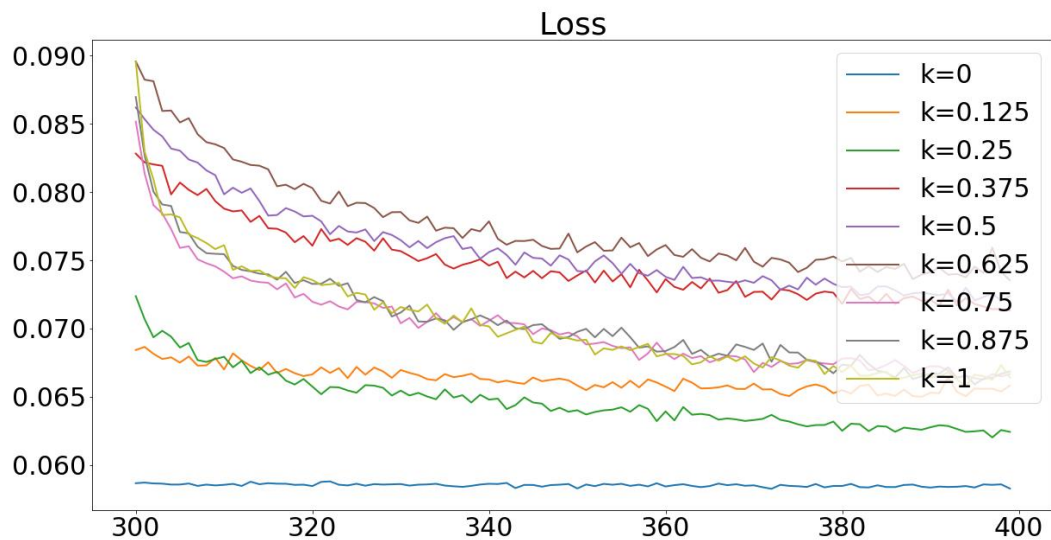
จากขั้นตอนก่อนหน้าซึ่งเป็นการฝึกสอนตัวแบบรู้งำ (pre-trained model) ผู้วิจัยใช้ตัวแบบดังกล่าวสร้างชุดข้อมูลใหม่ด้วยวิธีการ Region-Focus Training โดยกำหนดค่า $k=0, 0.125, 0.25, 0.375, 0.5, 0.625, 0.75, 0.875$ และ 1.0 ทำให้ได้ชุดข้อมูลใหม่ 9 ชุดและจำนวนข้อมูลในแต่ละชุดถูกแสดงไว้ในตารางที่ 20 งานวิจัยนี้เลือกใช้ค่า k อยู่ในช่วง $[0, 1]$ เพราะพื้นที่ที่ท้าทายในแต่ละภาพเกิดจากวิธีการสร้างภาพย่อยโดยใช้ค่า stride เท่ากับ $(1, 1)$ หมายความว่าภาพย่อยหลายภาพมีความใกล้เคียงกันมากและมีโอกาสที่จะมีความท้าทายที่ใกล้เคียงกันถึงแม้ว่างานวิจัยนี้จะใช้วิธีการลดค่าหลังจากคำนวณความผิดพลาดแล้วแต่ถ้า k มีค่ามากทำให้มีโอกาสที่ภาพที่ถูกเพิ่มเข้ามาในชุดข้อมูลมีความใกล้เคียงกับภาพที่ถูกเพิ่มเข้ามาก่อนหน้านี้มากขึ้น

ตารางที่ 20 จำนวนข้อมูลในชุดข้อมูลใหม่ที่ได้จากวิธีการ Region-Focus Training

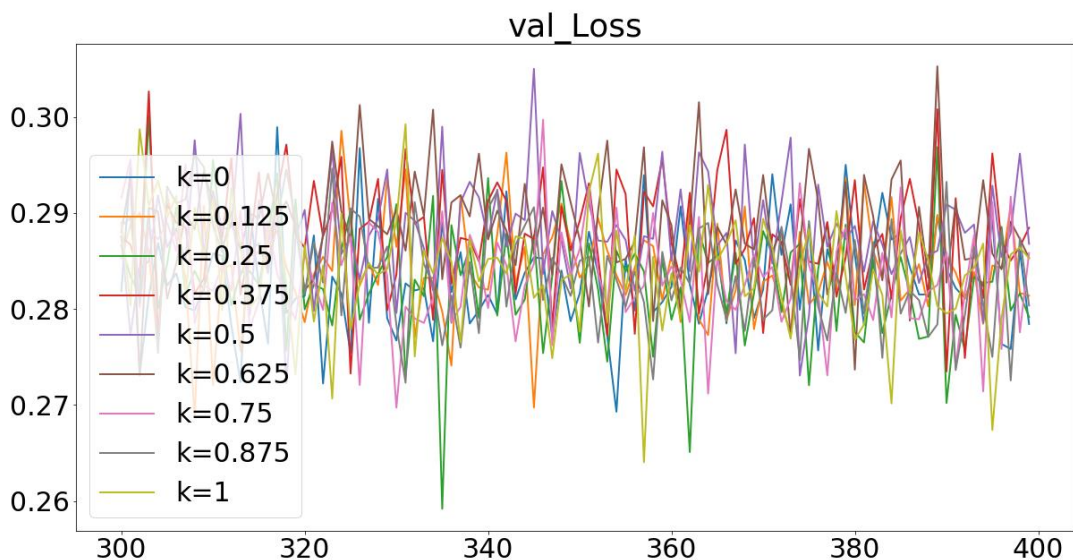
ชุดข้อมูล (k)	จำนวนตัวอย่าง (ภาพย่อย)
0	21,160
0.125	25,000
0.25	26,920
0.375	30,760
0.5	32,680
0.625	34,600
0.75	38,400
0.875	40,360
1.0	44,200

หลังจากสร้างชุดข้อมูลใหม่ผู้วิจัยฝึกสอนตัวแบบรู้งำโดยใช้ชุดข้อมูลที่สร้างขึ้นใหม่แต่ละชุดโดยฝึกสอนต่อจากตัวแบบรู้งำในขั้นตอนก่อนหน้า (pre-trained model) อีก 100 รอบและใช้ค่า Learning rate เป็น $0.000001 (10^{-6})$ ซึ่งผลลัพธ์ของการทดลองถูกแสดงไว้ในภาพที่ 31 ภาพที่ 32 ภาพที่ 33 และภาพที่ 34 โดยการแสดงผลลัพธ์จะไม่แสดงค่า training dice และ validation dice เพราะว่าการาฟที่ได้จากค่า training dice และ validation dice ลักษณะที่ใกล้เคียงกับกราฟที่ได้จากค่า training IoU (ภาพที่ 33) และ validation IoU (ภาพที่ 34) ตามลำดับ

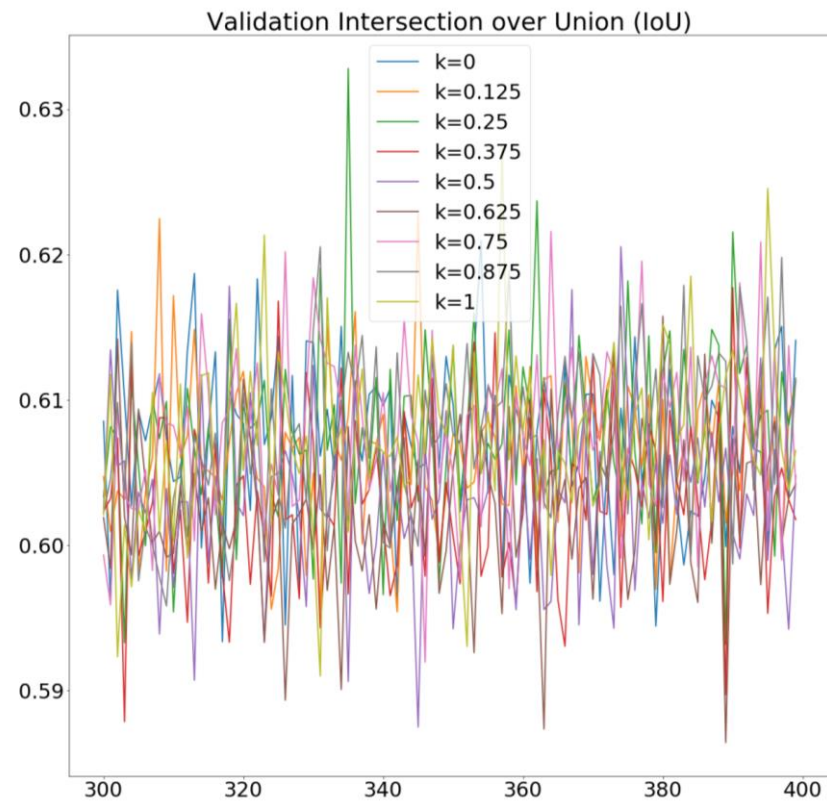
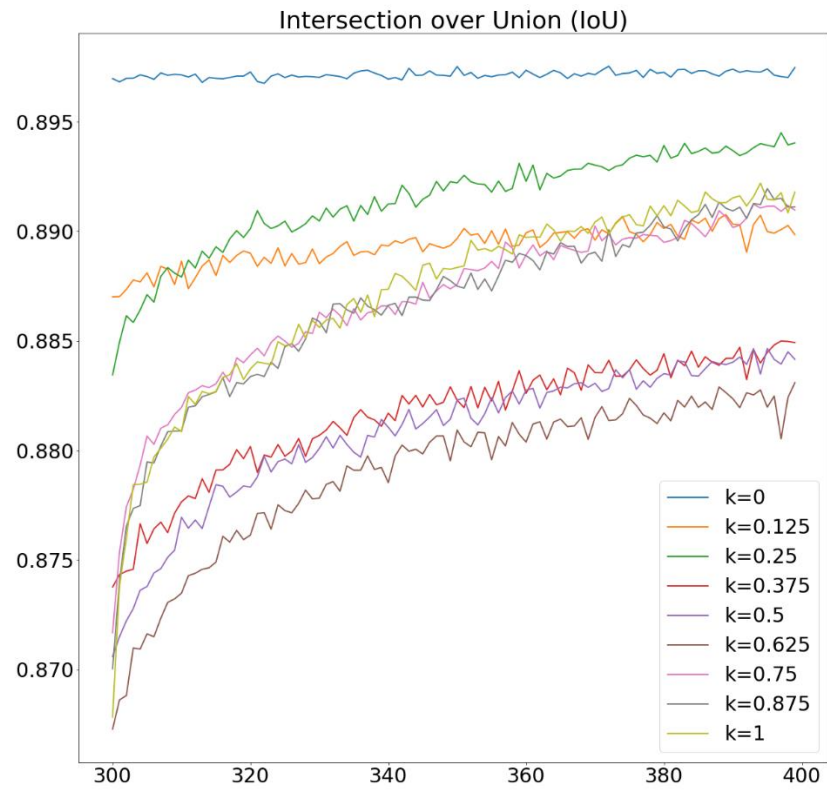
ค่า training loss เมื่อ $k = 0$ (เส้นสีฟ้าด้านล่างสุดในภาพที่ 31) แสดงให้เห็นว่าตัวแบบรู้จำที่ถูกฝึกไว้ก่อนหน้า (pre-trained model, 300 รอบ) นั้นไม่มีค่า training loss ที่ดีขึ้นหรือแย่ลง หมายความว่า การฝึกสอนตัวแบบรู้จำนี้เริ่มตัวแล้ว และค่า training loss เมื่อ k มากกว่า 0 มีแนวโน้มลดลงและยังไม่เข้าสู่จุดอิ่มตัว หมายความว่า การฝึกสอนตัวแบบเมื่อ k มากกว่า 0 ยังไม่เริ่มตัวและยังมีโอกาสพัฒนาต่อไปได้อีก



ภาพที่ 31 กราฟแสดงค่า training loss



ภาพที่ 32 กราฟแสดงค่า validation loss



กราฟของค่า training IoU (ภาพที่ 33) แสดงผลการทำนายจากตัวอย่างในชุดข้อมูลฝึกสอน (ภาพย่อ) ในหน่วย IoU เส้นของค่า IoU เมื่อ k เท่ากับ 0 (เส้นสีฟ้าด้านบนสุด) มีลักษณะคล้ายเส้นตรงและมีค่าที่สูงสุดในแต่ละรอบของการฝึกสอน เพราะว่าชุดข้อมูลที่นำมาทำนายเป็นชุดข้อมูลเดิมที่ตัวแบบเคยทำนายมาก่อนในการฝึกสอน 300 รอบก่อนหน้านี้ เมื่อค่า k เท่ากับ 0.125 และ 0.25 ให้ผลลัพธ์ที่ตรงลงมาจากเมื่อ k เท่ากับ 0 เพราะเมื่อ k เท่ากับ 0.125 หรือ 0.25 มีการเพิ่มตัวอย่างที่ทำนายเข้าไปเพียงเล็กน้อยจึงทำให้ตัวแบบยังสามารถทำนายได้ดีกว่าเมื่อเพิ่มตัวอย่างที่ทำนายเข้าไปมากกว่าคือเมื่อเพิ่มพื้นที่ที่ทำนายและตัวแบบไม่เคยพบเห็นมาก่อนทำให้ตัวแบบทำนายและได้ผลลัพธ์ที่แย่ง ซึ่งกราฟที่แสดงอยู่ในภาพที่ 33 นั้นสมเหตุสมผลและเป็นไปตามที่ควรจะเป็น

5.3 การประเมินผล (Evaluation)

งานวิจัยนี้ใช้หน่วยในการประเมินการทดลอง 4 หน่วยได้แก่ Confusion Matrix, Intersection over Union (IoU), Dice Similarity Index (Dice Similarity Coefficient, DSC) และ Region-size error (RSE) ในส่วนนี้แสดงผลการประเมินการทดลองโดยแบ่งออกเป็น 3 ส่วนคือ 1. Confusion Matrix 2. Intersection over Union และ Dice Similarity Index 3. Region-size error และค่าสหสัมพันธ์ (Correlation)

5.3.1 Confusion Matrix

ในส่วนนี้แสดงค่า precision, recall และ F1-score ของแต่ละเนื้อเยื่อบาดแผลเรื้อรังในทุกการทดลองโดยแบ่งการผลลัพธ์ออกเป็น 4 ส่วนตามชนิดเนื้อเยื่อบาดแผลคือ 1. พื้นหลัง 2. เนื้อเยื่อเนื้อแดง 3. เนื้อเยื่อหนอง และ 4. เนื้อเยื่อเนือตาย

5.3.1.1 พื้นหลัง (Background)

ผลลัพธ์ของพื้นหลัง (ตารางที่ 21) แสดงให้เห็นว่าการทำนายพิกเซลว่าเป็นพื้นหลังทำได้ง่ายแม่นยำ ซึ่งถือว่าสมเหตุสมผลเนื่องจากข้อมูลมีพิกเซลที่มีผลเฉลยเป็นพื้นหลังมีจำนวนมากและมากกว่าพิกเซลที่มีผลเฉลยเป็นเนื้อเยื่อบาดแผลหลายเท่าตัวโดยจำนวนพิกเซลของข้อมูลผลเฉลยถูกแสดงไว้ในตารางที่ 22

ตารางที่ 21 ค่า precision, recall และ F1-score ของการทำนายพื้นหลัง (background)

การทดลอง (k)	Precision	Recall	F1-score
0	0.99	0.99	0.99
0.125	0.99	0.99	0.99
0.25	0.99	0.99	0.99
0.375	0.99	0.99	0.99
0.5	0.99	0.99	0.99
0.625	0.99	0.99	0.99
0.75	0.99	0.99	0.99
0.875	0.99	0.99	0.99
1.0	0.99	0.99	0.99

ตารางที่ 22 ข้อมูลผลเฉลย (จำนวนพิกเซล)

ชุดข้อมูล	บาดแผล	พื้นหลัง	รวม
ฝึกสอน (training set)	7,263,217	258,891,663	266,154,880
ทดสอบ (testing set)	2,245,795	80,814,685	83,060,480

5.3.1.2 เนื้อเยื่อเนื้อแดง (Granulation)

ผลลัพธ์ของการทำนายเนื้อเยื่อเนื้อแดง (ตารางที่ 23) เห็นได้ว่าค่า precision, recall และ F1-score ดีที่สุดคือเมื่อ k มีค่าเท่ากับ 0.875 แต่มากกว่าเมื่อ k ไม่เท่ากับ 0.875 ไม่มากนักและเมื่อ k มีค่ามากกว่า 0 ได้ค่า recall มากกว่าหรือเท่ากับเมื่อ k เท่ากับ 0 เสมอกล่าวคือเมื่อ k มีค่ามากกว่า 0 ทำให้อัตราส่วนของการทำนายที่ถูกต้องมีมากกว่าเมื่อ k เท่ากับ 0 ค่า F1-score ของการทำนายเนื้อเยื่อเนื้อแดงเมื่อ k มีค่ามากกว่า 0 มีค่ามากกว่าหรือเท่ากับเมื่อ k เท่ากับ 0 และมีค่าสูงที่สุดเมื่อ k เท่ากับ 0.75 ซึ่งให้มีค่า F1-score เท่ากับ 0.7695 จากผลลัพธ์ในส่วนนี้แสดงให้เห็นว่าวิธีการ Region-Focus training สามารถเพิ่มประสิทธิภาพให้กับการฝึกสอนตัวแบบรู้จำเชิงลึกได้ตามสมมติฐานของงานวิจัย

ตารางที่ 23 ค่า precision, recall และ F1-score ของการทำนายเนื้อเยื่อเนื้อแดง (granulation)

การทดลอง (k)	Precision	Recall	F1-score
0	0.79	0.73	0.7588
0.125	0.79	0.73	0.7588
0.25	0.78	0.74	0.7595
0.375	0.79	0.74	0.7642
0.5	0.79	0.74	0.7642
0.625	0.78	0.75	0.7647
0.75	0.78	0.75	0.7647
0.875	0.79	0.75	0.7695
1.0	0.78	0.75	0.7647

5.3.1.3 เนื้อเยื่อหนอง (Slough)

ตารางที่ 24 ค่า precision, recall และ F1-score ของการทำนายเนื้อเยื่อหนอง (slough)

การทดลอง (k)	Precision	Recall	F1-score
0	0.71	0.70	0.7050
0.125	0.69	0.73	0.7094
0.25	0.70	0.75	0.7241
0.375	0.67	0.75	0.7077
0.5	0.68	0.77	0.7222
0.625	0.67	0.75	0.7077
0.75	0.68	0.78	0.7266
0.875	0.69	0.76	0.7233
1.0	0.67	0.79	0.7251

ผลลัพธ์ของการทำนายเนื้อเยื่อหนอง (ตารางที่ 24) พบว่าเมื่อ k มีค่ามากกว่า 0 ทำให้ค่า precision น้อยกว่าเมื่อ k เท่ากับ 0 และเมื่อ k มากกว่า 0 ค่า recall มีค่ามากกว่าหรือเท่ากับเมื่อ k เท่ากับ 0 ค่า precision ที่ดีที่สุดคือเมื่อ k เท่ากับ 0 และผลลัพธ์ของค่า recall ที่ดีที่สุดคือเมื่อ k เท่ากับ 1.0 ในกรณีที่ k เท่ากับ 0.75 ให้ค่า F1-score ที่มากที่สุดกล่าวคือเมื่อ k เท่ากับ 0.75 มีประสิทธิภาพสูงที่สุด จากผลลัพธ์โดยรวมถือว่าการการทำนายเนื้อเยื่อหนองทำได้ไม่ด้นักเมื่อเทียบกับ

การทำนายเนื้อเยื่อเนื้อแดงหมายความว่าการทำนายเนื้อเยื่อหนองมีความแม่นยำต่ำกว่าการทำนายเนื้อเยื่อแดงและพื้นหลังแต่เมื่อ k มีค่ามากกว่า 0 ให้มีค่า F1-score ที่มากกว่าเมื่อ k เท่ากับ 0 เสมอ หมายความว่าวิธีการ Region-Focus Training สามารถเพิ่มประสิทธิภาพให้กับการฝึกสอนตัวแบบรู้จำเชิงลึกได้ตามสมมติฐานของงานวิจัย

5.3.1.4 เนื้อเยื่อเนื้อตาย (Necrosis)

ผลลัพธ์ของการทำนายเนื้อเยื่อเนื้อตาย (ตารางที่ 25) เห็นได้ว่าค่า precision มีค่าใกล้เคียงกันมากแต่ค่า recall มีค่าน้อยที่สุดเมื่อ k เท่ากับ 0 ซึ่งต่างจากค่าที่มากที่สุดคือ 0.42 เมื่อ k มีค่าเท่ากับ 0.75 ถึง 0.23 หมายความว่าวิธีการ Region-Focus Training สามารถเพิ่มความแม่นยำในการทำนายเนื้อเยื่อเนื้อตายได้อย่างมาก แต่ภาพรวมของการทำนายเนื้อเยื่อเนื้อตายมีความแม่นยำต่ำที่สุดเมื่อเทียบกับทุกเนื้อเยื่อที่งานวิจัยนี้ต้องการจำแนก ผลลัพธ์ในหน่วย F1-score เมื่อ k มีค่ามากกว่า 0 ให้ค่ามากกว่าเมื่อ k เท่ากับ 0 เสมอหมายความว่าวิธีการ Region-Focus Training สามารถเพิ่มประสิทธิภาพให้กับการฝึกสอนตัวแบบรู้จำเชิงลึกได้ตามสมมติฐานของงานวิจัยและสามารถเพิ่มประสิทธิภาพได้อย่างมาก

ตารางที่ 25 ค่า precision, recall และ F1-score ของการทำนายเนื้อเยื่อเนื้อตาย (necrosis)

การทดลอง (k)	Precision	Recall	F1-score
0	0.33	0.19	0.2412
0.125	0.34	0.21	0.2596
0.25	0.34	0.23	0.2744
0.375	0.33	0.28	0.3030
0.5	0.34	0.38	0.3589
0.625	0.33	0.33	0.3300
0.75	0.33	0.42	0.3696
0.875	0.33	0.37	0.3489
1.0	0.33	0.38	0.3532

จากผลลัพธ์ของ Confusion Matrix เห็นได้ว่าวิธีการ Region-Focus Training สามารถเพิ่มประสิทธิภาพของการฝึกสอนตัวแบบรู้จำเชิงลึกได้และในการทำนายเนื้อเยื่อเนื้อแดงและหนองมีค่า F1-score ที่สูงกว่าเนื้อตายมากหมายความว่าทำนายเนื้อเยื่อเนื้อแดงและหนองได้แม่นยำกว่าเนื้อตาย

5.3.2 Intersection over Union และ Dice Similarity Index

ในส่วนนี้แสดงผลการประเมินในหน่วยของ Intersection over Union (IoU) และ Dice Similarity Index (Dice Similarity Coefficient, DSC) โดยแสดงค่าเฉลี่ยของการแยกพื้นที่ของแต่ละเนื้อเยื่อโดยไม่รวมพื้นหลัง

ตารางที่ 26 ผลลัพธ์การแยกพื้นที่เฉลี่ยแต่ละเนื้อเยื่อโดยไม่รวมพื้นหลัง

การทดลอง (k)	IoU (%)	DSC (%)
0	52.28	65.07
0.125	53.46	66.08
0.25	54.66	67.20
0.375	54.57	67.23
0.5	55.96	68.59
0.625	55.15	67.88
0.75	56.48	69.18
0.875	55.87	68.54
1.0	56.12	68.69

จากผลลัพธ์ในตารางที่ 26 เมื่อ k มีค่ามากกว่า 0 มีค่า IoU และ dice ที่ดีกว่าเมื่อ k มีค่าเท่ากับ 0 ในกรณีที่ k มีค่าเท่ากับ 0.75 ให้ค่า IoU ที่มากกว่าเมื่อ k เท่ากับ 0 ถึง 4.2% และค่า dice ถึง 4.11% กล่าวคือวิธีการ Region-Focus Training สามารถเพิ่มความแม่นยำให้การฝึกสอนตัวแบบรู้จำเชิงลึกอย่างมาก

5.3.3 Region-size error (RSE) และค่าสหสัมพันธ์ (Correlation)

ในส่วนนี้แสดงผลลัพธ์ในหน่วย region-size error (RSE) โดยแบ่งออกเป็น 2 แบบคือแบบแยกชนิดเนื้อเยื่อไม่รวมพื้นหลังและแบบขาดแผล (รวมทุกเนื้อเยื่อแต่ไม่รวมพื้นหลัง) นอกจากนี้ยังแสดงค่าสหสัมพันธ์ (Correlation) ระหว่างอัตราส่วนของขาดแผลในภาพกับค่า RSE แบบขาดแผล โดยผลลัพธ์ในหน่วย RSE ถูกแสดงไว้ในตารางที่ 27


ตารางที่ 27 ผลลัพธ์การแยกพื้นที่ในหน่วย RSE แบบแยกชนิดเนื้อเยื่อและแบบบาดแผล

การทดลอง (k)	RSE _{Tissues} (%)	RSE _{Wound} (%)
0	135.84	113.23
0.125	119.68	96.61
0.25	116.38	90.20
0.375	103.87	73.57
0.5	108.86	63.33
0.625	101.19	63.41
0.75	97.83	54.11
0.875	108.50	61.27
1.0	101.05	60.24

ผลลัพธ์การประเมินในหน่วย RSE (ตารางที่ 27) พบว่าค่า RSE มีค่าน้อยที่สุดคือเมื่อ k มีค่าเท่ากับ 0.75 และเมื่อ k มีค่ามากกว่า 0 ทำให้ค่า RSE น้อยกว่าเมื่อ k เท่ากับ 0 เสมอและในกรณีที่ดีที่สุดให้ผลลัพธ์ที่ดีกว่าเมื่อ k เท่ากับ 0 ในหน่วย RSE แบบแยกชนิดเนื้อเยื่อและบาดแผลถึง 38.01% และ 59.12% ตามลำดับ หมายความว่าวิธีการ Region-Focus Training สามารถเพิ่มประสิทธิภาพให้การฝึกสอนตัวแบบรู้จำเชิงลึกได้

นอกจากนี้ผลลัพธ์ในตารางที่ 27 มีค่า RSE ที่มากผิดปกติ ผู้วิจัยวิเคราะห์ปัญหาดังกล่าวเพื่อหาสาเหตุของปัญหาโดยผู้วิจัยพบว่าภาพที่มีค่า RSE มากผิดปกติมีลักษณะบางอย่างที่คล้ายกันคือมีวัตถุแปลกปลอมที่มีลักษณะคล้ายเนื้อเยื่อบาดแผล บาดแผลมีขนาดเล็กเมื่อเทียบกับขนาดของภาพ กล่าวคืออัตราส่วนของบาดแผลในภาพมีน้อย บาดแผลมีลักษณะคลุมเครือเช่น มีเนื้อเยื่อที่รักษาหายแล้วแต่ยังมีลักษณะเป็นสีแดง บาดแผลเป็นบาดแผลลึก ขอบแผลเป็นหนังที่ไม่ใช่บาดแผลหรือบาดแผลที่ผู้เชี่ยวชาญไม่สามารถระบุได้ชัดเจนว่าเป็นเนื้อเยื่อชนิดใด


ในความพยายามหาสาเหตุดังกล่าวผู้วิจัยแสดงตัวอย่างของภาพที่มีค่า RSE มากผิดปกติซึ่งได้จากการทดลองที่ให้ผลดีที่สุด (k=0.75) และผู้วิจัยแสดงค่าสหสัมพันธ์ (correlation) ระหว่างอัตราส่วนของบาดแผลในภาพและค่า RSE แบบบาดแผล ตัวอย่างภาพที่มีค่า RSE มากผิดปกติถูกแสดงไว้ที่ภาพที่ 35 ผลลัพธ์การคำนวณค่าสหสัมพันธ์ (ตารางที่ 28) พบว่ามีความสัมพันธ์กันในเชิงลบหมายความว่าเมื่ออัตราส่วนของบาดแผลในภาพมีค่าน้อยลงทำให้ค่า RSE แบบบาดแผลมีค่าเพิ่มขึ้น ในทำนองเดียวกันเมื่อค่าอัตราส่วนของบาดแผลในภาพมีค่ามากขึ้นทำให้ค่า RSE แบบบาดแผลมีค่าลดลง



ภาพที่ 35 ตัวอย่างภาพที่ให้ค่า RSE แบบขาดแคลนมากผิดปกติโดยค่า RSE ของภาพบน ภาพกลาง และภาพล่างมีค่า 440.771, 654.627 และ 270.111 ตามลำดับ

ตารางที่ 28 ค่าสหสัมพันธ์ (correlation) ระหว่างอัตราส่วนของขนาดผลในภาพกับค่า RSE แบบรวม
บนชุดข้อมูลทดสอบ (testing set)

การทดลอง (k)	ค่าสหสัมพันธ์ (correlation)
0	-0.2779
0.125	-0.2673
0.25	-0.2616
0.375	-0.2836
0.5	-0.2715
0.625	-0.2807
0.75	-0.2738
0.875	-0.2772
1.0	-0.2698



บทที่ 6

สรุปผลการดำเนินงานวิจัยและข้อเสนอแนะ

งานวิจัยนี้ได้เสนอวิธีการในการแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผลเรื้อรังจากภาพถ่ายบาดแผลโดยใช้วิธีการสร้างตัวแบบรู้จำเชิงลึกซึ่งมุ่งเน้นที่การเพิ่มประสิทธิภาพของการฝึกสอนตัวแบบรู้จำด้วยวิธีการ Region-Focus Training ซึ่งผลลัพธ์ของการทดลองแสดงให้เห็นว่าวิธีการเพิ่มข้อมูลด้วยวิธีการ Region-Focus Training นั้นสามารถเพิ่มประสิทธิภาพให้การฝึกสอนตัวแบบรู้จำได้ตามสมมติฐานของงานวิจัย

แนวคิดของการฝึกสอนเครื่องแบบใหม่นี้พยายามให้เครื่องได้ฝึกกับตัวอย่างที่ทำหายมากขึ้น โดยอาศัยความผิดพลาดในการทำนายเป็นตัววัดระดับความทำหายของตัวอย่าง การจะทำให้สำเร็จได้ภายในเวลาที่จำกัดจำเป็นต้องใช้อัลกอริทึมที่มีประสิทธิภาพทั้งในการประเมินความยากง่ายของตัวอย่างและการหาตำแหน่งภาพย่อยที่ทำหายเป็นพิเศษ ซึ่งวิทยานิพนธ์นี้ได้นำเสนอแนวทางในการคำนวณและทดสอบประสิทธิภาพด้วยการทดลอง

แนวคิดของวิธีการที่นำเสนอขึ้นกับค่าพารามิเตอร์ k ซึ่งเป็นค่าที่กำหนดจำนวนตัวอย่างที่ทำหายที่จะใช้ในการฝึกตัวแบบรู้จำ จากผลลัพธ์ของงานวิจัยนี้พบว่าเมื่อ k มีค่ามากขึ้นทำให้ผลการทดลองมีแนวโน้มดีขึ้น แต่ไม่เสมอไปเพราะค่า k ที่ดีที่สุดในงานวิจัยนี้คือ 0.75 ซึ่งการเพิ่มค่า k เป็น 0.875 หรือ 1.0 ทำให้ความแม่นยำที่ได้ในการทดลองน้อยลง ดังนั้นการเลือกค่า k ที่เหมาะสมเป็นอีกปัจจัยหนึ่งที่ส่งผลต่อประสิทธิภาพที่เพิ่มขึ้นของการฝึกสอนตัวแบบรู้จำด้วยวิธีการที่นำเสนอ

ข้อจำกัดของวิธีการ Region-Focus Training นั้นคือผู้ใช้งานต้องใช้วิธีการแบ่งภาพออกเป็นภาพย่อยจึงสามารถประยุกต์ใช้กับวิธีการ Region-Focus Training ได้ งานวิจัยนี้ทดลองใช้วิธีการ Region-Focus Training กับงานแยกพื้นที่และจำแนกชนิดเนื้อเยื่อบาดแผล ซึ่งภาพมีเพียงภาพบาดแผลเรื้อรังและภาพผลเฉลยได้จากตัวผู้วิจัยเอง

ผู้วิจัยคาดหวังว่าวิธีการ Region-Focus Training จะช่วยให้การแยกพื้นที่ภาพขนาดใหญ่มีความแม่นยำที่สูงขึ้น โดยเฉพาะภาพ pathology ทางการแพทย์ซึ่งมักมีขนาดมากกว่า 1 พันล้านพิกเซลต่อภาพ ทำให้ไม่สามารถที่จะนำเข้าภาพสู่การคำนวณในเครื่องคอมพิวเตอร์ทั่วไปได้ในคราวเดียว แต่จำเป็นต้องแบ่งย่อยเป็นพื้นที่ภาพขนาดเล็กก่อน ซึ่ง Region-Focus Training จะสามารถช่วยให้การฝึกตัวแบบรู้จำเน้นไปที่พื้นที่ที่ทำหายและเพิ่มความแม่นยำโดยรวมได้ดีขึ้น

ในอนาคตผู้วิจัยจะนำวิธีการที่นำเสนอมาสร้างแอปพลิเคชันเพื่อช่วยให้แพทย์สามารถวัดขนาดของบาดแผลได้ดียิ่งขึ้นและสามารถช่วยให้แพทย์เลือกวิธีการที่เหมาะสมและมีมาตรฐานในการรักษาผู้ป่วย โดยให้แพทย์ส่งภาพบาดแผลที่มีวัตถุอ้างอิงอยู่ในภาพและแอปพลิเคชันจะส่งข้อมูล

ผลลัพธ์คืนให้แพทย์ ผู้วิจัยจะพัฒนาวิธีการและเทคนิคใหม่เพื่อเพิ่มประสิทธิภาพของแอปพลิเคชันให้มีความแม่นยำและประสิทธิภาพมากพอที่จะนำมาใช้งานได้จริง ทำที่สุดนี้ผู้วิจัยคาดหวังว่างานวิจัยนี้จะเป็นประโยชน์ต่อสังคมต่อไป



รายการอ้างอิง

- [1] Medetec medical image database [Online]. Available: <http://www.medetec.co.uk/files/medetec-image-databases.html>
- [2] C. Pathompatai, R. Kanawong, and P. Taeprasartsit, "Region-Focus Training: Boosting Accuracy for Deep-Learning Image Segmentation," *International Joint Conference on Computer Science and Software Engineering (JCSSE)*, 2019.
- [3] C. Wang *et al.*, "A unified framework for automatic wound segmentation and analysis with deep convolutional neural networks," in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2015, pp. 2415-2418.
- [4] G. E. Dahl, T. N. Sainath, and G. E. Hinton, "Improving deep neural networks for LVCSR using rectified linear units and dropout," in *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, 2013, pp. 8609-8613.
- [5] A. Dosovitskiy, J. T. Springenberg, and T. Brox, "Learning to generate chairs with convolutional neural networks," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1538-1546.
- [6] P. C. Hough V, "Method and means for recognizing complex patterns," United States, 1962. Available: <http://www.freepatentsonline.com/3069654.html>.
- [7] B. Scholkopf and A. J. Smola, *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. MIT Press, 2001.
- [8] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Cham, 2015, pp. 234-241: Springer International Publishing.
- [9] X. Yang, Z. Zeng, and S. Yi, "Deep convolutional neural networks for automatic segmentation of left ventricle cavity from cardiac magnetic resonance images," *IET Computer Vision*, vol. 11, no. 8, pp. 643-649, 2017.
- [10] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," 2016.

- [11] M. E. N. and B. W. A., *Intelligent scissors for image composition* (SIGGRAPH '95: Proceedings of the 22nd annual conference on Computer graphics and interactive techniques). 1995.
- [12] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," *CoRR*, vol. abs/1412.6980, 2014.





ประวัติผู้เขียน

ชื่อ-สกุล	ชนก ปฐมเพทาย
วัน เดือน ปี เกิด	21 ตุลาคม 2537
สถานที่เกิด	อำเภอเมืองกาญจนบุรี จังหวัดกาญจนบุรี
วุฒิการศึกษา	สำเร็จการศึกษาปริญญาวิทยาศาสตรบัณฑิต สาขาวิชาคณิตศาสตร์ มหาวิทยาลัยศิลปากร พ.ศ.2559 อาจารย์ที่ปรึกษาวิทยานิพนธ์ ผศ.ดร.เฉลิมพงศ์ วรวรโรจน์ทัย GPA: 3.13 ศึกษาต่อระดับปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ มหาวิทยาลัยศิลปากร อาจารย์ที่ปรึกษาวิทยานิพนธ์ อ.ดร. ภิญโญ แท้ประสาธสิทธิ์ GPA: 3.88
ที่อยู่ปัจจุบัน	225 ถนนแสงชูโตใต้ ตำบลปากแพรก อำเภอเมืองกาญจนบุรี จังหวัด กาญจนบุรี 71000
ผลงานตีพิมพ์	C. Pathompatai, R. Kanawong and P. Taeprasartsit, "Region-Focus Training: Boosting Accuracy for Deep-Learning Image Segmentation," 2019 16th International Joint Conference on Computer Science and Software Engineering (JCSSE), Chonburi, Thailand, 2019, pp. 319-323, doi: 10.1109/JCSSE.2019.8864162. Pinyo Taeprasartsit, Chanok Pathompatai, Kasidit Jusomjai, Henky Wibowo, Jan Sebek, and Punit Prakash "A personalized approach for microwave ablation treatment planning fusing radiomics and bioheat transfer modeling", Proc. SPIE 11315, Medical Imaging 2020: Image-Guided Procedures, Robotic Interventions, and Modeling, 1131532 (16 March 2020); https://doi.org/10.1117/12.2549790

