



การแยกพื้นที่बाटแผลจากภาพถ่ายด้วยการเรียนรู้เชิงลึกและการขยายข้อมูลแบบต่าง ๆ



โดย
นายณัฏฐ์พัฒน์ พลบดี

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต

สาขาวิชาเทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญามหาบัณฑิต

ภาควิชาคอมพิวเตอร์

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

ปีการศึกษา 2561

ลิขสิทธิ์ของบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

การแยกพื้นที่ขาดแผลจากภาพถ่ายด้วยการเรียนรู้เชิงลึกและการขยายข้อมูลแบบต่าง ๆ



โดย
นายณัฏฐพัฒน์ พลบดี

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต

สาขาวิชาเทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญามหาบัณฑิต

ภาควิชาคอมพิวเตอร์

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

ปีการศึกษา 2561

ลิขสิทธิ์ของบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

WOUND-REGION SEGMENTATION FROM IMAGE BY USING DEEP LEARNING
AND VARIOUS DATA AUGMENTATION METHODS



By
MR. Nanthipath PHOLBERDEE

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 2018
Copyright of Graduate School, Silpakorn University

หัวข้อ	การแยกพื้นที่बाटแผลจากภาพถ่ายด้วยการเรียนรู้เชิงลึกและการขยายข้อมูลแบบต่าง ๆ
โดย	นันทิพัฒน์ พลบดี
สาขาวิชา	เทคโนโลยีสารสนเทศ แผนก ก แบบ ก 2 ระดับปริญญา มหาบัณฑิต
อาจารย์ที่ปรึกษาหลัก	ผู้ช่วยศาสตราจารย์ ดร. ภิญโญ แท้ประสาทสิทธิ์

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร ได้รับพิจารณาอนุมัติให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต

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

พิจารณาเห็นชอบโดย

..... ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร. นันทิ นิภาพันธ์)

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

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

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

59309205 : เทคโนโลยีสารสนเทศ แผน ก แบบ ก 2 ระดับปริญญาโท

คำสำคัญ : บาดแผลเรื้อรัง, การเรียนรู้เชิงลึก, การประมวลผลภาพ, ภาพบาดแผล, บาดแผล, การแบ่งส่วนเชิงความหมาย, การแบ่งแยกพื้นที่บาดแผล, การแบ่งแยกบาดแผล

นาย นันทิพัฒน์ พลบดี: การแยกพื้นที่บาดแผลจากภาพถ่ายด้วยการเรียนรู้เชิงลึกและการขยายข้อมูลแบบต่าง ๆ อาจารย์ที่ปรึกษาวิทยานิพนธ์ : ผู้ช่วยศาสตราจารย์ ดร. ภิญโญ แท้ประสาทสิทธิ์

การแบ่งแยกพื้นที่บาดแผลเรื้อรังเป็นสิ่งจำเป็นสำหรับการประเมินและดูความก้าวหน้าในการฟื้นตัวของสภาพบาดแผล อย่างไรก็ตามความแม่นยำในการวัดขนาดบาดแผลขึ้นอยู่กับความชำนาญของผู้วัดขนาด กล่าวคือผลการวัดอาจเปลี่ยนไปมากเมื่อเปลี่ยนผู้วัดขนาด ทำให้เกิดเป็นความคลาดเคลื่อนและทำให้ประเมินความก้าวหน้าในการรักษาผิดพลาด จากปัญหาเหล่านี้จึงได้มีแนวคิดนำปัญญาประดิษฐ์ที่มีการเรียนรู้เชิงลึกสำหรับการแบ่งแยกเชิงความหมายมาแก้ไขปัญหที่เกิดขึ้น โดยที่ปัญญาประดิษฐ์จะทำหน้าที่แบ่งแยกภาพบาดแผลเพื่อให้ได้พื้นที่บาดแผลจริงออกมา แล้วนำพื้นที่บาดแผลนั้นไปเข้าสู่กระบวนการวัดและประเมินสภาพต่อไปในอนาคต แต่น่าเสียดายที่การแบ่งส่วนเชิงความหมายในงานก่อนหน้าให้ไม่ได้ผลลัพธ์ที่น่าพอใจสำหรับงานด้านการแบ่งแยกภาพบาดแผล ถึงแม้ว่าจะมีชุดข้อมูลการฝึกที่มีขนาดใหญ่ก็ตาม

งานวิจัยนี้จึงคิดทบทวนเกี่ยวกับความท้าทายและมุ่งหวังที่จะไม่เพียงแต่ปรับปรุงความแม่นยำในการแบ่งแยกพื้นที่ภาพบาดแผลแต่ยังศึกษาผลกระทบของประเภทของเนื้อเยื่อบาดแผลและสีที่มีผลต่อความแม่นยำของการวัดพื้นที่บาดแผล นำไปสู่สมมติฐานที่ว่าสีและประเภทของเนื้อเยื่อบาดแผลส่งผลกระทบต่อการแบ่งส่วนบาดแผลอย่างมีนัยสำคัญ เพื่อตอบสนองสมมติฐานที่เกิดขึ้นในการทดลองทางผู้วิจัยได้มีการเพิ่มความหลากหลายของสีด้วยการขยายข้อมูลด้วยโมเดลรูปแบบสีจำนวน 6 รูปแบบ และนอกจากนี้ยังมีการแบ่งแยกประเภทเนื้อเยื่อบาดแผลออกเป็น 3 ประเภทได้แก่เนื้อเยื่อแผลเนื้อแดง (granulation) , หนอง (slough) และเนื้อเยื่อแผลเนื้อตาย (necrosis) ทั้งในชุดข้อมูลการฝึกและชุดข้อมูลการทดสอบ

จากผลการทดลองแสดงให้เห็นว่าประเภทของเนื้อเยื่อบาดแผลไม่ส่งผลกระทบต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ และเนื้อเยื่อประเภทหนองเป็นเนื้อเยื่อที่ทำหน้าที่ในการแบ่งแยกพื้นที่ของภาพบาดแผลส่วนเนื้อเยื่อประเภทเนื้อแดงเป็นเนื้อเยื่อที่ทำหน้าที่น้อยที่สุด นอกจากนี้การเพิ่มความหลากหลายของสีของภาพแผลช่วยเพิ่มความแม่นยำการแบ่งแยกพื้นที่พื้นที่บาดแผลได้ ทำให้กล่าวได้ว่าสีส่งผลกระทบต่อการแบ่งส่วนบาดแผลอย่างมีนัยสำคัญ และในงานวิจัยนี้มีความ

แผนยการแบ่งแยกพื้นที่บาดแผลใกล้เคียงวิธีการแบบบก่อนหน้าถึงแม้ว่าจะมีชุดข้อมูลการฝึกขนาด
เล็กก็ตาม



59309205 : Major (INFORMATION TECHNOLOGY)

Keyword : chronic wound, deep learning, image processing, wound, semantic segmentation, wound image, chronic wound segmentation

MR. NANTHIPATH PHOLBERDEE : WOUND-REGION SEGMENTATION FROM IMAGE BY USING DEEP LEARNING AND VARIOUS DATA AUGMENTATION METHODS
THESIS ADVISOR : ASSISTANT PROFESSOR DOCTOR PINYO TAEPRASARTSIIT

Chronic wound segmentation is an essential task for evaluating wound and its healing progress. However, accuracy of wound size measurement depends on expertise of the measurer. The measurement result may be significantly different among measurers, and thus, healing progress reports. To solve this issue, deep learning for semantic segmentation is introduced for wound-region segmentation in an image. We can, then, calculate the segmented wound region into its corresponding true size and evaluate the healing progress of the patient. Unfortunately, semantic segmentation in prior work did not produce satisfactory outputs in wound image segmentation, even with a large training dataset.

This work, therefore, rethinks about the challenge and aims at not only improving segmentation accuracy, but also studying the impact of wound tissue types and color on accuracy, these lead to two hypotheses driving this research: (1) a type of wound tissues plays an important role in segmentation accuracy and (2) utilization of better color data can significantly improve the accuracy. To investigate the first hypothesis, multiple neural network models were trained according to wound tissue types: granulation, slough, necrosis and three fissure types combined. For the second hypothesis, color augmentation was utilised during model training and accuracy of models trained with color augmentation was compared with those of models without color augmentation.

The experiments showed that types of wound did not significantly affect accuracy of wound segmentation and indicated that slough was the most challenging tissue in this task, while granulation was the least challenging one. Also, properly increasing color variety of wound images by color augmentation greatly improved

segmentation accuracy. Therefore, according to the experiments, colors play an important roles in wound segmentation performance. The accuracy we archived was close to prior work, even though this method employed much smaller training set.




กิตติกรรมประกาศ

งานวิทยานิพนธ์นี้สำเร็จลุล่วงได้ด้วยความอนุเคราะห์จาก อ.ดร. ภิญโญ แท้ประสาทสิทธิ์ อาจารย์ที่ปรึกษางานวิทยานิพนธ์ ท่านได้ให้ความรู้ คำปรึกษา ช่วยเหลือให้กำลังใจชี้แนวทางแก้ไขส่วนที่บกพร่องขอกราบพระคุณอย่างสูง

ผู้วิจัยขอกราบขอบพระคุณบุพการี และคณะวิทยาศาสตร์ สาขาเทคโนโลยีสารสนเทศ ที่มอบโอกาสในการศึกษาจนประสบความสำเร็จ รวมไปถึงสำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.) ที่มอบทุนสนับสนุนงานวิทยานิพนธ์นี้ในโครงการที่ชื่อว่า "โครงการพัฒนาศักยภาพบุคลากร STEM (Science, Technology, Engineering, Mathematics) เพื่อการวิจัยและพัฒนาสำหรับภาคอุตสาหกรรม : STEM Workforce ประจำปี 2560) " รหัสโครงการ #SCA-C0-2560-5202-TH

นนทิพัฒน์ พลบดี



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	ฉ
กิตติกรรมประกาศ.....	ช
สารบัญ.....	ฉ
สารบัญภาพ.....	1
สารบัญตาราง.....	3
บทที่ 1 บทนำ.....	5
1.1 ที่มาและความสำคัญ.....	5
1.2 วัตถุประสงค์ของงานวิจัย.....	8
1.3 ประโยชน์ที่คาดว่าจะได้รับ.....	8
1.4 โครงร่างหัวข้อวิทยานิพนธ์.....	8
บทที่ 2 งานวิจัยที่เกี่ยวข้อง.....	9
2.1 Automated Tissue Classification Framework for Reproducible Chronic Wound Assessment.....	9
2.1.1 Selecting of Wound Image and Preprocessing.....	9
2.1.2 Color Space Conversion from RGB to HIS.....	9
2.1.3 Wound Area Segmentation Using Fuzzy Divergence Based Thresholding	10
2.1.4 Feature Extraction for Tissue Subclassification.....	11
2.1.5 Statistical Learning Schemes	11
2.1.6 ผลลัพธ์ (Result)	12
2.2 A Unified Framework for Automatic Wound Segmentation and Analysis with Deep Convolutional Neural Networks.....	14

2.2.1 Wound Segmentation and Surface Area Estimation.....	15
2.2.2 Wound Infection Detection.....	16
2.2.3 Healing Infection Detection	16
2.2.4 conclusion	17
2.3 A Framework of Wound Segmentation Based on Deep Convolutional Networks	
.....	18
2.3.1 Prepare Data	18
2.3.2 Method.....	21
2.3.3 Experiments.....	22
บทที่ 3 ทฤษฎีที่เกี่ยวข้อง.....	26
3.1 Data Preparation.....	26
3.1.1 Color RGB.....	26
3.1.2 Livewire Algorithm.....	27
3.1.3 Data Augmentation.....	28
3.2 Semantic Segmentation.....	30
3.2.1 การเรียนรู้เชิงลึก (Deep learning).....	30
3.2.2 สถาปัตยกรรม U-net.....	30
3.3 Evaluation	32
3.3.1 Confusion Matrix	32
3.3.2 Intersection over Union (IoU)	33
3.3.3 Dice Similarity Coefficient.....	33
3.3.4 Region Size Error	34
บทที่ 4 วิธีการดำเนินงานวิจัย.....	35
4.1 โครงสร้างระบบ	35

4.1.1 Hardware.....	35
4.1.2 Software.....	35
4.2 ขั้นตอนการทำงาน.....	36
4.2.1 การประมวลผลเบื้องต้น (Pre-processing).....	36
4.2.2 การเรียนรู้เชิงลึกของเครื่อง (Training model).....	42
4.2.2.1 การขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพ.....	44
4.2.2.2 การขยายข้อมูลด้วยการหมุนและกลับภาพอีก 7 ทิศทาง.....	45
4.2.3 การประมวลผลสุดท้าย (Post-processing).....	46
4.2.4 การประเมินผล (Evaluate).....	46
บทที่ 5 ผลการดำเนินงานวิจัย.....	47
5.1 การเรียนรู้เชิงลึกที่มีสีของภาพบาดแผลเป็นตัวแปร.....	47
5.1.1 การทดลองขยายภาพด้วยสีอีก 1 รูปแบบสี.....	48
5.1.2 การทดลองขยายภาพด้วยสีอีก 2 รูปแบบสี.....	49
5.1.3 การทดลองขยายภาพด้วยสีอีก 3 รูปแบบสี.....	50
5.1.4 การทดลองขยายภาพด้วยสีอีก 6 รูปแบบสี.....	51
5.1.5 การทดลองขยายภาพด้วยสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง.....	52
5.2 การเรียนรู้เชิงลึกโดยแบ่งแยกประเภทของภาพบาดแผลเรื้อรัง.....	53
5.2.1 การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทเนื้อแดง.....	57
5.2.1.1 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดง 159 ภาพ.....	58
5.2.1.2 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี.....	59
5.2.1.3 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายด้วยการหมุนและพลิกอีก 7 ทิศทาง.....	60
5.2.1.4 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง.....	62


5.2.2 การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทหนอง	63
5.2.2.1 ชุดข้อมูลการฝึกที่เป็นประเภทหนอง 142 ภาพ	63
5.2.2.2 ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี	65
5.2.2.3 ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายด้วยการหมุนและพลิกอีก 7 ทิศทาง	66
5.2.2.4 ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และ พลิกอีก 7 ทิศทาง	68
5.2.3 การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทเนื้อตาย	69
5.2.3.1 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตาย 97 ภาพ	69
5.2.3.2 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี	71
5.2.3.3 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายด้วยการหมุนและพลิกอีก 7 ทิศทาง	72
5.2.3.4 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง	74
บทที่ 6 สรุปผลการทดลองและการเสนอแนะ	76
6.1 สรุปผลการทดลอง	76
6.1.1 สรุปผลการทดลองที่ว่าสีมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ	76
6.1.2 สรุปผลการทดลองที่ว่าเนื้อเยื่อมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ ..	77
6.2 ข้อเสนอแนะ	78
รายการอ้างอิง	79
ประวัติผู้เขียน	82

สารบัญภาพ

หน้า

ภาพที่ 1.1	บาดแผลเนื้อแดง (Granulation).....	5
ภาพที่ 1.2	บาดแผลเนื้อตาย (Necrosis).....	6
ภาพที่ 1.3	บาดแผลหนอง (Slough).....	6
ภาพที่ 2.1	การเปลี่ยนแปลงสีของภาพ.....	10
ภาพที่ 2.2	บริเวณใกล้เคียงกับค่ารัศมีที่แตกต่างกัน (R) สำหรับการคำนวณ LBP	12
ภาพที่ 2.3	ภาพผลลัพธ์การแบ่งแยกภาพบาดแผลเรื้อรังโดยใช้ fuzzy divergence thresholding.....	12
ภาพที่ 2.4	โครงสร้างเครือข่ายประสาทเทียม.....	15
ภาพที่ 2.5	ความคืบหน้าของการรักษาของสองบาดแผล.....	16
ภาพที่ 2.6	ภาพตัวอย่างชุดข้อมูล.....	18
ภาพที่ 2.7	ภาพจากเครื่องมือ Watershed.....	19
ภาพที่ 2.8	สถาปัตยกรรมของ WoundSeg.....	20
ภาพที่ 2.9	Post-processing techniques.....	22
ภาพที่ 2.10	ภาพผลลัพธ์ของการทำนายภาพจาก Medetec.....	23
ภาพที่ 2.11	ภาพผลลัพธ์ของการทำนายภาพจากคลินิก.....	24
ภาพที่ 3.1	ภาพตัวอย่างบาดแผลจาก Medetec	26
ภาพที่ 3.2	ภาพรวมของโปรแกรม MultiMaker	27
ภาพที่ 3.3	ภาพการใช้งาน Livewire algorithm ในการแบ่งส่วนภาพของโปรแกรม MultiMaker.....	27
ภาพที่ 3.4	ภาพบาดแผลดั้งเดิม.....	28
ภาพที่ 3.5	ภาพการขยายข้อมูล ของ model s8 ไป ipad.....	28
ภาพที่ 3.6	ภาพการขยายข้อมูล ของ model motoC ไป s8.....	29
ภาพที่ 3.7	การขยายข้อมูลด้วยการหมุนภาพอีก 7 ทิศทาง โดยการหมุนและพลิก.....	29
ภาพที่ 3.8	สถาปัตยกรรมของ U-net.....	31

ภาพที่ 4.1 Flowchart ขั้นตอนการทำงาน	36
ภาพที่ 4.2 การย่อขนาดรูปภาพและเติมพื้นหลังด้วยสีขาวให้เต็มพื้นที่ขนาด 256 x 256 พิกเซล .	37
ภาพที่ 4.3 ภาพแยกแยะบริเวณขาดแผลกับพื้นหลัง	38
ภาพที่ 4.4 การย่อขนาดรูปภาพและเติมพื้นหลังด้วยสีดำให้เต็มพื้นที่ขนาด 256 x 256 พิกเซล ...	39
ภาพที่ 4.5 ตัวอย่างการดึงข้อมูล label ออกจากภาพแยกแยะบริเวณขาดแผลกับพื้นหลัง.....	40
ภาพที่ 4.6 ตัวอย่างการดึงข้อมูล features	41
ภาพที่ 4.7 ตัวอย่างพีเจอร์ไฟล์	41
ภาพที่ 4.8 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net.....	42
ภาพที่ 4.9 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ encoder ชั้นแรก.....	42
ภาพที่ 4.10 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ encoder ชั้นสุดท้าย.....	43
ภาพที่ 4.11 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ decoder ชั้นแรก.....	43
ภาพที่ 4.12 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ decoder ชั้นสุดท้าย.....	44
ภาพที่ 4.13 ภาพตัวอย่างวิธีการขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพ	45



สารบัญตาราง

หน้า

ตารางที่ 2.1 การแบ่งแยกประเภทฟีกเซลด้วยวิธีการ Bayesian learning.....	13
ตารางที่ 2.2 การแบ่งแยกประเภทฟีกเซลด้วยวิธีการ support vector machine (SVM).....	13
ตารางที่ 2.3 ประสิทธิภาพการประเมินผลของการแบ่งแยกประเภทฟีกเซล	14
ตารางที่ 2.4 การประเมินผลการแบ่งแยกพื้นที่.....	15
ตารางที่ 2.5 การประเมินการทำนายการติดเชื้อโดย model ทั้งหมดฟีกด้วยวิธีการของ SVM.....	16
ตารางที่ 2.6 ประสิทธิภาพของการประเมินความก้าวหน้าในการรักษา.....	17
ตารางที่ 2.7 ประสิทธิภาพของการทดลอง	24
ตารางที่ 2.8 การเปรียบเทียบประสิทธิภาพกับงานวิจัยอื่น ๆ	24
ตารางที่ 5.1 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีภาพชุดข้อมูลการฟีกจำนวน 292 ภาพ.....	47
ตารางที่ 5.2 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบพื้นฐานนั้นนั้นจะใช้การหมุนและ พลิกอีก 7 ทิศทาง ชุดข้อมูลการฟีกจำนวน 2,336 ภาพ	47
ตารางที่ 5.3 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 1 รูปแบบสี และมีชุดข้อมูล ทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้.....	48
ตารางที่ 5.4 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 2 รูปแบบสี และมีชุดข้อมูล ทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้.....	49
ตารางที่ 5.5 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 3 รูปแบบสี และมีชุดข้อมูล ทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้.....	50
ตารางที่ 5.6 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี และมีชุดข้อมูล ทดสอบเป็นชุดทดสอบประสิทธิภาพของการ.....	51
ตารางที่ 5.7 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และ พลิกอีก 7 ทิศทาง มีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้.....	52
ตารางที่ 5.8 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีภาพชุดข้อมูลการฟีก 292 ภาพ	54

ตารางที่ 5.9 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี โดยที่มีภาพชุดข้อมูลการฝึก 2,044 ภาพ.....	55
ตารางที่ 5.10 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง ชุดข้อมูลการฝึกจำนวน 2,336 ภาพ.....	56
ตารางที่ 5.11 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง ชุดข้อมูลการฝึกจำนวน 16,352 ภาพ.....	57
ตารางที่ 5.12 การเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดง 159 ภาพ.....	58
ตารางที่ 5.13 การเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี จำนวน 1,113 ภาพ.....	59
ตารางที่ 5.14 การเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง จำนวน 1,272 ภาพ.....	61
ตารางที่ 5.15 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง จำนวน 8,904 ภาพ.....	62
ตารางที่ 5.16 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนอง 142 ภาพ.....	64
ตารางที่ 5.17 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี จำนวน 994 ภาพ.....	65
ตารางที่ 5.18 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง จำนวน 1,136 ภาพ.....	67
ตารางที่ 5.19 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง จำนวน 7,952 ภาพ.....	68
ตารางที่ 5.20 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตาย 97 ภาพ.....	70
ตารางที่ 5.21 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี จำนวน 679 ภาพ.....	71
ตารางที่ 5.22 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง จำนวน 776 ภาพ.....	73
ตารางที่ 5.23 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง จำนวน 5,432 ภาพ.....	74

บทที่ 1 บทนำ

1.1 ที่มาและความสำคัญ

บาดแผลเรื้อรัง (Chronic Wound) หมายถึง บาดแผลที่ไม่สามารถรักษาหายได้ตามลำดับและทันเวลาภายในระยะเวลา 4-6 สัปดาห์ การรักษาตัวของแผลที่ล่าช้าอาจมีสาเหตุจากปัจจัยด้านผู้ป่วยหรือสิ่งแวดล้อม และเป็นปัญหาที่พบบ่อยในผู้สูงอายุ ผู้ป่วยโรคเบาหวาน ผู้ป่วยอัมพาตที่มีปัญหาเกี่ยวกับการเคลื่อนไหว ซึ่งบาดแผลเรื้อรังมักพบเป็นภาวะแทรกซ้อนในผู้ป่วยที่ต้องนอนโรงพยาบาล สาเหตุของการเกิดบาดแผลเรื้อรังมาจากการที่เนื้อเยื่อแผลมีเลือดมาเลี้ยงไม่เพียงพอ การกดทับหลอดเลือด หลอดเลือดอักเสบ หรือมีการอักเสบของเส้นประสาทรับความรู้สึกจึงทำให้แผลไม่ได้รับการดูแลอย่างถูกต้อง สาเหตุทั่วไปของการเกิดบาดแผลเรื้อรังแบ่งได้เป็นสี่ประเภทคือ บาดแผลเรื้อรังจากแผลโรคเบาหวาน (Diabetic ulcers) บาดแผลเรื้อรังจากแผลกดทับ (Pressure ulcers) และแผลเรื้อรังจากภาวะหลอดเลือดตีบ (Venous and arterial ulcers) และบาดแผลเรื้อรังจากบาดที่เกิดขึ้นกับคนชรา (Elderly ulcers) นอกจากนี้บาดแผลเรื้อรังแบ่งออกได้เป็น 3 ประเภทคือ บาดแผลเนื้อแดง (Granulation), บาดแผลหนอง (Slough), บาดแผลเนื้อตาย (Necrosis)



ภาพที่ 1.1 บาดแผลเนื้อแดง (Granulation)



ภาพที่ 1.2 บาดแผลเนื่อตาย (Necrosis)



ภาพที่ 1.3 บาดแผลหนอง (Slough)

จากภาพที่ 1.1 คือภาพบาดแผลเนื้อแดง (Granulation) เป็นเนื้อเยื่อที่ถูกสร้างขึ้นใหม่มีลักษณะเป็นสีแดงหรือชมพูเข้ม ซึ่งบาดแผลเนื้อแดงจะบ่งบอกถึงกระบวนการการฟื้นฟูของบาดแผล ภาพที่ 1.2 คือบาดแผลหนอง (Slough) เป็นเนื้อเยื่อที่มีลักษณะที่มีสีเหลืองที่ประกอบด้วยไฟบริน, หนอง และวัสดุโปรตีน ภาพที่ 1.3 คือบาดแผลเนื้อตาย (Necrosis) เป็นเนื้อเยื่อที่มีลักษณะที่มีดำ ซึ่งจะบ่งบอกถึงปริมาณเลือดในเนื้อเยื่อไปเลี้ยงไม่เพียงพอ อาจมีสาเหตุมาจากเส้นเลือดตีบหรือเส้นเลือดอุดตัน

บาดแผลเรื้อรังเป็นปัญหาที่ส่งผลกระทบต่อในหลายด้าน สำหรับผู้ป่วยบาดแผลเรื้อรังจะสร้างความเจ็บปวด ความบอบช้ำต่อสภาพร่างกายและจิตใจ ด้านเศรษฐกิจนั้นโรงพยาบาลต้องเสียค่าใช้จ่ายในการรักษาผู้ป่วยสูงขึ้นถึง 2 เท่า ผู้ป่วยต้องรักษาในโรงพยาบาลนานกว่าปกติ 3 – 5 เท่า ทำให้อัตราการครองเตียง (Bed Occupancy Rate) มีระยะเวลานานขึ้น นอกจากนี้ในด้านการพยาบาล การเกิดบาดแผลเรื้อรังในผู้ป่วยแสดงถึงคุณภาพการรักษายาบาลที่ไม่ได้มาตรฐาน และแผลกดทับเป็นหนึ่งในบาดแผลเรื้อรังที่ได้ถูกกำหนดให้เป็นตัวชี้วัดคุณภาพตัวหนึ่งของระบบการรับรองคุณภาพของการรักษาพยาบาล นอกจากนี้ การเกิดบาดแผลเรื้อรังทำให้ผู้ป่วยต้องเดินทางมายังสถานพยาบาลเพื่อตรวจรักษาเป็นระยะ สร้างความยากลำบากแก่ผู้ป่วยที่อาศัยในพื้นที่ห่างไกลจากสถานพยาบาล เช่น กรณีที่ผู้ป่วยเป็นผู้สูงอายุที่อาศัยในพื้นที่ห่างไกลและมีบาดแผลเรื้อรังที่บริเวณเท้า ในกรณีนี้เป็นไปไม่ได้เลยที่ผู้ป่วยจะสามารถเดินทางมารักษายังสถานพยาบาลได้ด้วยตนเอง

การที่ผู้ป่วยมักจะต้องเดินทางเข้าพบแพทย์บ่อยขึ้นอาจเกิดจากคุณภาพในการรักษาของแพทย์มีคุณภาพที่ต่ำกว่ามาตรฐาน ในปัจจุบันการประเมินบาดแผลเรื้อรังยังคงใช้เทคนิคการประเมินด้วยตัวแพทย์ เพื่อระบุและอธิบายรูปร่าง, พื้นผิว, ความลึก รวมไปถึงถึงลักษณะความรุนแรงทางชีววิทยาของเนื้อเยื่อผิวหนังในแต่ละชั้นของแผล หลังจากนั้นแพทย์จะเลือกยาในการรักษา ซึ่งเทคนิคที่กล่าวมานี้ยังขาดความแม่นยำต้องจึงต้องอาศัยแพทย์ผู้เชี่ยวชาญถึงจะสามารถประเมินบาดแผลได้อย่างแม่นยำมากขึ้น เมื่อรวมเข้ากับปัจจัยหลายอย่างส่งผลต่อการหายของแผลทำให้การคาดคะเนระยะเวลาหายของแผลก็ทำได้ยากขึ้นด้วย

วิธีการหนึ่งที่จะช่วยแก้ปัญหาดังกล่าวข้างต้นคือการสร้างตัวแบบการรู้จำชนิดเนื้อเยื่อแผลจะนำไปสู่ระบบสำหรับการตรวจวัดขนาดและประเมินสภาพแผล ทำให้ได้ข้อมูลสำหรับไปเทียบเคียงกับคู่มือการรักษาสากล ซึ่งระบุยาและวิธีการที่เหมาะสมกับแผลที่กำลังรักษาอยู่ได้โดยสะดวก งานในส่วนนี้จะช่วยให้แพทย์ที่ประสบการณ์ยังน้อยเลือกยาและวิธีการได้สอดคล้องกับมาตรฐานมากขึ้นและเป็นไปอย่างมีประสิทธิภาพ

1.2 วัตถุประสงค์ของงานวิจัย


ในปัจจุบันมีการสร้างตัวแบบการเรียนรู้เชิงลึก (Deep learning model) ที่รู้จักเนื้อเยื่อบาดแผลมากมายแต่ทว่ายังไม่มีแบบการเรียนรู้เชิงลึกใดมีความแม่นยำเพียงพอต่อการนำไปประยุกต์ใช้จริงกับการรักษาบาดแผล ทางผู้วิจัยจึงคิดหาสาเหตุของปัญหา [3] จนเกิดเป็นสมมติฐานที่ว่าสีและประเภทของเนื้อเยื่อบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ ดังนั้นในงานวิจัยนี้จึงมีวัตถุประสงค์ในการทดสอบสมมติฐานที่ว่าสีและประเภทของเนื้อเยื่อบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ ซึ่งทางผู้วิจัยจะดำเนินการทดลองโดยมีสีและประเภทของเนื้อเยื่อบาดแผลเป็นตัวแปรสำคัญในการทดลอง

1.3 ประโยชน์ที่คาดว่าจะได้รับ

สามารถแบ่งแยกพื้นที่บาดแผลเรื้อรังจากภาพบาดแผลได้ เพื่อนำไปสู่การคำนวณเพื่อหาขนาดพื้นที่บาดแผลและการแยกประเภทของเนื้อเยื่อบาดแผลได้ และเพื่อให้รู้ว่าสีและประเภทของเนื้อเยื่อบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

1.4 โครงร่างหัวข้อวิทยานิพนธ์

ลำดับข้องานวิจัยจะเป็นไปดังนี้คือ บทที่ 2 คืองานวิจัยที่เกี่ยวข้องที่เกี่ยวกับการแบ่งแยกพื้นที่บาดแผลโดยใช้เทคนิคการเรียนรู้ของเครื่อง (machine learning) บทที่ 3 คือทฤษฎีที่เกี่ยวข้อง



บทที่ 2 งานวิจัยที่เกี่ยวข้อง

2.1 Automated Tissue Classification Framework for Reproducible Chronic Wound Assessment

งานของ Rashmi Mukherjee และชาวคณะ (Mukherjee et al., 2014) มีเป้าหมายในการพัฒนาคอมพิวเตอร์ที่ช่วยให้สามารถแบ่งประเภทเนื้อเยื่อ (granulation, slough, tissue) ในการประเมินการรักษาบาดแผลเรื้อรัง ซึ่งประกอบไปด้วยวิธีการ image processing และ statistical machine learning โดยมีขั้นตอนการทำแบ่งออกเป็น 5 ขั้นตอน

2.1.1 Selecting of Wound Image and Preprocessing

ในการทดลองนี้ได้นำภาพบาดแผลมาจากรฐานข้อมูลภาพ Medetec (<http://www.medetec.co.uk>) ซึ่งมีบริเวณของเนื้อเยื่อแดง (granulation) 222 บริเวณ, หนอง (slough) 451 บริเวณ และเนื้อตาย (necrosis) 94 บริเวณ จากรูปบาดแผลภาพทั้งหมด 74 รูปภาพ

เนื่องด้วยการนำรูปภาพมาใช้ทำให้เกิดปัญหาสิ่งรบกวนตามมาจึงใช้ median filter ในการลบสิ่งรบกวนออกจากภาพ ซึ่งวิธีนี้เป็นตัวกรองแบบไม่เป็นเชิงเส้นที่นิยมใช้มากที่สุดโดยการเปลี่ยนค่าศูนย์กลางหน้าต่างโดยค่ามัธยฐานของศูนย์กลาง ในการใช้ตัวกรองค่ามัธยฐานโดยใช้โครงสร้างองค์ประกอบ (structural element window) 5×5 ถูกนำมาใช้กับ ถูกนำมาใช้กับช่อง RGB แต่ละช่องสำหรับภาพบาดแผล

2.1.2 Color Space Conversion from RGB to HIS


จากภาพที่นำมาจาก Medetec ได้ค่าสีของรูปภาพเป็นค่าสี RGB ซึ่งทำให้เกิดปัญหาการวินิจฉัยเนื่องจากความไม่สม่ำเสมอของสีในภาพแผล RGB นอกจากนี้องค์ประกอบ RGB มีความสัมพันธ์กันเป็นอย่างมากไม่เหมาะสมที่จะใช้ข้อมูลสีโดยตรง เพื่อแบ่งส่วนขอบแผลของแผล ค่าสี RGB ของภาพแผลจะเปลี่ยนเป็นค่าสี HIS (h: hue, s: saturation, i: intensity) เนื่องจากอยู่ใกล้กับที่มนุษย์มองเห็นสี ในความเป็นจริง H อธิบายสีบริสุทธิ์ที่ (สีส้ม, สีแดง) S ให้องศาที่สีบริสุทธิ์เจือจางด้วยแสงสีขาวและ I เป็นสีอันทัน (gray level) เพื่อหลีกเลี่ยงความขัดแย้งระหว่างการแบ่งส่วนของแผลจากผิวหนัง จึงเลือกส่วน S ของช่อง HSI ถูกเลือกไว้ที่นี้ซึ่งแสดงให้เห็นความแตกต่างที่ดีขึ้นในขอบเขตแผลดังแสดงในภาพที่ 2.1




(a)



(b)



(c)



(d)

ภาพที่ 2.1 การเปลี่ยนแปลงสีของภาพ

(<https://www.hindawi.com/journals/bmri/2014/851582/fig2>)

จากภาพที่ 2.1 ภาพ a และ b คือภาพดั้งเดิมที่มีค่าสีเป็น RGB ส่วนภาพ c และ d คือภาพที่ถูกเปลี่ยนค่าสีจาก RGB เป็น HSI โดยที่ภาพแสดงแค่ค่าของช่องสี S เท่านั้น

2.1.3 Wound Area Segmentation Using Fuzzy Divergence Based Thresholding

ความแม่นยำในการแบ่งส่วนมักจะลดลงเนื่องจากความทับซ้อนของความเข้มและความคลุมเครือของพิกเซลโดยเฉพาะที่บริเวณแผลและบริเวณที่ไม่ใช่แผล เพื่อลดความเข้มของพิกเซลซ้อนกันจึงพิจารณา fuzzy divergence เพื่อแบ่งแยกพื้นที่บาดแผลใน channel s ของรูปภาพบาดแผล นอกจากนี้ได้ใช้ลักษณะทางสัณฐานวิทยา (morphology) แบบ การกัดเซาะ (erosion) และ การขยาย (dilation) เพื่อให้ได้พื้นที่แผล (wound bed) จริงออกมาจากภาพรูปภาพบาดแผล หลังจากนั้นจะนำ RGB ของพื้นที่แผลที่ได้ไปสกัดต่อไป

2.1.4 Feature Extraction for Tissue Subclassification

เพื่อให้การประเมินผลที่ถูกต้องมากขึ้นต่อการแบ่งประเภทบาดแผลมีการคำนวณคุณสมบัติทางสีและเนื้อสัมผัสเชิงปริมาณที่นี้เนื่องจากคุณสมบัติเหล่านี้ให้ข้อมูลที่เป็นประโยชน์เกี่ยวกับคำอธิบายสีและโครงสร้างจุลภาคของเนื้อเยื่อ

คุณสมบัติทางสี (Color Features)


การวิเคราะห์ภาพบาดแผลเกี่ยวข้องกับข้อมูลสีสำหรับการประเมินผลทางคลินิก ทางคลินิกสีมีข้อมูลที่สำคัญเนื่องจากคุณสมบัติของแสงผ่าน / สะท้อนผ่านเนื้อเยื่อ ในมุมมองของนี้เราพยายามที่จะสกัดสีคุณลักษณะเชิงปริมาณเพื่อทำความเข้าใจบาดแผลในช่องว่างสีต่าง ๆ ในงานนี้มีค่าสีทั้งหมด 15 อัน ได้แก่ RGB, HIS, XYZ, Lab, Luv, LCH, HSV, HSL, YUV YIQ, CAT02, LMS, YCbCr, JPEG-YCbCr, YDdDr and YPbPr ซึ่งค่าสีแต่ละค่าสีสามองค์ประกอบทำให้จำนวนช่องสีทั้งหมดมี 45 ช่องสี และในการพิจารณาหาค่าปริมาณสีของเนื้อเยื่อได้โดยไม่ต้องคำนึงถึงพื้นที่ของบาดแผล

คุณสมบัติของพื้นผิว (Texture Features)

Local binary pattern (LBP) เป็นวิธีที่ง่ายและมีประสิทธิภาพสำหรับการวิเคราะห์เนื้อสัมผัสของภาพระดับสีเทา หลักการทำงานก็คือ LBP จะให้คำตอบ (labels) กับทุกพิกเซลของรูป โดยที่คำตอบนั้นนำมาจากค่า thresholding ของรอบ ๆ บริเวณของทุก ๆ พิกเซลซึ่งมีค่าเป็นเลขฐานสอง


2.1.5 Statistical Learning Schemes

Bayesian และ support vector machine (SVM) เป็นเทคนิคการเรียนรู้ที่สำคัญที่สุดในการศึกษาเนื้อเยื่อบาดแผล 3 ประเภท คือ granulation, slough, tissue โดยพิจารณาจากคุณสมบัติทางสีและคุณสมบัติของพื้นผิวอย่างมีนัยสำคัญทางสถิติ นอกจากนี้การคำนวณความถูกต้องและการตรวจสอบความถูกต้องทางสถิติโดยใช้ Kappa เพื่อหาความแม่นยำของการทำนายพิกเซลผลลัพธ์



ภาพที่ 2.2 บริเวณใกล้เคียงกับค่ารัศมีที่แตกต่างกัน (R) สำหรับการคำนวณ LBP
 (<https://www.hindawi.com/journals/bmri/2014/851582/fig4/>)

2.1.6 ผลลัพธ์ (Result)



ภาพที่ 2.3 ภาพผลลัพธ์การแบ่งแยกภาพบาดแผลเรื้อรังโดยใช้ fuzzy divergence thresholding
 (https://www.hindawi.com/journals/bmri/2014/851582/fig6)

จากภาพที่ 2.3 (a) คือภาพบาดแผลเรื้อรังดั้งเดิม (b) ภาพที่ถูกแปลงค่าสีจาก RGB ไปเป็น HIS แล้วดึงแค่ช่อง S มาใช้ (c) ภาพที่ถูกแบ่งแยกพื้นที่แล้ว (d) ภาพ ground truth ทำโดยผู้เชี่ยวชาญ (e) สัดส่วนพิกเซลในเนื้อเยื่อต่าง ๆ granulation (G), slough (S), and necrotic (N) และผลลัพธ์ถูกแบ่งออกเป็นสองส่วนตามเทคนิคการเรียนรู้ในการศึกษาเนื้อเยื่อ 3 ประเภท ดังในตารางที่ 2.1 ส่วนในตารางที่ 2.2 กับตารางที่ 2.3 จะแสดงประสิทธิภาพการทำนายผลของการแบ่งแยกประเภทพิกเซลของสอง

ตารางที่ 2.1 การแบ่งแยกประเภทพิกเซลด้วยวิธีการ Bayesian learning

Original	Predicted pixels			Tissue-wise accuracy (%)	Overall accuracy
	Granulation	Slough	Necrosis		
Granulation	192	21	9	86.48	84.15 %
Slough	67	353	31	78.27	
Necrosis	5	15	74	78.27	

ตารางที่ 2.2 การแบ่งแยกประเภทพิกเซลด้วยวิธีการ support vector machine (SVM)

SVM	Original	Predicted pixels		
		Granulation	Slough	Necrosis
Linear kernel	Granulation	184	35	3
	Slough	50	390	11
	Necrosis	14	34	46
2 nd order polynomial	Granulation	182	33	7
	Slough	38	400	13
	Necrosis	5	22	69
3 rd order polynomial	Granulation	195	23	4
	Slough	31	410	10
	Necrosis	3	16	75
RBF kernel	Granulation	184	32	6
	Slough	39	401	11
	Necrosis	4	20	70

ตารางที่ 2.3 ประสิทธิภาพการประเมินผลของการแบ่งแยกประเภทฟิกเซล

Statistical learning schemes	Tissue-wise accuracy (%)			Overall accuracy (%)	Kappa statistic
	Granulation	Slough	Necrosis		
Bayesian classifier	86.48	72.27	78.72	81.15	0.704
SVM with linear kernel	82.88	86.47	48.93	72.76	0.653
SVM with 2 nd polynomial kernel	81.98	88.69	73.40	81.35	0.718
SVM with 3 rd polynomial kernel	87.84	90.90	79.78	86.13	0.793
SVM with RBF kernel	82.88	88.91	74.46	80.08	0.697

จากตารางที่ 2.3 ทำให้เราพบว่าการเรียนรู้แบบ SVM with 3rd polynomial kernel มีความแม่นยำสูงที่สุดในการทำนายเนื้อเยื่อทั้งสามประเภท (granulation, slough, necrosis)


จากการทดลองที่ผ่านขณะนี้แพทย์อาจได้รับเครื่องมือคำนวณที่เชื่อถือได้และมีประสิทธิภาพเชื่อถือได้และมีประสิทธิภาพสำหรับการแบ่งส่วนและการวัดพื้นที่แผลช่วยในการประเมินการรักษาบาดแผลได้อย่างถูกต้องรวมทั้งการวัดมิติด้วยการระบุลักษณะของเนื้อเยื่อ ในอนาคตจะข้อมูลที่มีขนาดใหญ่กว่านี้ในการทดลองเพื่อทดสอบว่าผลลัพธ์มีความแตกต่างชุดข้อมูลนี้หรือเปล่า

2.2 A Unified Framework for Automatic Wound Segmentation and Analysis with Deep Convolutional Neural Networks

งานของ Changhan Wang และชาวคณะ (Wang et al., 2015) นำเสนอระบบอัตโนมัติการแบ่งแยกพื้นที่แผลและวิเคราะห์สภาพบาดแผลจากภาพบาดแผลด้วยวิธีการเรียนรู้เชิงลึก (Deep learning) ร่วมกับการเรียนรู้งานที่เกี่ยวข้องกับคุณลักษณะการมองเห็น ยิ่งไปกว่านั้นคุณลักษณะที่เรียนรู้จะนำไปวิเคราะห์ต่อไปอีกสองทาง การตรวจหาเชื้อและการทำนายความคืบหน้าการรักษา นี้คือความพยายามครั้งแรกในการคาดการณ์ในระยะยาวของความคืบหน้าการรักษาบาดแผลโดยทั่วไป ดังนั้นสามารถแบ่งการทดลองออกเป็น 3 ส่วนดังนี้

2.2.1 Wound Segmentation and Surface Area Estimation

ในการทดลองนี้เป็นการนำเสนอการแบ่งแยกพื้นที่ฐานบาดแผลด้วยวิธีการเรียนรู้เชิงลึก (Deep learning) เราจึงนำเสนอเครือข่ายประสาทเทียม (convolutional neural networks) แบบเข้ารหัส 5 ชั้น (5 encoding layers) ตามด้วยการถอดรหัส 4 ชั้น (decoding layers) และใช้ ReLU เป็นฟังก์ชัน nonlinearity สำหรับตัวเข้ารหัสและตัวถอดรหัส convolution ทั้งสองแบบ ดังภาพที่ 2.4



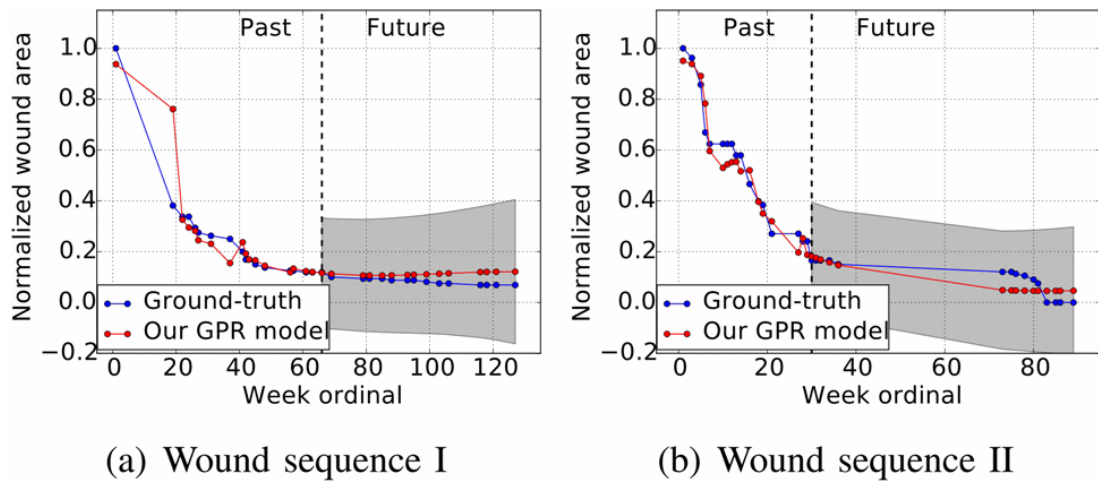
ภาพที่ 2.4 โครงสร้างเครือข่ายประสาทเทียม
(ieeexplore.ieee.org/document/7318881)

สำหรับการเรียนรู้พื้นฐานเราได้ใช้ support vector machine (SVM) และมีการเรียนรู้เชิงลึกซึ่งเราได้ใช้โครงข่ายประสาทเทียมที่มีโครงสร้างดังกล่าว ในการทดลองได้มีการเก็บข้อมูลโดยใช้ image patches ขนาด 9×9 pixels กับรูปภาพ RGB เพื่อนำไปทำชุดข้อมูลการฝึกที่มีจำนวน 500 รูป และชุดข้อมูลการทดสอบที่มีจำนวน 150 รูป ผลลัพธ์ของการทดลองในอยู่ตารางที่ 2.4

ตารางที่ 2.4 การประเมินผลการแบ่งแยกพื้นที่

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

จากตารางที่ 2.4 สังเกตค่า mean IoU ของทั้งการเรียนรู้ด้วย SVM และ ConvNet ถือว่าเป็นค่าที่น้อยทั้งคู่และยังไม่เพียงพอต่อการนำวิธีการนี้ไปใช้งานจริง



ภาพที่ 2.5 ความคืบหน้าของการรักษาของสองบาดแผล
(ieeexplore.ieee.org/document/7318881)

2.2.2 Wound Infection Detection

ในส่วนนี้เป็นการแบ่งประเภทของภาพบาดแผลว่าติดเชื้อหรือไม่ โดยถือว่าเนื้อเยื่อที่ติดเชื้อเป็นข้อมูลเชิงบวก (positive data) แล้วฝึกด้วย SVM เท่านั้น ส่วนชุดข้อมูลการฝึกมีจำนวน 2,700 ภาพ และชุดข้อมูลการทดสอบอยู่ 700 ภาพ นอกจากนี้ยังได้ใช้ cross validation จำนวน 5-fold ในการแบ่งแยกข้อมูลฝึกอีกด้วย

ตารางที่ 2.5 การประเมินการทำนายการติดเชื้อโดย model ทั้งหมดฝึกด้วยวิธีการของ SVM

	P	Accuracy	Recall	Precision	F-1 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 %

2.2.3 Healing Infection Detection

สำหรับการทดลองนี้เราใช้ชุดข้อมูลจำนวน 192 บาดแผล พร้อมกับบันทึกการรักษาบาดแผล ซึ่งเราได้แบ่งชุดข้อมูลเป็นสองส่วนคือ ชุดข้อมูลการฝึก 160 บาดแผล และชุดข้อมูลการ

ทดสอบอีก 32 บาทแผล โดยเริ่มต้นเราใช้ Gaussian process regression (GPR) กับครั้งแรกของบันทึกการรักษา และจากนั้นจะทำนายการรักษาในอนาคตจนกว่าบาทแผลจะมีขนาดเล็กถึง 0% - 10% ของแผลเดิม ซึ่งการวัดขนาดบาทแผลเราได้ใช้ mean absolute error (MAEtime) ทำการวัดขนาดบาทแผลตลอดเวลาการทำนายด้วยการรักษาด้วย

ในการเก็บรวมข้อมูลทั้งภาพและไม่ใช้ภาพ (บันทึกการรักษา) เราจึงได้สร้างเวกเตอร์คุณลักษณะโดยการรวม 1) บันทึกการรักษาของสัปดาห์ปัจจุบัน 2) บันทึกการรักษาของสัปดาห์ก่อนหน้า 3) พื้นที่บาทแผลก่อนหน้า (นำไปเทียบกับพื้นที่บาทแผลครั้งแรก) 4) คุณลักษณะของภาพ (เก็บคุณลักษณะของภาพโดย ConvNet และลดลงไป 10 มิติ ด้วย PCA) 5) อายุและเพศของผู้ป่วย

จากภาพที่ 2.5 คือความคืบหน้าของการรักษาของสองบาทแผล แกน y หมายถึงความสัมพันธ์ของขนาดบาทแผล ส่วนแกน x หมายถึงระยะเวลาเป็นหน่วยสัปดาห์ และเส้นโค้งสีแดงหมายถึงการทำนายการรักษา ส่วนเส้นสีน้ำเงินคือข้อมูลการรักษารจริง นอกจากนี้พื้นที่ที่ถูกแรเงาคือพื้นที่ที่มีความแม่นยำของการทำนาย 95% ขึ้นไป และ Gaussian process regression (GPR) สามารถเก็บรวมรวบรวมคุณลักษณะการรักษาทั้งหมดทั้งข้อมูลที่เป็นภาพและไม่ใช้ภาพเพื่อมาทำนายการรักษาในอนาคตได้ และในตารางที่ 2.6 เราได้ใช้ linear และ Polynomial (3-order) เป็นพื้นฐานเพื่อเปรียบเทียบการประเมินความก้าวหน้าในการรักษา กับ Gaussian process regression

ตารางที่ 2.6 ประสิทธิภาพของการประเมินความก้าวหน้าในการรักษา

	MAEtime (10%)	MAEtime (5%)	MAEtime (0%)	Avg. MAEarea
Linear	8.84	18.64	3.30	6.06%
Polynomial (3-order)	16.70	5.1	3.81	6.07%
GP	10.07	2.94	2.17	3.95%

2.2.4 conclusion

เราได้นำเสนอโครงสร้างแบบรวมสำหรับการแบ่งส่วนบาทแผลและการวิเคราะห์สภาพบาทแผลด้วยรูปแบบ ConvNet ที่เราเสนอไว้ระบบของเราสามารถแบ่งกลุ่มภาพบาทแผลในรูปแบบ end-to-end และยังสามารถนำ ConvNet ไปเรียนรู้เพื่อเป็นประโยชน์ต่องานอื่น ๆ เช่นการตรวจหาการติดเชื้อที่แผลและการทำนายความคืบหน้าในการรักษา โดยรวมแล้วระบบจะมี

ประสิทธิภาพเพียงพอที่จะประมวลผลภาพบาดแผลภายใน 5 วินาทีบนคอมพิวเตอร์แล็ปท็อปทั่วไป
สุดท้ายเราได้แสดงให้เห็นถึงความแข็งแกร่งของระบบของเราในการปฏิบัติงานทั้งสามอย่าง

2.3 A Framework of Wound Segmentation Based on Deep Convolutional Networks

งานของ Xiaohui Liu และชาวคณะ (Liu et al., 2017) ได้กล่าวถึงความท้าทายในการทำระบบแบ่งแยกพื้นที่บาดแผลแบบอัตโนมัติ เนื่องจากบาดแผลมีความหลากหลายลักษณะเกินไปและความซับซ้อนของลักษณะขอบแผล จึงทำให้เขาคิดเสนอโครงข่ายประสาทเทียมแบบลึก (Deep convolutional network) ชื่อ WoundSeg ที่สามารถระบุตำแหน่งและแบ่งแยกพื้นที่บาดแผลโดยอัตโนมัติเพื่อแก้ปัญหาความท้าทายเหล่านั้น

2.3.1 Prepare Data

เนื่องจากปัจจุบันยังไม่มีชุดข้อมูลเปิดแบบสาธารณะที่เหมาะสมสำหรับการทำการแบ่งแยกพื้นที่แบบอัตโนมัติ เขาจึงจำเป็นต้องสร้างข้อมูลขึ้นมาเองด้วยการแสวงหาความร่วมมือจากสถาบันทางการแพทย์และเก็บรวบรวมภาพบาดแผลจำนวนหนึ่งพร้อมกับนำภาพบาดแผลมาจาก Medetec (www.medetec.co.uk) ซึ่งการสร้างชุดข้อมูลจะมีรูปภาพที่แตกต่างกัน โดยมีจำนวนภาพทั้งหมด 950 ภาพ (ขนาด 600 x 800 พิกเซล)



ภาพที่ 2.6 ภาพตัวอย่างชุดข้อมูล

(<https://ieeexplore.ieee.org/document/8302184>)

จากภาพที่ 2.6 ภาพที่อยู่แถวบนคือภาพบาดแผลจาก Medetec Database และภาพที่อยู่แถวล่างคือภาพบาดแผลจากคลินิก

แน่นอนว่าชุดข้อมูลภาพบาดแผลที่ได้มา ยังไม่มีคำอธิบายประกอบสำหรับลักษณะบาดแผล แพทย์ที่คลินิกซึ่งทำการให้คำอธิบายประกอบกับชุดข้อมูลภาพบาดแผลให้ โดยเฉพาะอย่าง

ยิ่งบริเวณขอบบาดแผลที่มีความซับซ้อนอย่างมากต่อการให้คำอธิบายประกอบ ซึ่งเครื่องการให้คำอธิบายประกอบนั้นเป็นเครื่องมือแบบกึ่งอัตโนมัติที่ใช้อัลกอริทึม Watershed ที่ถูกออกแบบเพื่อให้ผู้ใช้สามารถทำเครื่องหมายบริเวณพื้นที่แผลได้ด้วยแท็บเล็ตปากกาหรือเมาส์




ภาพที่ 2.7 ภาพจากเครื่องมือ Watershed

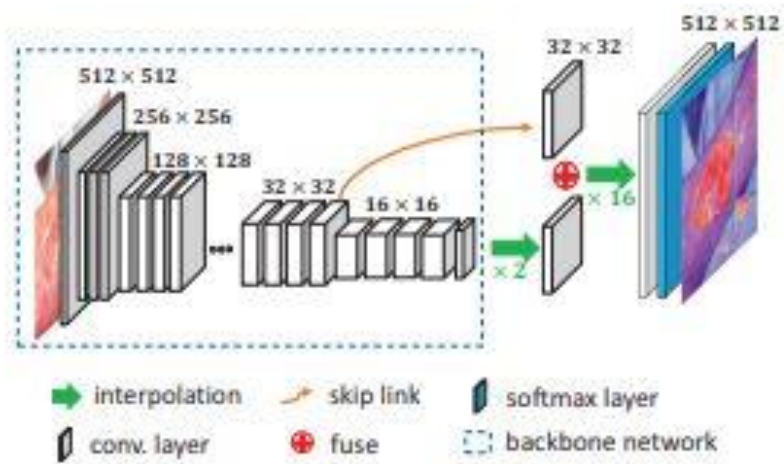
(<https://ieeexplore.ieee.org/document/8302184>)

จากภาพที่ 2.7 ภาพจากเครื่องมือ Watershed เพื่อช่วยให้คำอธิบายประกอบ โดยที่ภาพ (a) เส้นสีแดงคือการอธิบายบริเวณแผล และเส้นสีเขียวคือการอธิบายบริเวณภาพพื้นหลัง (b) คือการแบ่งแยกพื้นที่ของภาพด้วย Watershed อัลกอริทึม (c) เป็นคำอธิบายเฉพาะบริเวณพื้นที่แผล และนำคำอธิบายนี้ไปทำชุดข้อมูลการฝึกและทดสอบ






(a) Data Augmentation



(b) Segmentation Network




(c) Post Processing

ภาพที่ 2.8 สถาปัตยกรรมของ WoundSeg
 (<https://ieeexplore.ieee.org/document/8302184>)

2.3.2 Method

จากภาพที่ 2.8 ประกอบไปด้วย (a) Data Augmentation ด้วยการ พลิก, หมุน, ขยาย, การแปลง และการครอบแบบสุ่ม (b) Segmentation Network คือเครือข่ายประสาทเทียมในการ การแบ่งแยกพิกเซล (c) Post Processing หลังจากที่ได้พิกเซลจาก (b) และใช้การอนุมานเพื่อให้ได้ ภาพผลสุดท้าย

จากภาพที่ 2.8 แสดงถึงภาพรวมของการทำงานสามารถแบ่งออกเป็นได้ 3 ส่วนคือ การ ขยายข้อมูล (Data Augmentation), เครือข่ายการแบ่งส่วน (Segmentation Network) and การ ประมวลผลสุดท้าย (Post Processing) โดยที่ การขยายข้อมูล (Data Augmentation) จะใช้เฉพาะ ในขั้นตอนการฝึกเพื่อหลีกเลี่ยงการ overfitting และเราเพิ่มข้อมูลการฝึกอบรมด้วยการพลิก, หมุน, ขยาย, แปลง, และอื่น ๆ จากนั้นจะสุ่มตัดภาพให้เป็นขนาด 512×512 พิกเซล เครือข่ายการแบ่ง ส่วน (Segmentation Network) เป็นส่วนสำคัญในการแบ่งประเภทของพิกเซล ซึ่งพิกเซลจะถูก ออกเป็น 2 ประเภทคือ พิกเซลบริเวณแผล และพื้นหลัง นอกจากนี้ยังมีการเปลี่ยนโครงสร้างของ เครือข่ายประสาทเทียมหลายอย่างเพื่อให้ได้ผลลัพธ์ที่ดีที่สุด หลังจากนั้นการประมวลผลสุดท้าย (Post Processing) จะนำพิกเซลที่ถูกทำนาย (พิกเซลบริเวณแผล) แล้วไปคำนวณต่อด้วย morphological operations เนื่องจากจากแบ่งประเภทของพิกเซลอาจจะได้พิกเซลบริเวณแผล ออกมาหลาย ๆ บริเวณ ดังนั้นจะต้องตัดสินใจให้ได้ว่าบริเวณไหนคือบริเวณแผลของจริงกันแน่ โดย การนำการตรวจสอบผิวหนังมาตรวจเพื่อหาพิกเซลบริเวณแผลที่ซ้อนทับกับพิกเซลผิวหนังจะถือว่า พิกเซลตรงนั้นคือพิกเซลแผลจริงดังภาพที่ 2.9




ภาพที่ 2.9 Post-processing techniques

(<https://ieeexplore.ieee.org/document/8302184>)

จากภาพที่ 2.9 ขั้นตอนของ morphological operations อยู่ใน (d-f) การใช้การตรวจสอบพิกเซลผิวหนังและหาพิกเซลบริเวณแผลที่ซ้อนทับกันอยู่ใน (g-i)

2.3.3 Experiments

ประสาทเทียมมากมายที่ถูกสร้างมาเพื่อการแบ่งแยกพื้นที่บาดแผล แต่ทว่าเครือข่ายเหล่านั้นมีความอยากลำบากและราคาสูงสำหรับการติดตั้งเพื่อใช้กับโทรศัพท์เคลื่อนที่ ทางผู้วิจัยจึงได้เสนอ MobileNet ซึ่งมีเครือข่าย 28 ชั้นที่ซับซ้อนและเป็น pointwise convolutions อีกด้วย และสำหรับการทดลองนี้ได้เลือก MobileNet $\times 0.75$ ส่วนในขั้นสุดท้ายมีการทอดแทรกของชั้นที่ 32, 16, 8 ตามลำดับ



ภาพที่ 2.10 ภาพผลลัพธ์ของการทำนายภาพจาก Medetec
(<https://ieeexplore.ieee.org/document/8302184>)

จากภาพที่ 2.10 คือภาพผลลัพธ์ของการทำนายภาพจาก Medetec โดยที่ (a) ภาพชุดข้อมูลทดสอบ (b) ภาพ ground truth (c) การใช้ความน่าจะเป็นของ bwr-colormap ซึ่งค่าความน่าจะเป็นเป็น 0.5 คือสีขาว 0 คือสีดำ และ 1 คือสีแดง (d) ภาพผลลัพธ์การทำนายของเครือข่ายประสาทเทียมจากรูป a (e) ภาพขอบแผล (f) ภาพผลลัพธ์การทำนายของเครือข่ายประสาทเทียมที่ซ้อนทับกับภาพ ground truth สีดำคือ พิกเซลที่ทำนายถูกต้องของพื้นหลัง, สีแดงคือ พิกเซลที่ทำนายถูกต้องของพื้นที่แผล, สีเขียวคือ พิกเซลที่ทำนายว่าเป็นพื้นหลังแต่ภาพ ground truth บอกว่าเป็นพื้นที่แผล, สีฟ้าคือ พิกเซลที่ทำนายว่าเป็นพื้นที่แผลแต่ภาพ ground truth บอกว่าเป็นพื้นหลัง, สีขาว คือพิกเซลที่ไม่ตกไปอยู่ในกลุ่มไหนเลย

ตารางที่ 2.7 ประสิทธิภาพของการทดลอง

Backbone Network	Interpolating Scale	Accuracy (%)	mIoU (%)	DSC (%)
MobileNet x 0.75-fcn32	x32	98.01	83.80	91.19
MobileNet x 0.75-fcn16	x16	98.12	84.60	91.66
MobileNet x 0.75-fcn8	x8	97.70	81.70	89.92

สำหรับการทดลองได้มีการใช้ cross validation จำนวน 5 k-fold เพื่อแบ่งชุดข้อมูล การฝึก แล้วจากตารางที่ 2.7 พบว่าการใช้ MobileNet x 0.75-fcn16 มีประสิทธิภาพสูงสุด จึงนำ ผลของส่วนตรงนี้ไปเปรียบเทียบการงานวิจัยอื่น ๆ ในตารางที่ 2.8 จะสังเกตได้ว่า WoundSeg ยัง ประสิทธิภาพที่สูงสุด



ภาพที่ 2.11 ภาพผลลัพธ์ของการทำนายภาพจากคลินิก
(<https://ieeexplore.ieee.org/document/8302184>)

ตารางที่ 2.8 การเปรียบเทียบประสิทธิภาพกับงานวิจัยอื่น ๆ

Related work	Number of images	Approaches	Accuracy (%)	Sensitivity (%)	Precision (%)	mIoU (%)	DSC (%)
Shih et al.	112 (112)*	Adaptive thresholding	93.80	-	-	-	-
Kolesnik et al.	73 (23)	SVM	94.20	-	-	-	-
Yadav et al.	77 (77)	Fuzzy c-means	75.23	86.45	86.78	-	-
Dhane et al.	105 (105)	Spectral clustering	86.73	89.54	91.80	-	-
Dhane et al.	70 (70)	Fuzzy spectral clustering	91.50	-	87.30	79.0	86.70
Wang et al.	650 (150)	Deep CNN	95.00	-	-	47.30	-
WoundSeg	950 (190)	Deep CNN	98.18	90.58	93.31	85.06	91.93

*เลขที่อยู่ในวงเล็บหมายถึงจำนวนของชุดข้อมูลการทดสอบ

จากการเปรียบเทียบต่าง ๆ และประสิทธิภาพของ WoundSeg ถือได้ว่ามีแนวโน้มที่จะสามารถทำงานทดแทนการวัดด้วยตัวแพทย์เองได้ และยังเป็นภาพที่กำกวมสำหรับบาดแผลหรือขอบบาดแผลจะยังเป็นประโยชน์ต่อผู้ป่วยและแพทย์เอง

บทที่ 3 ทฤษฎีที่เกี่ยวข้อง

3.1 Data Preparation

ในปัจจุบันยังไม่มีข้อมูลสาธารณะที่เหมาะสมสำหรับการฝึกเครือข่ายประสาทเทียมเพื่อแบ่งแยกพื้นที่บาดแผล ทางผู้วิจัยจึงหลีกเลี่ยงไม่ได้ที่จะต้องดำเนินการสร้างข้อมูลขึ้นมาเอง โดยผู้วิจัยได้นำข้อมูลภาพบาดแผลมาจาก Medetec และทำดำเนินการเตรียมข้อมูลตามวิธีดังต่อไปนี้ (ผู้วิจัยได้แบ่งจำนวนชุดข้อมูลออกเป็น 2 ส่วนคือ ชุดข้อมูลการฝึก และชุดข้อมูลการทดสอบ)

3.1.1 Color RGB



ภาพที่ 3.1 ภาพตัวอย่างบาดแผลจาก Medetec

จากชุดข้อมูลที่ได้มาเป็นภาพบาดแผลขนาดต่าง ๆ ดังภาพที่ 3.1 โดยที่ภาพทุกภาพถูกถ่ายด้วยกล้องดิจิทัลทั่วไป ทำให้ภาพแต่ละภาพมีค่าสีเป็น RGB โดยที่ R หมายถึงช่วงค่าความเข้มสีของสีแดง G หมายถึงช่วงค่าความเข้มสีของสีเขียว B หมายถึงช่วงค่าความเข้มสีของสีฟ้า เมื่อนำค่าสีของ RGB มารวมกันทำให้เกิดค่าสีต่าง ๆ


ในวิธีการรักษาแบบดั้งเดิมแพทย์สามารถแบ่งแยกพื้นที่บาดแผลของผู้ป่วยได้ด้วยการสังเกตสีผิวของบริเวณบาดเนื้อเยื่อบาดแผล ทางผู้วิจัยจึงนำวิธีการแบ่งแยกพื้นที่บาดแผลแบบดั้งเดิมของแพทย์มาประยุกต์ใช้กับภาพบาดแผลที่มีค่าสี RGB เพื่อให้คอมพิวเตอร์สามารถแบ่งแยกพื้นที่บาดแผลได้

3.1.2 Livewire Algorithm

เป็นเทคนิคการแบ่งส่วนของภาพเพื่อช่วยให้ผู้ใช้สามารถเลือกพื้นที่ที่ต้องการจะดึงข้อมูล (ค่าสี RGB) ได้อย่างรวดเร็วและถูกต้องโดยใช้การคลิกเมาส์เพียงครั้งเดียว โดย Livewire algorithm ของงานวิจัยนี้ถูกพัฒนาอยู่ในโปรแกรมที่ชื่อ MultiMaker และพัฒนาโดยห้องแลปของภาควิชาคอมพิวเตอร์มหาวิทยาลัยศิลปากร



ภาพที่ 3.2 ภาพรวมของโปรแกรม MultiMaker



ภาพที่ 3.3 ภาพการใช้งาน Livewire algorithm ในการแบ่งส่วนของภาพของโปรแกรม MultiMaker

3.1.3 Data Augmentation

จากงานวิจัยของ Nanthipath และชาวคณะ (Pholberdee, Pathompatai, & Taeprasartsit, 2018) พบว่าค่าสี RGB ของภาพส่งผลกระทบต่อความแม่นยำในการแบ่งแยกพื้นที่บาดแผล ดังนั้นเพื่อเพิ่มประสิทธิภาพของการแบ่งแยกพื้นที่บาดแผลทางผู้วิจัยจึงคิดที่ขยายข้อมูลภาพ โดยการขยายข้อมูลนั้นแบ่งออกเป็น 2 วิธีคือ 1) การขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพ การขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีนี้ได้ดำเนินการตามงานวิจัยของ Chanachai และชาวคณะ (Puttaruka & Taeprasartsit, 2018) 2) การขยายข้อมูลด้วยการหมุนและกลับภาพอีก 7 ทิศทาง




ภาพที่ 3.4 ภาพบาดแผลดั้งเดิม



ภาพที่ 3.5 ภาพการขยายข้อมูล ของ model s8 ไป ipad



ภาพที่ 3.6 ภาพการขยายข้อมูล ของ model motoC ไป s8



ภาพที่ 3.7 การขยายข้อมูลด้วยการหมุนภาพอีก 7 ทิศทาง โดยการหมุนและพลิก

3.2 Semantic Segmentation

Semantic Segmentation คือการแบ่งแยกพื้นที่ภาพในระดับพิกเซล โดยในปัจจุบัน Semantic Segmentation มีเทคนิคที่นิยมสำหรับการแบ่งแยกพื้นที่ภาพก็คือ เครือข่ายประสาทเทียม (Convolution Neural Network) ซึ่งเป็นสถาปัตยกรรมของการเรียนรู้เชิงลึก (Deep learning) และเทคนิคนี้ถือว่าประสบความสำเร็จอย่างมากในงานด้านการแบ่งพื้นที่ของภาพ ทางผู้วิจัยจึงคิดนำเทคนิคมาประยุกต์ใช้กับภาพบาดแผลเพื่อทำการแบ่งแยกพื้นที่ภาพบาดแผล

3.2.1 การเรียนรู้เชิงลึก (Deep learning)

การเรียนรู้เชิงลึก (Deep learning) เป็นสาขาหนึ่งในการเรียนรู้ของเครื่อง (machine learning) พื้นฐานของการเรียนรู้เชิงลึกคือ อัลกอริทึมที่พยายามจะสร้างแบบจำลองเพื่อแทนความหมายของข้อมูลในระดับสูงโดยการสร้างสถาปัตยกรรมข้อมูลขึ้นมาที่ประกอบไปด้วยโครงสร้างย่อย ๆ หลายอัน และแต่ละอันนั้นได้มาจากการแปลงที่ไม่เป็นเชิงเส้น


การเรียนรู้เชิงลึก อาจมองได้ว่าเป็นวิธีการหนึ่งของการเรียนรู้ของเครื่องที่พยายามเรียนรู้วิธีการแทนข้อมูลอย่างมีประสิทธิภาพ ตัวอย่างเช่น รูปภาพภาพหนึ่ง สามารถแทนได้เป็นเวกเตอร์ของความสว่างต่อจุดพิกเซล หรือมองในระดับสูงขึ้นไปเป็นเซตของขอบของวัตถุต่าง ๆ หรือมองว่าเป็นพื้นที่ของรูปร่างใด ๆ ก็ได้ การแทนความหมายดังกล่าวจะทำให้การเรียนรู้ที่จะทำงานต่าง ๆ ทำได้ง่ายขึ้น ไม่ว่าจะเป็นการรู้จำใบหน้าหรือการรู้จำการแสดงออกทางสีหน้า การเรียนรู้เชิงลึกถือว่าเป็นวิธีการที่มีศักยภาพสูงในการจัดการกับพีเจอรส์สำหรับการเรียนรู้แบบไม่มีผู้สอนหรือการเรียนรู้แบบกึ่งมีผู้สอน

3.2.2 สถาปัตยกรรม U-net

U-net เป็นเครือข่ายประสาทเทียม (Convolution Neural Network) ที่พัฒนาเพื่อการแบ่งแยกพื้นที่ภาพทางการแพทย์ของภาควิชาวิทยาการคอมพิวเตอร์มหาวิทยาลัย Freiburg ในประเทศเยอรมัน ซึ่งเครือข่ายของ U-net เป็น fully convolution network และมีสถาปัตยกรรมที่ได้รับปรับปรุงและขยายเพื่อทำงานกับชุดข้อมูลการฝึกที่มีขนาดเล็กและการแบ่งแยกพื้นที่ที่แม่นยำขึ้น

สถาปัตยกรรมของ U-net เป็นสถาปัตยกรรมที่เป็นรูปตัวยูที่ประกอบไปด้วย convolution network ในแต่ละชั้นแล้วมี activation function เป็น ReLU และ max pooling ในการลดข้อมูลลง นอกจากนั้นสถาปัตยกรรมของ U-net ยังมีการสอดแทรกจากชั้นข้อมูลก่อนด้วย

ซึ่งในการสอดแทรกนี้ทำให้สถาปัตยกรรมของ U-net มีประสิทธิภาพที่สถาปัตยกรรมของดีกว่าสถาปัตยกรรมของอื่น ๆ



ภาพที่ 3.8 สถาปัตยกรรมของ U-net
(<https://lmb.informatik.uni-freiburg.de/people/ronneber/u-net>)

3.3 Evaluation

ในส่วนนี้จะจะเป็นเทคนิคทั่วไปในการประเมินประสิทธิภาพของการแบ่งแยกพื้นบาดแผล ซึ่งแบ่งการเทคนิคการประเมินออกเป็น 3 ส่วน คือ Confusion Matrix, Intersection over Union (IoU), Dice Similarity Index

3.3.1 Confusion Matrix

Confusion Matrix คือการประเมินผลของการทำนาย (หรือผลลัพธ์จากโปรแกรม) เปรียบเทียบกับผลลัพธ์จริง ๆ ที่ระบุโดยผู้เชี่ยวชาญ ("Confusion matrix,") ซึ่งมี attributes ดังนี้

True Positive (TP) คือ พิกเซลสิ่งที่โปรแกรมทำนายว่าจริง และผู้เชี่ยวชาญระบุว่ามันจริง

True Negative (TN) คือ พิกเซลสิ่งที่โปรแกรมทำนายว่าไม่จริง และผู้เชี่ยวชาญระบุว่ามันไม่จริง

False Positive (FP) คือ พิกเซลสิ่งที่โปรแกรมทำนายว่าจริง แต่ผู้เชี่ยวชาญระบุว่าไม่จริง

False Negative (FN) คือ พิกเซลสิ่งที่โปรแกรมทำนายว่าไม่จริง แต่ผู้เชี่ยวชาญระบุว่าจริง

จากนั้นจะทำ attributes เหล่านี้ไปหาค่า Precision (ค่าที่บอกว่าโปรแกรมทำนายว่าจริงถูกต้องเท่าไร) และ Recall (ค่าที่บอกว่าโปรแกรมทำนายได้ว่าจริง เป็นอัตราส่วนเท่าไรของจริงทั้งหมด)

$$\text{Precision}(TP, FP) = \frac{TP}{TP + FP} \quad (3.1)$$

$$\text{Recall}(TP, FN) = \frac{TP}{TP + FN} \quad (3.2)$$

3.3.2 Intersection over Union (IoU)

Intersection over Union (IoU) คือ เป็นสถิติที่ใช้เปรียบเทียบค่าความคล้ายคลึงกันของพิกเซลที่ทำนายและพิกเซลจริงที่ผู้เชี่ยวชาญระบุ ("Jaccard index,")

$$\text{IoU}(A, B) = \frac{A \cap B}{A \cup B} \quad (3.3)$$

โดยที่ A หมายถึงพิกเซลแผลที่ถูกทำนายด้วยคอมพิวเตอร์

โดยที่ B หมายถึงพิกเซลแผลจริงที่ผู้เชี่ยวชาญระบุ

3.3.3 Dice Similarity Coefficient

Dice Similarity Coefficient เป็นสถิติที่ใช้ในการเปรียบเทียบความคล้ายคลึงกันของสองตัวอย่าง ซึ่งสองตัวอย่างในที่นี้คือพิกเซลที่ทำนายและพิกเซลจริงที่ผู้เชี่ยวชาญระบุ ("Sørensen–Dice coefficient,")

$$\text{DSC}(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (3.4)$$

โดยที่ A หมายถึงพิกเซลแผลที่ถูกทำนายด้วยคอมพิวเตอร์

โดยที่ B หมายถึงพิกเซลพิกเซลแผลจริงที่ผู้เชี่ยวชาญระบุ


3.3.4 Region Size Error

Region Size Error (RSE) เป็นค่าความผิดพลาดของการทำนายขนาดบาดแผลด้วยคอมพิวเตอร์ ซึ่งจำเป็นอย่างมากสำหรับในงานวิจัยนี้ เนื่องจากว่าการ evaluation ของค่า IoU และ DSC เป็นการบ่งบอกถึงความแม่นยำในการทำนายขนาดและตำแหน่งของบาดแผลด้วยคอมพิวเตอร์ แต่ในการรักษาบาดแผลเรื้อรังผู้เชี่ยวชาญหรือแพทย์จะต้องทำการวัดขนาดบาดแผลในการรักษา เพื่อประเมินความรุนแรงของบาดแผลและรักษาตามอาการ ดังนั้นขนาดของบาดแผลมีความสำคัญกว่าตำแหน่งที่ปรากฏ ซึ่งค่า RSE เป็นค่าที่สนใจค่าของขนาดบาดแผลอย่างเดียวเท่านั้น จึงเป็นอีกตัวชี้วัดว่า model ไตบ้างมีประสิทธิภาพที่ดี

$$RSE(A, B) = \frac{|A - B|}{B} \quad (3.5)$$

โดยที่ A หมายถึงพิกเซลแผลที่ถูกทำนายด้วยคอมพิวเตอร์

โดยที่ B หมายถึงพิกเซลพิกเซลแผลจริงที่ผู้เชี่ยวชาญระบุ



บทที่ 4 วิธีการดำเนินงานวิจัย

บทนี้กล่าวถึงวิธีการดำเนินงานวิจัย และขั้นตอนการทำงานของ การตอบสนองมาตรฐานที่ว่าสี่และประเภทของเนื้อเยื่อบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

4.1 โครงสร้างระบบ

4.1.1 Hardware

- หน่วยประมวลผลกลาง Intel ® Core ™ i7-6850K 3.60 GHz
- หน่วยความจำหลัก 128 GB DDR4 speed 2400 MHz
- หน่วยความจำสำรอง 6 TB
- การ์ดแสดงผล NVIDIA GeForce GTX 1080 8 GB

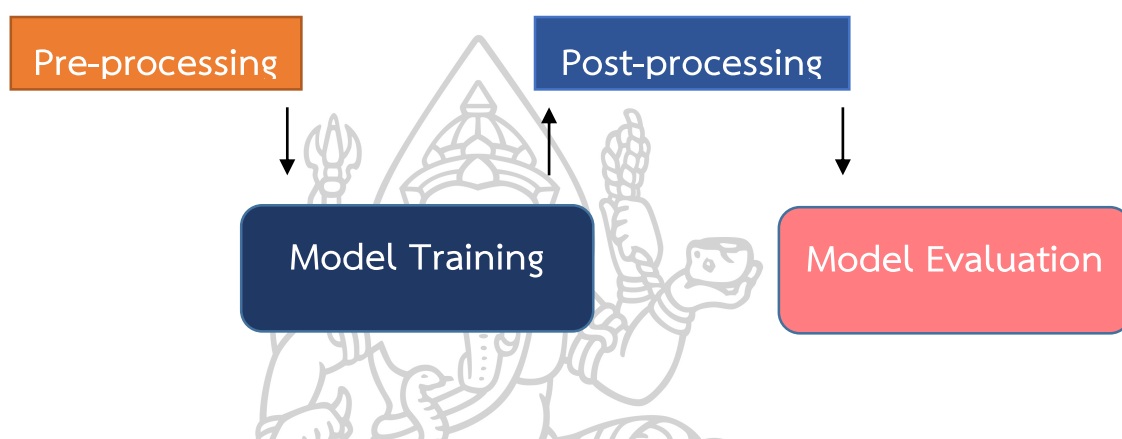
4.1.2 Software

- ระบบปฏิบัติการ Ubuntu 16.04.5
- โปรแกรม python พร้อมกับ framework ชื่อ CNTK ของ Microsoft
- โปรแกรม Docker

4.2 ขั้นตอนการทำงาน

ผู้วิจัยได้ออกแบบขั้นตอนการทำงานไว้ 4 ขั้นตอนดังรูปที่ 4.1 โดยมีรายละเอียดดังนี้

- a. ขั้นตอนที่ 1 การประมวลผลเบื้องต้น (Pre-processing)
- b. ขั้นตอนที่ 2 การเรียนรู้เชิงลึกของเครื่อง (Model Training)
- c. ขั้นตอนที่ 3 การประมวลผลสุดท้าย (Post-processing)
- d. ขั้นตอนที่ 4 การประเมินผล (Model Evaluation)



ภาพที่ 4.1 Flowchart ขั้นตอนการทำงาน

4.2.1 การประมวลผลเบื้องต้น (Pre-processing)

เนื่องจากในปัจจุบันยังไม่มีข้อมูลที่เหมาะสมสำหรับการนำไปใช้ในการเรียนรู้เชิงลึกของเครื่องในด้านการแบ่งแยกพื้นที่บาดแผลเรื้อรัง จากสาเหตุที่กล่าวมาทำให้การประมวลผลเบื้องต้น (Pre-processing) นี้ทางผู้วิจัยจะดำเนินการเตรียมข้อมูลและสร้างฟีเจอร์ไฟล์ที่ใช้สำหรับการเรียนรู้เชิงลึกของเครื่อง (Training model) และการประเมินผล (Evaluate)

ในการเตรียมข้อมูลทางผู้วิจัยได้นำข้อมูลภาพบาดแผลเรื้อรังมาจาก Medetec (www.medetec.co.uk) ซึ่งเป็นฐานข้อมูลภาพที่เปิดแบบสาธารณะ จำนวนภาพที่นำมาจาก Medetec มีจำนวนทั้งหมด 319 ภาพ จากนั้นจะทางผู้วิจัยนำภาพเหล่านั้นไปแบ่งข้อมูลออกเป็น 2 ชุดคือ 1. ชุดข้อมูลการฝึก (ข้อมูลสำหรับ Training model) จำนวน 292 ภาพ 2. ชุดข้อมูลการทดสอบ (ข้อมูลสำหรับ Evaluate) จำนวน 27 ภาพ

เนื่องด้วยงานวิจัยนี้เป็นงานวิจัยด้านการเรียนรู้เชิงลึกประเภทการแบ่งแยกพื้นที่ภาพในระดับพิกเซล (Semantic Segmentation) ฉะนั้นภาพทุกภาพที่จะใช้ในการเรียนรู้เชิงลึกต้องมีขนาดของรูปภาพที่เท่ากัน แต่ทว่าภาพจากฐานข้อมูล Medetec มีขนาดที่ไม่เท่ากันทางผู้วิจัยดำเนินการทำให้ภาพทั้งหมดมีขนาดเท่ากันที่ 256 x 256 พิกเซล โดยจะนำรูปภาพแต่ละรูปย่อลงไปให้เป็น 1:4 ส่วน แต่เนื่องจากขนาดภาพเป้าหมายมีขนาด 256 x 256 พิกเซล มีขนาดใหญ่กว่าภาพที่ย่อลงไปแล้ว ทำให้มีพื้นที่บางส่วนเป็นพื้นที่ว่าง และเราจะเติมพื้นที่ว่างนี้ด้วยสีขาว ดังรูปภาพที่ 4.2




ภาพที่ 4.2 การย่อขนาดรูปภาพและเติมพื้นที่ว่างด้วยสีขาวให้เต็มที่พื้นที่ขนาด 256 x 256 พิกเซล

เมื่อเตรียมข้อมูลภาพเสร็จแล้วทางผู้วิจัยจะนำข้อมูลภาพเหล่านั้นไปสร้างฟีเจอร์ไฟล์ที่ใช้สำหรับการเรียนรู้เชิงลึกของเครื่อง (Model Training) และการประเมินผล (Model Evaluation) โดยที่แต่ละฟีเจอร์ไฟล์จะประกอบไปด้วยข้อมูล 2 ส่วน คือ Label (คำตอบ) และ Features (คุณลักษณะสี)


Label (คำตอบ)

ก่อนที่จะดึงข้อมูล label จากไฟล์ภาพได้ทางผู้วิจัยจะนำภาพไปเข้าโปรแกรม MultiMaker เพื่อที่จะได้ภาพที่แยกแยะบริเวณบาดแผลกับพื้นหลัง (สีขาวคือบาดแผล, สีดำพื้นหลัง) ดังรูปที่ 4.3 เพราะว่าทางผู้วิจัยจะดึงข้อมูล label จากภาพแยกแยะบริเวณบาดแผลกับพื้นหลัง (ภาพ



ground tru


ภาพที่ 4.3 ภาพแยกแยะบริเวณบาดแผลกับพื้นหลัง



เมื่อได้ภาพที่แยกแยะบริเวณขาดแผลกับพื้นหลังก็จะทำให้ภาพมีขนาด 256 x 256 พิกเซล ด้วยวิธีคล้ายเดิมแต่เปลี่ยนการวางพื้นหลังให้เป็นสีดำแทน ดังรูปภาพที่ 4.4

4.2.2 การเรียนรู้เชิงลึกของเครื่อง (Training model)

ในขั้นตอนนี้จะเป็นขั้นตอนการเรียนรู้เชิงลึกของเครื่องโดยใช้โครงข่ายประสาทเทียมแบบ U-net ที่ประกอบไปด้วยการ encoder 4 ชั้น และ decoder 4 ชั้น ดังในภาพที่ 4.8



ภาพที่ 4.8 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net

โดยการทำงานจะเริ่มจากนำพีเจอาร์ไฟล์ (เฉพาะชุดข้อมูลการฝึกเท่านั้น) ที่เตรียมไว้ในขั้นตอน pre-processing มาเข้าสู่โครงสร้าง encoder ชั้นแรก ซึ่งประกอบไปด้วย convolution 2 ครั้งที่มีขนาด 3 x 3 จำนวน filter 64 และที่ activation function เป็น relu และต่อกด้วย max pooling ที่ strides เท่ากับ 2 x 2 เพื่อลดขนาดภาพให้เล็กลงครึ่งหนึ่งเสมอ ดังภาพที่ 4.9

```
conv1 = Convolution((3,3), 64,
                    init=glorot_uniform(),
                    activation=relu,
                    pad=True)(input/255)
conv1 = Convolution((3,3), 64,
                    init=glorot_uniform(),
                    activation=relu,
                    pad=True)(conv1)
pool1 = MaxPooling((2,2),
                  strides=(2,2))(conv1)
```

ภาพที่ 4.9 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ encoder ชั้นแรก

การ encoder ในทุกชั้นจะประกอบไปด้วย convolution 2 ทิ้งตัว กับ max pooling จนถึงชั้นสุดท้ายที่จะประกอบไปด้วยแค่ convolution 2 ตัวเท่านั้น กล่าวคือไม่มี max pooling ประกอบอยู่ใน encoder ชั้นสุดท้ายนั่นเอง และจาก encoder แต่ละชั้นที่กล่าวมาจะทำให้ขนาด จาก 256×256 พิกเซล ลดลงเหลือ 32×32 พิกเซล

```
conv4 = Convolution(3,3), 512,
                    init=glorot_uniform(),
                    activation=relu,
                    pad=True)(pool3)
conv4 = Convolution(3,3), 512,
                    init=glorot_uniform(),
                    activation=relu,
                    pad=True)(conv4)
```

ภาพที่ 4.10 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ encoder ชั้นสุดท้าย

ในส่วนของ decoder นั้นจะมีทั้งหมด 3 ชั้น ซึ่งในแต่ละชั้นจะประกอบไปด้วยการ upsampling จากข้อมูลใน encoder ก่อนหน้าและจากนั้นจะมีด้วย convolution 2 ครั้งที่มีขนาด 3×3 จำนวน filter 64 และที่ activation function เป็น relu แบบนี้ในทุกชั้นของ decoder (decoder ชั้นแรกจะดึงข้อมูลของ encoder ชั้น 3, decoder ชั้น 3 จะดึงข้อมูลของ encoder ชั้น 2 และ decoder ชั้นสุดท้ายจะดึงข้อมูลของ encoder ชั้นแรก)

```
up5 = C.splice(UpSampling2D(conv4), conv3, axis=0)
conv5 = Convolution(3,3), 256,
                init=glorot_uniform(),
                activation=relu, pad=True)(up5)
conv5 = Convolution(3,3), 256,
                init=glorot_uniform(),
                activation=relu, pad=True)(conv5)
```

ภาพที่ 4.11 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ decoder ชั้นแรก


```

up7 = C.splice(UpSampling2D(conv6), conv1, axis=0)
conv7 = Convolution((3,3), 64,
                    init=glorot_uniform(),
                    activation=relu,
                    pad=True)(up7)
conv7 = Convolution((3,3), 64,
                    init=glorot_uniform(),
                    activation=relu,
                    pad=True)(conv7)

conv8 = Convolution((1,1), num_classes,
                    init=glorot_uniform(),
                    activation=sigmoid, pad=True)(conv7)

```

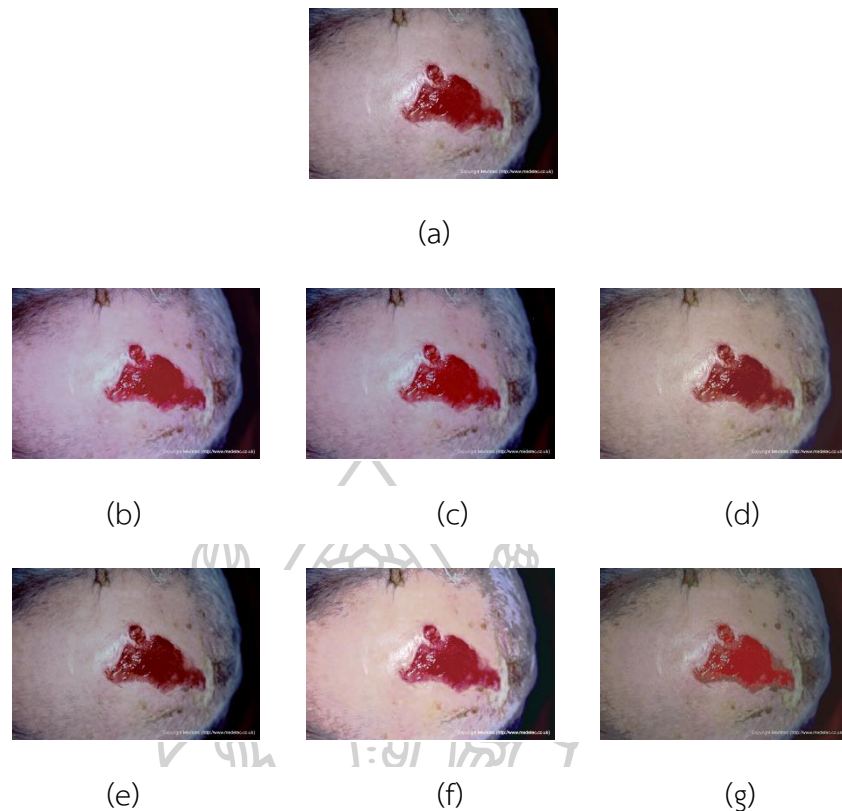
ภาพที่ 4.12 โครงสร้างของการเรียนรู้เชิงลึกแบบ U-net ที่ decoder ชั้นสุดท้าย

จากที่กล่าวมาทำให้รู้แล้วถึงโครงสร้างของการเรียนรู้เชิงลึก ต่อไปจะเป็นการพูดถึงวิธีการเรียนรู้เชิงลึกและพารามิเตอร์ที่ใช้ต่าง ๆ แต่ก่อนที่จะกล่าวถึงวิธีการเรียนรู้เชิงลึกและพารามิเตอร์ทางผู้วิจัยขอกล่าวถึงเรื่อง Data Augmentation (การขยายข้อมูล) ของภาพบาดแผลเรื้อรังก่อน

โดย Data Augmentation (การขยายข้อมูล) มีจุดประสงค์ในการเพิ่มจำนวนภาพบาดแผลเรื้อรังที่ใช้ในกระบวนการเรียนรู้เชิงลึก ซึ่งถือว่าเป็นเรื่องปรกติมาก ๆ สำหรับการขยายข้อมูลในงานวิจัยด้านภาพต่าง ๆ ฉะนั้นภาพบาดแผลที่ถูกขยายข้อมูลนั้นคือภาพบาดแผลของชุดข้อมูลการฝึกเท่านั้น ซึ่งการขยายข้อมูลออกเป็น 2 วิธีคือ 1) การขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพ (Puttaruka & Taepasartsit, 2018) 2) การขยายข้อมูลด้วยการหมุนและกลับภาพอีก 7 ทิศทาง

4.2.2.1 การขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพ

วิธีการขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพนั้นจะนำค่าสีของภาพบาดแผลต้นฉบับไปใช้งานกับ model color conversion เพื่อให้ได้ภาพบาดแผลใหม่ที่มีลักษณะคล้ายคลึงกับภาพบาดแผลเดิมแต่จะมีสีของภาพที่แตกต่างออกไปเล็กน้อย และเนื่องจาก model color conversion แต่ละตัวสามารถแปลงค่าสีได้ออกมาไม่เหมือนกัน เพื่อเพิ่มความหลากหลายของข้อมูล ในงานวิจัยนี้ทางผู้วิจัยจึงได้เลือก model color conversion มาเป็นจำนวน 6 รูปแบบสีด้วยกัน ได้แก่ iPadtoS8, iPadtoMotoC, S8toiPad, S8toMotoC, MotoCtoS8 และ MotoCtoiPad จากการขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพ จะทำให้ภาพเพิ่มจำนวนจากเดิมไปอีก 6 เท่า ของจำนวนภาพต้นฉบับ



ภาพที่ 4.13 ภาพตัวอย่างวิธีการขยายข้อมูลด้วยการเปลี่ยนแปลงค่าสีของภาพ

โดยที่ (a) ภาพต้นฉบับ (b) ภาพที่ผ่านการแปลงค่าสีของรูปแบบสี iPadtoMotoC (c) ภาพที่ผ่านการแปลงค่าสีของรูปแบบสี iPadtoS8 (d) ภาพที่ผ่านการแปลงค่าสีของรูปแบบสี MotoCtoiPad (e) ภาพที่ผ่านการแปลงค่าสีของรูปแบบสี S8toMotoC (f) ภาพที่ผ่านการแปลงค่าสีของรูปแบบสี MotoCtoS8 (g) ภาพที่ผ่านการแปลงค่าสีของรูปแบบสี S8toiPad

4.2.2.2 การขยายข้อมูลด้วยการหมุนและกลับภาพอีก 7 ทิศทาง

วิธีการขยายข้อมูลด้วยการหมุนและกลับภาพอีก 7 ทิศทางนั้นจะใช้ฟังก์ชัน `getRotationMatrix2D` ของ `open cv` กับภาษา `python` กับภาพขนาดผลต้นฉบับเพื่อได้ภาพขนาดผลใหม่ที่เหมือนเดิมแต่แตกต่างจากเดิมคือมีการหมุนและพลิกภาพอีก 7 ทิศทาง ซึ่งจากการขยายข้อมูลด้วยการหมุนและกลับภาพอีก 7 ทิศทาง จะทำให้ภาพเพิ่มจำนวนจากเดิมไปอีก 7 เท่าของจำนวนภาพต้นฉบับ

ต่อไปจะกล่าวถึงวิธีการของกระบวนการเรียนรู้เชิงลึกกว่าและพารามิเตอร์ต่าง ๆ โดยที่เริ่มจากการนำภาพขนาดผลจากชุดข้อมูลการฝึกที่ผ่านกระบวนการประมวลผลเบื้องต้น และการ

ขยายข้อมูลแบบต่าง ๆ มาแล้ว ไปแบ่งแยกข้อมูลด้วยวิธีการของ cross validation ซึ่งจะแบ่งรอบของการ cross กันออกเป็น 5 รอบ โดยในแต่ละรอบของ cross validation จะดำเนินการแบ่งแยกข้อมูลออกเป็นชุดข้อมูลการฝึกและชุดข้อมูลการทดสอบภายในชุดข้อมูลการฝึกที่นำมาอีกที จากนั้นจะนำชุดข้อมูลการฝึกที่ผ่าน cross validation มาแล้วไปเข้าสู่กระบวนการเรียนรู้เชิงลึก โดยที่แต่ละรอบจะมีชุดข้อมูลการฝึกและชุดข้อมูลการทดสอบที่ไม่เหมือนกัน แต่มีค่าพารามิเตอร์ที่เหมือนกันทุกรอบคือ ค่า optimizer ถูกตั้งค่าเป็นแบบ Adam ที่มีค่า learning rate อยู่ที่ 0.00001 และมีขนาดของ minibatch size เท่ากับ 8

เมื่อทำการเรียนรู้เชิงลึกเสร็จสิ้นแล้วผลลัพธ์ที่ได้จากการเรียนรู้เชิงลึกคือที่ตัวผ่านการฝึกฝน (trained model) แล้วหลังจากนั้นจะตัวแบบฝึกฝนทำนายภาพในขนาดตัวบรีเวณใดของภาพที่เป็นขนาดแผลบ้างหรือบริเวณใดเป็นขนาดแผล

4.2.3 การประมวลผลสุดท้าย (Post-processing)

หลังจากที่ได้ตัวแบบฝึกฝน (model) แล้วทางผู้วิจัยจะนำพีเจอร์ไฟล์ (ชุดข้อมูลการทดสอบ) ไปเข้าตัวแบบฝึกฝนเพื่อแบ่งแยกพื้นที่ขนาดแผล แต่ทว่าผลลัพธ์ที่ได้ออกมาจากตัวแบบฝึกฝนคือตัวเลขระหว่าง 0 – 1 ขนาด 256 x 256 ตัว ทำให้ผู้วิจัยตั้งค่า thresholding ที่ 0.5 เพื่อบ่งบอกว่าเลขตัวนั้นคือขนาดแผลหรือไม่ ซึ่งถ้าตัวเลขที่ได้นั้นมีค่ามากกว่าหรือเท่ากับ 0.5 จะถือว่าตรงนั้นเป็นขนาดแผล แต่ถ้าต่ำกว่าจะถือว่าไม่ใช่ขนาดแผล

4.2.4 การประเมินผล (Evaluate)

สุดท้ายนี้จะเป็นประเมินประสิทธิภาพของตัวแบบฝึกฝน โดยนำภาพขนาดแผลที่ได้จากการทำนายของคอมพิวเตอร์ (ตัวแบบฝึกฝน) ดั้งชั้นตอนที่กล่าวมาในข้างต้นกับภาพขนาดแผลที่ถูกระบุโดยผู้เชี่ยวชาญ (ภาพ ground truth) มาคำนวณหาค่าความแตกต่างของพิกเซลล์ต่าง ๆ ของภาพ เพื่อนำไปสู่กระบวนการประเมินประสิทธิภาพ ซึ่งวิธีการประเมินประสิทธิภาพมีอยู่ 4 วิธีคือ 1. Confusion matrix (สมการที่ 3.1 และ 3.2) 2. IoU (Intersection over Union สมการที่ 3.3) 3. DSC (Dice Similarity Coefficient สมการที่ 3.4) 4. RSE (Region Size Error สมการที่ 3.5) ดังที่กล่าวมาในบทที่ 3.3

บทที่ 5 ผลการดำเนินงานวิจัย

เพื่อตอบสนองมติฐานที่ว่าสีและประเภทของเนื้อเยื่อบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญทางผู้วิจัยได้แบ่งการทดลองนี้ออกเป็น 2 ส่วน ได้แก่การเรียนรู้เชิงลึกที่มีสีของภาพบาดแผลเป็นตัวแปรและการเรียนรู้เชิงลึกโดยแบ่งแยกประเภทของภาพบาดแผลเรื่องสี

5.1 การเรียนรู้เชิงลึกที่มีสีของภาพบาดแผลเป็นตัวแปร

ในการทดลองนี้ทางผู้วิจัยมีจุดประสงค์ในการพิสูจน์ว่าสีของภาพบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ จึงได้นำสีของภาพเนื้อเยื่อบาดแผลเป็นตัวแปรสำคัญในการทดลองแต่ก่อนหน้านั้นทางผู้วิจัยจึงได้สร้างการทดลองพื้นฐานเพื่อนำไปใช้ในการเปรียบเทียบกับทดลองอื่น ๆ ซึ่งในการทดลองพื้นฐานนั้นทางผู้วิจัยได้นำภาพชุดข้อมูลการฝึกจำนวน 292 ภาพ เข้าไปสู่กระบวนการเรียนรู้เชิงลึกและทำการทดสอบประสิทธิภาพ ดังในตาราง 5.1

ตารางที่ 5.1 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีภาพชุดข้อมูลการฝึกจำนวน 292 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบ	94.24	76.09	74.41	82.98	18.16

นอกจากนั้นในการทดลองพื้นฐานนี้ยังมีการขยายข้อมูลของรูปภาพบาดแผลด้วย ซึ่งการขยายข้อมูลแบบพื้นฐานนั้นจะใช้การหมุนและพลิกอีก 7 ทิศทาง ของภาพทำให้ภาพมีจำนวนเพิ่มขึ้นเป็น 2,336 ภาพ เข้าไปสู่กระบวนการเรียนรู้เชิงลึกและทำการทดสอบประสิทธิภาพ ดังในตาราง 5.2

ตารางที่ 5.2 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบพื้นฐานนั้นจะใช้การหมุนและพลิกอีก 7 ทิศทาง ชุดข้อมูลการฝึกจำนวน 2,336 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบ	94.97	82.82	79.11	87.48	14.87

จากตารางที่ 5.2 จะสังเกตได้ว่าการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทางมีประสิทธิภาพที่สูงกว่าการเรียนรู้เชิงลึกแบบพื้นฐานในตารางที่ 5.1 ซึ่งเป็นไปตามทฤษฎีที่ว่า การหมุนและพลิกของรูปภาพมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ (Pawara, Okafor, & Wiering, 2017)

เมื่อทางผู้วิจัยได้ผลลัพธ์ของการทดลองพื้นฐานแล้วจากนั้นทางผู้วิจัยจะเริ่มนำสู่กระบวนการตอบสนองมาตรฐานว่ามีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ ดังนั้นทางผู้วิจัยจึงนำภาพบาดแผลไปขยายข้อมูลด้วยสีของภาพ (Data Color Augmented) [4] ซึ่งการขยายข้อมูลภาพด้วยสีนั้นทางผู้วิจัยได้เลือกรูปแบบของสีมาอีก 6 รูปแบบ ได้แก่ iPadtoS8, iPadtoMotoC, S8toiPad, S8toMotoC, MotoCtoS8 และMotoCtoiPad ซึ่งทำให้ผู้วิจัยสามารถแบ่งการทดลองออกไปได้อีก 5 การทดลอง 1. การทดลองขยายภาพด้วยสีอีก 1 รูปแบบสี 2. การทดลองขยายภาพด้วยสีอีก 2 รูปแบบสี 3. การทดลองขยายภาพด้วยสีอีก 3 รูปแบบสี 4. การทดลองขยายภาพด้วยสีอีก 6 รูปแบบสี 5. การทดลองขยายภาพด้วยสีอีก 6 รูปแบบสีและขยายภาพด้วยการหมุนและพลิกอีก 7 ทิศทาง

5.1.1 การทดลองขยายภาพด้วยสีอีก 1 รูปแบบสี

ในการทดลองนี้ทางผู้วิจัยได้นำชุดข้อมูลการฝึกจำนวน 292 ภาพ ไปขยายข้อมูลด้วยรูปแบบสีเพิ่มอีก 1 รูปแบบสี ซึ่งจะทำให้จำนวนชุดข้อมูลการฝึกเพิ่มจำนวนเป็น 584 ภาพ โดยที่รูปแบบสีที่นำมาใช้มีทั้งหมด 3 รูปแบบ ได้แก่ iPadtoMotoc, MotoCtoiPad และ S8toMotoC แล้วเพื่อความเป็นมาตรฐานเดียวกันจะมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้เชิงลึก

ตารางที่ 5.3 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 1 รูปแบบสี และมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้

ชุดข้อมูลการฝึก	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
รูปแบบสี iPadtoMotoc	94.36	79.09	77.67	86.00	17.41
รูปแบบสี MotoCtoiPad	92.73	83.26	79.17	87.32	15.85
รูปแบบสี S8toMotoC	93.42	82.94	80.07	87.55	14.60

จากในตารางที่ 5.3 ทำให้รู้ว่าการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 1 รูปแบบสี ทุกรูปแบบสีมีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึกแบบพื้นฐานในตารางที่ 5.1 แต่มีเฉพาะรูปแบบสี S8toMotoC ที่มีประสิทธิภาพดีกว่าการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทางในตารางที่ 5.2 ด้วย

5.1.2 การทดลองขยายภาพด้วยสีอีก 2 รูปแบบสี

ในการทดลองนี้ทางผู้วิจัยได้นำชุดข้อมูลการฝึกจำนวน 292 ภาพ ไปขยายข้อมูลด้วยรูปแบบสีเพิ่มอีก 2 รูปแบบสี ซึ่งจะทำให้จำนวนชุดข้อมูลการฝึกเพิ่มจำนวนเป็น 876 ภาพ โดยที่รูปแบบสีที่นำมาใช้มีทั้งหมด 2 รูปแบบ ได้แก่ 1. iPadtoMotoc และ MotoCtoiPad 2. S8toMotoC และ MotoCtoS8แล้วเพื่อความเป็นมาตรฐานเดียวกันจะมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้เชิงลึก

ตารางที่ 5.4 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 2 รูปแบบสี และมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้

ชุดข้อมูลการฝึก	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
รูปแบบสีแรก iPadtoMotoc และ MotoCtoiPad	92.29	86.10	80.32	88.24	14.72
รูปแบบสีที่สอง S8toMotoC และ MotoCtoS8	94.93	83.62	80.41	87.65	14.30

ในตารางที่ 5.4 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 2 รูปแบบสีทั้งสองรูปแบบสีที่มีจำนวนชุดข้อมูลการฝึกเพียงแค่ 876 ภาพ มีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึก

แบบพื้นฐานในตารางที่ 5.1 และการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุน และพลิกอีก 7 ทิศทางที่มีจำนวนชุดข้อมูลการฝึกถึง 2,336 ภาพ ในตารางที่ 5.2

แล้วในการการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 2 รูปแบบสีทั้งสอง รูปแบบสียังมีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 1 รูปแบบสี ทุกรูปแบบสีอีกด้วย แต่ผลลัพธ์ไม่ได้แตกต่างกันมาก

5.1.3 การทดลองขยายภาพด้วยสีอีก 3 รูปแบบสี

ในการทดลองนี้ทางผู้วิจัยได้นำชุดข้อมูลการฝึกจำนวน 292 ภาพ ไปขยายข้อมูลด้วยรูปแบบสีเพิ่มอีก 3 รูปแบบสี ซึ่งจะทำให้จำนวนชุดข้อมูลการฝึกเพิ่มจำนวนเป็น 1,168 ภาพ โดยที่รูปแบบสีที่นำมาใช้มีทั้งหมด 2 รูปแบบ ได้แก่ 1. iPadtoMotoc, MotoCtoiPad และ S8toMotoC 2. S8toiPad, S8toMotoc และ MotoctoS8 แล้วเพื่อความเป็นมาตรฐานเดียวกันจะมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้เชิงลึก

ตารางที่ 5.5 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 3 รูปแบบสี และมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้

ชุดข้อมูลการฝึก	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
รูปแบบสีแรก iPadtoMotoc, MotoCtoiPad และ S8toMotoC	94.24	82.61	80.09	87.35	14.29
รูปแบบสีที่สอง S8toiPad, S8toMotoc และ MotoctoS8	94.97	84.81	80.90	88.30	14.50

ในตารางที่ 5.5 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 3 รูปแบบสีทั้งสองรูปแบบสีที่มีจำนวนชุดข้อมูลการฝึกเพียงแค่ 1,168 ภาพ มีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึก

แบบพื้นฐานในตารางที่ 5.1 และการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุน และพลิกอีก 7 ทิศทางที่มีจำนวนชุดข้อมูลการฝึกถึง 2,336 ภาพ ในตารางที่ 5.2

แล้วในการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 3 รูปแบบสีทั้งสองรูปแบบสียังมีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 1 รูปแบบสี ทุกรูปแบบสีในตารางที่ 5.3 และการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 2 รูปแบบสีทั้งสองรูปแบบสีในตารางที่ 5.4 อีกด้วย

5.1.4 การทดลองขยายภาพด้วยสีอีก 6 รูปแบบสี

ในการทดลองนี้ทางผู้วิจัยได้นำชุดข้อมูลการฝึกจำนวน 292 ภาพ ไปขยายข้อมูลด้วยรูปแบบสีเพิ่มอีก 6 รูปแบบสี ซึ่งจะทำให้จำนวนชุดข้อมูลการฝึกเพิ่มจำนวนเป็น 2,044 ได้แก่ โดยที่รูปแบบสีที่นำมาใช้ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 แล้วเพื่อความเป็นมาตรฐานเดียวกันจะมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้เชิงลึก

ตารางที่ 5.6 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี และมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการ

ชุดข้อมูลการฝึก	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
รูปแบบสี iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8	95.00	85.87	82.36	89.01	12.54

ในตารางที่ 5.6 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสีที่มีจำนวนชุดข้อมูลการฝึกเพียงแค่ 2,044 ภาพ มีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึกแบบพื้นฐานในตารางที่ 5.1 และการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทางที่มีจำนวนชุดข้อมูลการฝึกถึง 2,336 ภาพ ในตารางที่ 5.2

แล้วในการการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสียังมีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 1 รูปแบบสี ทุกรูปแบบสีในตารางที่ 5.3, การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 2 รูปแบบสีทั้งสองรูปแบบ

สีในตารางที่ 5.4 และการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 3 รูปแบบสีทั้งสองรูปแบบสีในตารางที่ 5.5 อีกด้วย

5.1.5 การทดลองขยายภาพด้วยสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง

ในการทดลองนี้ทางผู้วิจัยได้นำชุดข้อมูลการฝึกจำนวน 292 ภาพ ไปขยายข้อมูลด้วยรูปแบบสีเพิ่มอีก 6 รูปแบบสี ซึ่งจะทำให้จำนวนชุดข้อมูลการฝึกเพิ่มจำนวนเป็น 2,044 ได้แก่ โดยที่รูปแบบสีที่นำมาใช้ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 แล้วยังนำไปขยายข้อมูลต่อด้วยการหมุน และพลิกอีก 7 ทิศทาง ทำให้จำนวนเป็นข้อมูลเป็น 16,352 ภาพ และเพื่อความเป็นมาตรฐานเดียวกันจะมีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้เชิงลึก

ตารางที่ 5.7 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง มีชุดข้อมูลทดสอบเป็นชุดทดสอบประสิทธิภาพของการเรียนรู้

ชุดข้อมูลการฝึก	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
รูปแบบสี iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8	94.82	87.69	83.00	90.24	11.41

ในตารางที่ 5.7 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสีการหมุน และพลิกอีก 7 ทิศทาง มีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึกแบบพื้นฐานในตารางที่ 5.1 และการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง ในตารางที่ 5.2

แล้วในการการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง ยังมีประสิทธิภาพที่ดีกว่าการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 1 รูปแบบสีในตารางที่ 5.3, การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 2 รูปแบบสีทั้งสองรูปแบบสีในตารางที่ 5.4, การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 3 รูปแบบสีทั้งสองรูปแบบสีในตารางที่ 5.5 และการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสีในตารางที่ 5.6 อีกด้วย

5.2 การเรียนรู้เชิงลึกโดยแบ่งแยกประเภทของภาพบาดแผลเรื้อรัง

ในการทดลองนี้ทางผู้วิจัยมีจุดประสงค์ในการพิสูจน์ว่าเนื้อเยื่อของภาพบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ ทางผู้วิจัยได้นำชุดข้อมูลการฝึกแบ่งออกเป็น 3 ประเภท ได้แก่ 1. ประเภทบาดแผล เนื้อแดง (มีจำนวน 159 ภาพ) 2. ประเภทบาดแผลหนอง (มีจำนวน 142 ภาพ) และ ประเภทบาดแผลเนื้อตาย (มีจำนวน 97 ภาพ) โดยที่แบ่งประเภทบาดแผลตามสภาพบาดแผลภายในภาพบาดแผล ในกรณีที่ในภาพบาดแผลมีบาดแผลที่มากกว่าหนึ่งประเภททางผู้วิจัยก็จะถือว่าภาพนั้นมีบาดแผลมากกว่าหนึ่งประเภท ทำให้ได้ว่าภาพบาดแผลหนึ่งภาพอาจจะเข้าไปอยู่ในประเภทบาดแผลทั้งสามบาดแผลเลยก็เป็นได้ และในทางทำนองเดียวกับชุดข้อมูลการทดสอบก็จะถูกแบ่งออกเป็น 3 ประเภท ได้แก่ 1. ประเภทบาดแผลเนื้อแดง (มีจำนวน 10 ภาพ) 2. ประเภทบาดแผลหนอง (มีจำนวน 10ภาพ) และ ประเภทบาดแผลเนื้อตาย (มีจำนวน 7 ภาพ)

หลังจากที่แบ่งชุดข้อมูลการฝึกออกเป็น 3 ประเภท แล้วทางผู้วิจัยจะแบ่งการทดลองออกเป็นอีก 3 การทดลอง ได้แก่ 1. การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทเนื้อแดง 2. การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทหนอง และ การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทเนื้อตาย

ก่อนที่จะนำชุดข้อมูลการฝึกที่แบ่งแยกประเภทไปเข้าสู่กระบวนการเรียนรู้เชิงลึกทางผู้วิจัยจะนำตัวแบบการเรียนรู้พื้นฐานมาทดสอบกับชุดข้อมูลการทดสอบที่แบ่งแยกประเภทเนื้อแดง, หนอง และเนื้อตาย เพื่อหาประสิทธิภาพในการแบ่งแยกภาพบาดแผลของตัวแบบการเรียนรู้พื้นฐานในตาราง 5.8

ตารางที่ 5.8 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีภาพชุดข้อมูลการฝึก 292 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	97.53	88.52	85.13	91.67	9.80
ชุดข้อมูลการทดสอบประเภทหนอง	87.31	70.66	71.33	80.53	22.67
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	92.70	81.32	72.62	83.97	19.67

จากตารางที่ 5.8 สังเกตได้ว่าการเรียนรู้เชิงลึกแบบพื้นฐานโดยทดสอบด้วยชุดข้อมูลการทดสอบประเภทเนื้อแดงมีประสิทธิภาพที่ดีกว่าการทดสอบชุดข้อมูลการทดสอบ (แบบรวม) แต่การทดสอบชุดข้อมูลการทดสอบประเภทหนอง และการทดสอบชุดข้อมูลการทดสอบประเภทเนื้อตายกลับมีประสิทธิภาพที่ต่ำกว่าการทดสอบชุดข้อมูลการทดสอบ (แบบรวม) อาจจะเป็นเพราะว่าภาพประเภทของภาพแผลเนื้อแดงมีมากกว่าภาพประเภทอื่นหรืออาจจะเป็นเพราะว่าสีภาพประเภทเนื้อแดงมีชัดเจนในการแบ่งแยกของภาพ

ต่อไปจะเป็นการนำตัวแบบการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสี่อีก 6 รูปแบบสี่ (ที่นำแบบ 6 รูปแบบสี่ มาแบบเดียวเพราะการเรียนรู้เชิงลึกแบบการฝึกที่แบ่งแยกประเภทจะมีการขยายด้วยวิธีนี้ด้วย) มาทดสอบกับชุดข้อมูลการทดสอบที่แบ่งแยกประเภทเนื้อแดง, หนอง และเนื้อตาย เพื่อหาประสิทธิภาพในการแบ่งแยกภาพบาดแผลของตัวแบบการเรียนรู้พื้นฐานในตาราง 5.9

ตารางที่ 5.9 การเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสี่อีก 6 รูปแบบสี่ โดยที่มีภาพชุดข้อมูลการฝึก 2,044 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	97.36	94.47	90.10	94.77	4.97
ชุดข้อมูลการทดสอบประเภทหนอง	93.65	75.40	79.08	85.48	15.95
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	92.87	86.72	75.80	81.30	18.69

จากตารางที่ 5.9 สังเกตได้ว่าการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสี่อีก 6 รูปแบบ มีแนวโน้มของผลการทดลองคล้ายกับตารางที่ 5.8 แต่ประสิทธิภาพโดยรวมของตารางที่ 5.9 มีประสิทธิภาพที่ดีกว่า

ต่อไปจะเป็นการนำตัวแบบการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง มาทดสอบกับชุดข้อมูลการทดสอบที่แบ่งแยกประเภทเนื้อแดง, หนอง และเนื้อตาย เพื่อหาประสิทธิภาพในการแบ่งแยกภาพบาดแผลของตัวแบบการเรียนรู้พื้นฐานในตาราง 5.10

ตารางที่ 5.10 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง ชุดข้อมูล การฝึกจำนวน 2,336 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	97.48	90.11	86.26	92.46	6.72
ชุดข้อมูลการทดสอบประเภทหนอง	98.15	77.06	81.05	88.14	14.78
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	89.92	84.63	71.11	82.66	21.60

จากตารางที่ 5.10 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง มีแนวโน้มของผลการทดลองคล้ายกับตารางที่ 5.8 และ 5.9 แต่ประสิทธิภาพโดยรวมของตารางที่ 5.10 ดีกว่าตาราง 5.8 แต่กับ 5.9 มีเพียงแค่ชุดข้อมูลการทดสอบประเภทเนื้อแดงที่ตารางที่ 5.10 มีประสิทธิภาพที่ต่ำกว่า แต่ชุดข้อมูลการทดสอบประเภทหนอง และเนื้อตายตารางที่ 5.9 มีประสิทธิภาพที่สูงกว่า อาจจะเป็นได้ว่าเมื่อขยายข้อมูลด้วยสี่ส่งผลต่อบาดแผลเนื้อแดงมากกว่าขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง แต่ในทางกลับกันการขยายข้อมูลด้วยด้วยการหมุนและพลิกอีก 7 ทิศทาง ส่งผลต่อบาดแผลบาดแผลหนองและเนื้อตายมากกว่าการขยายข้อมูลด้วยสี่

ต่อไปจะเป็นการนำตัวแบบการเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสี่อีก 6 รูปแบบสี่ การหมุนและพลิกอีก 7 ทิศทาง มาทดสอบกับชุดข้อมูลการทดสอบที่แบ่งแยกประเภทเนื้อแดง, หนอง และเนื้อตาย เพื่อหาประสิทธิภาพในการแบ่งแยกภาพบาดแผลของตัวแบบการเรียนรู้พื้นฐานในตาราง 5.11

ตารางที่ 5.11 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และ พลิกอีก 7 ทิศทาง ชุดข้อมูลการฝึกจำนวน 16,352 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	95.13	93.09	87.02	92.29	7.08
ชุดข้อมูลการทดสอบประเภทหนอง	96.65	90.79	82.72	89.78	13.10
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	92.93	89.32	78.35	87.40	15.56

จากตารางที่ 5.11 การเรียนรู้เชิงลึกโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง มีแนวโน้มของผลการทดลองคล้ายกับตารางที่ 5.8, 5.9 และ 5.10 ยิ่งเป็นการตอกย้ำว่าการขยายข้อมูลด้วยสีส่งผลต่อขนาดแผลเนื้อแดงมากกว่าขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง แต่ในทางกลับกันการขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง ส่งผลต่อขนาดแผลบาดแผลหนองและเนื้อตายมากกว่าการขยายข้อมูลด้วยสี

5.2.1 การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทเนื้อแดง

สำหรับการทดลองนี้ทางผู้วิจัยแบ่งการทดลองออกไปอีก 4 การทดลอง โดยที่แต่ละการทดลองจะมีชุดข้อมูลการฝึกประเภทเนื้อแดงที่ไม่เหมือนกันได้แก่ 1. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดง 159 ภาพ 2. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี 3. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายด้วยการหมุนและพลิกอีก 7 ทิศทาง 4. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง

5.2.1.1 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดง 159 ภาพ

ได้นำเฉพาะชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงมาใช้ในการเรียนรู้เชิงลึกเท่านั้น ประสิทธิภาพของการเรียนรู้เชิงลึกอยู่ในตารางที่ 5.12 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.12 การเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดง 159 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	96.26	82.98	75.59	84.76	18.85
ชุดข้อมูลการทดสอบประเภทหนอง	82.62	39.45	39.76	51.05	47.87
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	89.79	68.83	54.03	65.92	34.77
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	90.28	61.95	56.52	67.03	33.91

ในการทดลองนี้ยังไม่เกิดการขยายข้อมูลเกิดขึ้นดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.12 มาเปรียบเทียบกับในตารางที่ 5.8 ทำให้พบว่าการเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงและมีชุดข้อมูลการทดสอบประเภทเนื้อแดงมีความแม่นยำของค่า IoU อยู่ที่ 75.59 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงมีความแม่นยำของค่า IoU อยู่ที่ 85.13 % จากในตาราง 5.8 แม้กระทั่งว่าการเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงซึ่งมีชุดทดสอบประเภทหนองและเนื้อตายก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานที่มีชุดข้อมูลการทดสอบประเภทหนองและ

เนื้อตาย ซึ่งค่า IoU อยู่ที่ 39.76 %, 54.03 %, 71.33 % และ 72.62 % ตามลำดับ แล้วจากในตารางที่ 5.1 และ 5.12 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.1 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.12

5.2.1.2 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงไปขยายข้อมูลด้วยสีของภาพบาดแผล ซึ่งรูปแบบสีที่นำมาขยายข้อมูลมีจำนวน 6 รูปแบบสี ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 ทำให้จำนวนชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยสีมีจำนวน 1,113 ภาพ จากเดิม 159 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตารางที่ 5.9 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.13 การเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี จำนวน 1,113 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	93.90	90.03	81.65	89.38	13.44
ชุดข้อมูลการทดสอบประเภทหนอง	79.91	64.28	52.24	62.68	37.04
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	85.08	85.89	66.55	77.77	17.96
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	85.81	78.90	66.41	76.06	23.70

ในการทดลองนี้เกิดการขยายข้อมูลเกิดขึ้นดังนั้นก็ให้นำประสิทธิภาพจากในตารางที่ 5.13 มาเปรียบเทียบกับในตารางที่ 5.9 ทำให้พบว่าการเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี 6 รูปแบบสีและมีชุดข้อมูลการทดสอบประเภทเนื้อแดงมีความแม่นยำของค่า IoU อยู่ที่ 81.65 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี และมีชุดข้อมูลการทดสอบประเภทเนื้อแดงมีความแม่นยำของค่า IoU อยู่ที่ 90.10 % จากในตาราง 5.9 แม้กระทั่งว่าการเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี 6 รูปแบบสีซึ่งมีชุดทดสอบประเภทหนองและเนื้อตายก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี ที่มีชุดข้อมูลการทดสอบประเภทหนองและเนื้อตาย ซึ่งค่า IoU อยู่ที่ 52.24 %, 66.55 %, 79.08 % และ 75.80 % ตามลำดับ แล้วจากในตารางที่ 5.6 และ 5.13 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.6 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.13

5.2.1.3 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายด้วยการหมุนและพลิกอีก 7

ทิศทาง

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงไปขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง ทำให้จำนวนชุดข้อมูล 1,272 ภาพ จากเดิม 159 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตารางที่ 5.10 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.14 การเรียนรู้เชิงลึกแบบโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง จำนวน 1,272 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	95.90	91.06	85.27	91.87	8.26
ชุดข้อมูลการทดสอบประเภทหนอง	91.80	71.30	73.93	81.13	18.80
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	82.37	84.24	60.62	71.91	29.06
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	89.48	81.04	74.17	82.30	18.02

ในการทดลองนี้เกิดการขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทางดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.14 มาเปรียบเทียบกับในตารางที่ 5.10 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง และมีชุดข้อมูลการทดสอบประเภทเนื้อแดงความแม่นยำของค่า IoU อยู่ที่ 85.27 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง และมีชุดข้อมูลการทดสอบประเภทเนื้อแดงความแม่นยำของค่า IoU อยู่ที่ 86.26 % และจากในตาราง 5.9 แม้กระทั่งว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทางซึ่งมีชุดข้อมูลการทดสอบประเภทหนองและเนื้อตายก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง ที่มีชุดข้อมูลการทดสอบประเภทหนองและเนื้อตายซึ่งค่า IoU อยู่ที่ 73.93 %, 60.62 %, 81.05% และ 71.11 % ตามลำดับ แล้วจากในตารางที่ 5.2 และ 5.14 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.2 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.14

5.2.1.4 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทเนื้อแดงไปขยายข้อมูลด้วยสีของภาพบาดแผล การหมุนและพลิกอีก 7 ทิศทาง ซึ่งรูปแบบสีที่นำมาขยายข้อมูลมีจำนวน 6 รูปแบบสี ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 ทำให้จำนวนชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยสีมีจำนวน 8,904 ภาพ จากเดิม 159 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตารางที่ 5.11 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.15 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง จำนวน 8,904 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	96.96	92.64	88.08	93.63	5.86
ชุดข้อมูลการทดสอบประเภทหนอง	82.20	68.79	66.91	76.61	20.91
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	80.46	89.25	69.65	81.37	26.87
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	86.25	77.51	72.47	80.88	20.12

ในการทดลองนี้เกิดการขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง ดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.15 มาเปรียบเทียบกับในตารางที่ 5.11 ทำให้

พบว่า การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง และชุดข้อมูลการทดสอบประเภทเนื้อแดงมีความแม่นยำของค่า IoU อยู่ที่ 88.08 % ซึ่งสูงกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง และใช้ชุดข้อมูลการทดสอบประเภทเนื้อแดงมีความแม่นยำของค่า IoU อยู่ที่ 87.02 % และจากในตาราง 5.15 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อแดงที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง ซึ่งมีชุดข้อมูลการทดสอบประเภทหนองและเนื้อตายกลับมีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง ที่มีชุดข้อมูลการทดสอบประเภทหนองและเนื้อตายซึ่งค่า IoU อยู่ที่ 66.91 %, 69.65 %, 82.72 % และ 78.35 % ตามลำดับ แล้วจากในตารางที่ 5.7 และ 5.15 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.7 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.15

5.2.2 การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทหนอง

สำหรับการทดลองนี้ทางผู้วิจัยแบ่งการทดลองออกไปอีก 4 การทดลอง โดยที่แต่ละการทดลองจะมีชุดข้อมูลการฝึกประเภทหนองที่ไม่เหมือนกันได้แก่ 1. ชุดข้อมูลการฝึกที่เป็นประเภทหนอง 142 ภาพ 2. ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี 3. ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายด้วยการหมุนและพลิกอีก 7 ทิศทาง 4. ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง

5.2.2.1 ชุดข้อมูลการฝึกที่เป็นประเภทหนอง 142 ภาพ

ได้นำเฉพาะชุดข้อมูลการฝึกที่เป็นประเภทหนองมาใช้ในการเรียนรู้เชิงลึกเท่านั้น ประสิทธิภาพของการเรียนรู้เชิงลึกอยู่ในตารางที่ 5.12 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.16 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนอง 142 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	94.73	88.50	79.51	88.11	9.78
ชุดข้อมูลการทดสอบประเภทหนอง	89.61	71.23	71.43	80.79	20.94
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	82.25	81.41	66.49	79.41	25.03
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	88.23	78.90	72.25	82.57	18.45

ในการทดลองนี้ไม่เกิดการขยายข้อมูลดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.16 มาเปรียบเทียบกับในตารางที่ 5.8 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนอง และชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของค่า IoU อยู่ที่ 71.43 % ซึ่งสูงกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐาน และมีชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของค่า IoU อยู่ที่ 71.33 % และจากในตาราง 5.16 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อตายกลับมีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อตายซึ่งค่า IoU อยู่ที่ 79.51 %, 66.49 %, 85.13 % และ 72.62 % ตามลำดับ แล้วจากในตารางที่ 5.1 และ 5.16 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.1 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.1

5.2.2.2 ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทหนองไปขยายข้อมูลด้วยสีของ ภาพบาดแผล ซึ่งรูปแบบสีที่นำมาขยายข้อมูลมีจำนวน 6 รูปแบบสี ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 ทำให้จำนวนชุดข้อมูลการฝึกประเภท หนองที่ขยายข้อมูลด้วยสีมีจำนวน 994 ภาพ จากเดิม 142 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตาราง ที่ 5.13 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.17 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี จำนวน 994 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	92.26	94.41	81.28	88.83	12.17
ชุดข้อมูลการทดสอบประเภทหนอง	89.66	72.61	75.55	84.05	18.38
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	80.76	85.93	67.32	79.68	24.57
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	87.65	78.03	72.37	81.28	21.03


ในการทดลองนี้เกิดการขยายข้อมูลด้วยสี 6 รูปแบบสี ดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.17 มาเปรียบเทียบกับในตารางที่ 5.9 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสีและชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของค่า IoU อยู่ที่ 75.55 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี และชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของ

ค่า IoU อยู่ที่ 79.08 % และจากในตาราง 5.17 แม้กระทั่งว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูล การฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี่ซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อ ตายก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสี่ อีก 6 รูปแบบสี่ ที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อตายซึ่งค่า IoU อยู่ที่ 81.28 %, 67.32 %, 90.10 % และ 75.80 %ตามลำดับ แล้วจากในตารางที่ 5.6 และ 5.17 ประสิทธิภาพของ ชุดข้อมูลการทดสอบแบบรวมในตาราง 5.6 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.17

5.2.2.3 ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายด้วยการหมุนและพลิกอีก 7

ทิศทาง

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทหนองไปขยายข้อมูลด้วยการ หมุนและพลิกอีก 7 ทิศทาง ทำให้จำนวนชุดข้อมูล 1,136 ภาพ จากเดิม 142 ภาพ ไปเข้าสู่ กระบวนการเรียนรู้ในตารางที่ 5.14 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุด ทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)



ตารางที่ 5.18 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยการหมุน และพลิกอีก 7 ทิศทาง จำนวน 1,136 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	92.24	89.86	76.15	85.34	16.76
ชุดข้อมูลการทดสอบประเภทหนอง	82.91	71.30	76.18	82.26	18.60
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	76.87	83.89	65.34	78.12	27.18
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	86.40	74.37	70.01	78.81	23.59

ในการทดลองนี้เกิดการขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทางดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.18 มาเปรียบเทียบกับในตารางที่ 5.10 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทางและชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของค่า IoU อยู่ที่ 76.18 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง และมีชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของค่า IoU อยู่ที่ 81.05 % และจากในตาราง 5.18 แม้กระทั่งว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทางซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อตายก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง ที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อตายซึ่งค่า IoU อยู่ที่ 76.15 %, 65.34 %, 86.26 % และ 84.63 % ตามลำดับ แล้วจากในตารางที่ 5.2 และ 5.18 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.2 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.18

5.2.2.4 ชุดข้อมูลการฝึกที่เป็นประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทหนองไปขยายข้อมูลด้วยสีของ ภาพบาดแผล การหมุนและพลิกอีก 7 ทิศทาง ซึ่งรูปแบบสีที่นำมาขยายข้อมูลมีจำนวน 6 รูปแบบสี ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 ทำให้จำนวนชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยสีมีจำนวน 7,952 ภาพ จากเดิม 142 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตารางที่ 5.15 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.19 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบ สี การหมุนและพลิกอีก 7 ทิศทาง จำนวน 7,952 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	94.49	91.23	79.41	87.40	13.32
ชุดข้อมูลการทดสอบประเภทหนอง	98.13	70.93	78.57	83.77	18.42
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	83.56	83.23	70.56	81.98	19.51
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	91.65	74.53	73.52	81.19	20.35

ในการทดลองนี้เกิดการขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง ดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.19 มาเปรียบเทียบกับในตารางที่ 5.11 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทางและชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของค่า IoU อยู่ที่

78.57 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทางและมีชุดข้อมูลการทดสอบประเภทหนองมีความแม่นยำของค่า IoU อยู่ที่ 82.72 % และจากในตาราง 5.19 แม้กระทั่งว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทหนองที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง ซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อตายก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง ที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและเนื้อตายซึ่งค่า IoU อยู่ที่ 79.41 %, 70.56 %, 87.02 % และ 78.35 % ตามลำดับ แล้วจากในตารางที่ 5.7 และ 5.19 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.7 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.19

5.2.3 การเรียนรู้เชิงลึกกับภาพบาดแผลประเภทเนื้อตาย

สำหรับการทดลองนี้ทางผู้วิจัยแบ่งการทดลองออกไปอีก 4 การทดลอง โดยที่แต่ละการทดลองจะมีชุดข้อมูลการฝึกประเภทเนื้อตายที่ไม่เหมือนกันได้แก่ 1. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตาย 97 ภาพ 2. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี 3. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายด้วยการหมุนและพลิกอีก 7 ทิศทาง 4. ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง

5.2.3.1 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตาย 97 ภาพ

ได้นำเฉพาะชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายมาใช้ในการเรียนรู้เชิงลึกเท่านั้น ประสิทธิภาพของการเรียนรู้เชิงลึกอยู่ในตารางที่ 5.16 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.20 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตาย 97 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	94.62	85.02	78.09	87.42	18.29
ชุดข้อมูลการทดสอบประเภทหนอง	76.40	50.05	47.20	59.39	37.10
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	90.78	84.82	71.82	82.88	20.36
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	87.15	65.79	61.95	72.50	27.24

ในการทดลองนี้ไม่เกิดการขยายข้อมูลดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.20 มาเปรียบเทียบกับในตารางที่ 5.8 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายและชุดข้อมูลการทดสอบประเภทเนื้อตายมีความแม่นยำของค่า IoU อยู่ที่ 71.82 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานและมีชุดข้อมูลการทดสอบประเภทเนื้อตายมีความแม่นยำของค่า IoU อยู่ที่ 72.62 % จากในตาราง 5.20 แม้กระทั่งว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองซึ่งค่า IoU อยู่ที่ 78.09 %, 47.20 %, 85.13 % และ 71.33 % ตามลำดับ แล้วจากในตารางที่ 5.1 และ 5.20 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.1 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.20

5.2.3.2 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายไปขยายข้อมูลด้วยสีของภาพบาดแผล ซึ่งรูปแบบสีที่นำมาขยายข้อมูลมีจำนวน 6 รูปแบบสี ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 ทำให้จำนวนชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยสีมีจำนวน 679 ภาพ จากเดิม 97 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตารางที่ 5.17 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.21 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี จำนวน 679 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	91.74	85.20	76.06	85.38	17.77
ชุดข้อมูลการทดสอบประเภทหนอง	79.35	59.65	55.24	67.36	34.65
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	91.42	83.80	73.24	84.09	21.56
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	86.86	69.65	64.97	75.29	27.73


ในการทดลองนี้เกิดการขยายข้อมูลด้วยสีดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.21 มาเปรียบเทียบกับในตารางที่ 5.9 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสีและชุดข้อมูลการทดสอบประเภทเนื้อตายมีความแม่นยำของค่า IoU อยู่ที่ 73.24 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสีและมีชุดข้อมูลการทดสอบประเภทเนื้อตายความแม่นยำของค่า

IoU อยู่ที่ 75.80 % จากในตาราง 5.9 แม้กระทั่งว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสีซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสีที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองซึ่งค่า IoU อยู่ที่ 76.06 %, 55.24 %, 90.10% และ 79.08 % ตามลำดับ แล้วจากในตารางที่ 5.6 และ 5.21 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.6 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.21

5.2.3.3 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายด้วยการหมุนและพลิกอีก 7

ทิศทาง

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายไปขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง ทำให้จำนวนชุดข้อมูล 776 ภาพ จากเดิม 97 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตารางที่ 5.18 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)



ตารางที่ 5.22 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง จำนวน 776 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	95.70	85.14	81.14	88.16	9.40
ชุดข้อมูลการทดสอบประเภทหนอง	91.08	50.20	58.99	67.73	31.96
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	94.96	82.57	74.79	85.13	17.48
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	94.10	64.90	68.01	76.57	23.40

ในการทดลองนี้เกิดการขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง ดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.22 มาเปรียบเทียบกับในตารางที่ 5.10 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทางและชุดข้อมูลการทดสอบประเภทเนื้อตายมีความแม่นยำของค่า IoU อยู่ที่ 74.79 % ซึ่งสูงกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทางและมีชุดข้อมูลการทดสอบประเภทเนื้อตายมีความแม่นยำของค่า IoU อยู่ที่ 71.11 % จากในตาราง 5.22 แต่การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทางซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองมีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลแบบการหมุนและพลิกอีก 7 ทิศทาง ที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองซึ่งค่า IoU อยู่ที่ 81.14 %, 58.99 %, 86.26 % และ 81.05 % ตามลำดับ แล้วจากในตารางที่ 5.2 และ 5.22 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.2 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.22

5.2.3.4 ชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง

การทดลองนี้จะนำชุดข้อมูลการฝึกที่เป็นประเภทเนื้อตายไปขยายข้อมูลด้วยสีของภาพบาดแผล การหมุนและพลิกอีก 7 ทิศทาง ซึ่งรูปแบบสีที่นำมาขยายข้อมูลมีจำนวน 6 รูปแบบ สี ได้แก่ iPadtoMotoc, iPadtoS8, MotoCtoiPad, S8toiPad, S8toMotoc และ MotoctoS8 ทำให้จำนวนชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยสีมีจำนวน 5,432 ภาพ จากเดิม 97 ภาพ ไปเข้าสู่กระบวนการเรียนรู้ในตารางที่ 5.19 ซึ่งชุดข้อมูลการทดสอบนั้นจะเป็นชุดข้อมูลการทดสอบที่เป็นชุดทดสอบประเภทเนื้อแดง หนอง, เนื้อตาย และชุดทดสอบแบบรวม (27 ภาพ)

ตารางที่ 5.23 การเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทาง จำนวน 5,432 ภาพ

ชุดข้อมูลทดสอบ	Precision (%)	Recall (%)	IoU (%)	DSC (%)	RSE (%)
ชุดข้อมูลการทดสอบประเภทเนื้อแดง	97.11	90.90	84.85	91.54	8.60
ชุดข้อมูลการทดสอบประเภทหนอง	93.30	54.24	61.89	71.12	33.46
ชุดข้อมูลการทดสอบประเภทเนื้อตาย	94.38	84.04	77.84	87.32	14.79
ชุดข้อมูลการทดสอบแบบรวม (27 ภาพ)	95.06	70.25	71.31	79.44	22.81

ในการทดลองนี้เกิดการขยายข้อมูลด้วยสี การหมุนและการพลิกอีก 7 ทิศทาง ดังนั้นจะนำประสิทธิภาพจากในตารางที่ 5.23 มาเปรียบเทียบกับในตารางที่ 5.11 ทำให้พบว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี การหมุน

และพลิกอีก 7 ทิศทางและชุดข้อมูลการทดสอบประเภทเนื้อตายมีความแม่นยำของค่า IoU อยู่ที่ 77.84 % ซึ่งต่ำกว่าประสิทธิภาพของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทางและมีชุดข้อมูลการทดสอบประเภทเนื้อตายมีความแม่นยำของค่า IoU อยู่ที่ 78.35 % จากในตาราง 5.23 แม้กระทั่งว่าการเรียนรู้เชิงลึกโดยที่มีภาพชุดข้อมูลการฝึกประเภทเนื้อตายที่ขยายข้อมูลด้วยรูปแบบสี การหมุนและพลิกอีก 7 ทิศทางซึ่งมีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองก็มีประสิทธิภาพที่ต่ำกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานโดยที่มีการขยายข้อมูลด้วยรูปแบบสีอีก 6 รูปแบบสี การหมุน และพลิกอีก 7 ทิศทาง ที่มีชุดข้อมูลการทดสอบประเภทเนื้อแดงและหนองซึ่งค่า IoU อยู่ที่ 84.85 %, 61.89 %, 87.02 % และ 82.72 %ตามลำดับ แล้วจากในตารางที่ 5.7 และ 5.23 ประสิทธิภาพของชุดข้อมูลการทดสอบแบบรวมในตาราง 5.7 มีประสิทธิภาพโดยรวมที่ดีกว่าในตารางที่ 5.23



บทที่ 6 สรุปผลการทดลองและการเสนอแนะ

6.1 สรุปผลการทดลอง

จากสมมติฐานที่ว่าสีและประเภทของเนื้อเยื่อบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญทำให้ผู้วิจัยสามารถสรุปผลของการทดลองออกมาได้เป็น 2 ส่วน คือ สีมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ และเนื้อเยื่อมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

6.1.1 สรุปผลการทดลองที่ว่าสีมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

ผลการดำเนินงานวิจัยต่าง ๆ ในบทที่ 5.1 ผู้วิจัยได้ทำการเรียนรู้เชิงลึกแบบพื้นฐานทั้งแบบที่ไม่มีการขยายข้อมูลและการขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง (ในตารางที่ 5.1 และ 5.2 ตามลำดับ) เพื่อเอาไว้เปรียบเทียบกับผลการทดลองที่ผู้วิจัยได้สร้างขึ้นมาจากสมมติฐานอีก 5 การทดลอง

ในแต่ละการทดลองทางผู้วิจัยได้มีการขยายข้อมูลด้วยรูปแบบสี ซึ่งแต่ละการทดลองก็จะมีจำนวนและชนิดรูปแบบสีที่แตกต่างกันมาขยายข้อมูล แล้วจากผลการทดลองจะสังเกตได้ว่าการเรียนรู้เชิงลึกที่มีการขยายข้อมูลด้วยสีในรูปแบบใดก็ตามจะมีประสิทธิภาพที่สูงกว่าของการเรียนรู้แบบพื้นฐานที่ไม่มีการขยายข้อมูล ส่วนการเรียนรู้เชิงลึกที่มีการขยายข้อมูลด้วยสีที่มีจำนวนรูปแบบสี 2 รูปแบบสีขึ้นไปจะมีประสิทธิภาพที่สูงกว่าของการเรียนรู้เชิงลึกแบบพื้นฐานที่มีการขยายข้อมูลด้วยการหมุนและพลิกอีก 7 ทิศทาง แล้วจากผลทดลองยังแสดงให้เห็นอีกว่ายิ่งจำนวนการขยายข้อมูลด้วยรูปแบบสีมีจำนวนรูปแบบมากขึ้นประสิทธิภาพของการแบ่งแยกพื้นที่บาดแผลก็จะมากขึ้นอีกด้วย และสุดท้ายนี้ถ้านำการขยายด้วยสี การหมุนและพลิกอีก 7 ทิศทาง จะทำให้ได้ประสิทธิภาพของการเรียนรู้เชิงลึกที่ดีที่สุด

ทำให้ได้ว่าจากผลการดำเนินงานวิจัยและที่กล่าวมาในข้างต้นทำให้สามารถสรุปได้ว่าการขยายข้อมูลด้วยสีช่วยให้ประสิทธิภาพการแบ่งแยกพื้นที่บาดแผลมีมากขึ้น หรือกล่าวคือสีมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

6.1.2 สรุปผลการทดลองที่ว่าเนื้อเยื่อมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

ผลการดำเนินงานวิจัยต่าง ๆ ในบทที่ 5.2 ผู้วิจัยได้นำการเรียนรู้เชิงลึกจากบทที่ 5.1 ทั้งหมดมาทดสอบประสิทธิภาพกับชุดข้อมูลทดสอบแบบแบ่งประเภทเนื้อเยื่อ (ในตารางที่ 5.8 – 5.11) เพื่อเอาไว้เปรียบเทียบกับผลการทดลองที่ผู้วิจัยได้สร้างขึ้นมาจากสมมติฐานอีก 3 การทดลอง (จะเปรียบเทียบเฉพาะตารางการเรียนรู้ที่มีการขยายข้อมูลเหมือนกัน) ในการทดลองที่แบ่งออกเป็น 3 ประเภทตามสภาพของรูปภาพบาดแผลได้แก่ (เนื้อแดง, หนอง และเนื้อตาย) ซึ่งแต่ละการทดลองก็จะการเรียนรู้ที่ทำการขยายข้อมูลแบบต่าง ๆ ที่คล้ายกับการทดลองที่ 5.1

จากผลการทดลองโดยรวมแล้วประเภทบาดแผลเนื้อแดงมีประสิทธิภาพที่ต่ำกว่าการเรียนรู้เชิงลึกแบบพื้นฐาน (แบบไม่แยกประเภทบาดแผลในการเรียนรู้เชิงลึก) แต่ประสิทธิภาพก็ไม่ต่ำไปกว่ากันมากอาจจะเป็นเพราะแผลเนื้อแดงเป็นสีแดงแล้วสีแดงในร่างกายคนส่วนมากก็จะเป็นบาดแผลรวมไปถึงพื้นหลังหรือสิ่งรบกวนต่าง ๆ ในภาพมีสีแดงน้อยมากทำให้แผลเนื้อแดงเรียกได้ว่าเป็นสิ่งที่ง่ายต่อการแบ่งแยกพื้นที่บาดแผล และยังมีการแบ่งแยกพื้นที่บาดแผลที่มีประสิทธิภาพที่สูงสุดอีกด้วยเมื่อเทียบกับบาดแผลหนอง และเนื้อตาย

จากผลการทดลองโดยรวมแล้วประเภทบาดแผลหนองมีประสิทธิภาพที่ต่ำกว่าการเรียนรู้เชิงลึกแบบพื้นฐาน (แบบไม่แยกประเภทบาดแผลในการเรียนรู้เชิงลึก) ซึ่งไม่เหมือนกับแผลเนื้อแดงที่มีความแตกต่างไม่มากแต่กับหนองกับความแตกต่างค่อนข้างมากเพราะว่าแผลหนองมีสีเหลืองซึ่งคล้ายกับผิวหนังของมนุษย์ทำให้อาจจะทำให้เกิดความสับสนของการแบ่งแยกพื้นที่บาดแผล และยังมีการแบ่งแยกพื้นที่บาดแผลที่มีประสิทธิภาพที่ต่ำที่สุดอีกด้วยเมื่อเทียบกับบาดแผลเนื้อแดง และเนื้อตาย

จากผลการทดลองโดยรวมแล้วประเภทบาดแผลเนื้อตายมีประสิทธิภาพที่ต่ำกว่าการเรียนรู้เชิงลึกแบบพื้นฐาน (แบบไม่แยกประเภทบาดแผลในการเรียนรู้เชิงลึก) ซึ่งไม่เหมือนกับแผลเนื้อแดงที่มีความแตกต่างไม่มากแต่กับเนื้อตายกับความแตกต่างค่อนข้างมาก เพราะว่ามีสีดำนซึ่งคล้ายกับพื้นหลังหรือสิ่งรบกวนที่เป็นสีดำทำให้อาจจะทำให้เกิดความสับสนของการแบ่งแยกพื้นที่บาดแผล

ทำให้ได้ว่าจากผลการดำเนินงานวิจัยและที่กล่าวมาในข้างต้นทำให้สามารถสรุปได้ว่าการแบ่งเนื้อเยื่อประเภทบาดแผลไม่ช่วยให้ประสิทธิภาพการแบ่งแยกพื้นที่บาดแผลมีมากขึ้นหรือกล่าวคือการแบ่งเนื้อเยื่อประเภทบาดแผลไม่ส่งผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

สุดท้ายนี้จากสรุปผลการทดลองข้างต้นทำให้สามารถตอบสมมติฐานที่ว่าสีและประเภทของเนื้อเยื่อบาดแผลมีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญได้ว่าสีที่มีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญเท่านั้น ส่วนการแบ่งเนื้อเยื่อบาดแผลไม่มีผลต่อการแบ่งแยกพื้นที่บาดแผลอย่างมีนัยสำคัญ

6.2 ข้อเสนอแนะ

การย่อรูปภาพอาจจะทำให้ภาพสูญเสียข้อมูลสำคัญไป แต่การใช้ภาพแบบไม่ย่อก็จะทำให้ขนาดภาพไม่เท่ากันเพราะภาพที่ใช้ในการเรียนรู้เชิงลึกต้องมีขนาดของรูปที่เท่ากันดังนั้นควรเลือกใช้วิธีการ scaling แทนเพื่อป้องกันการสูญเสียข้อมูลสำคัญไป และจากงานวิจัยในด้านรูปภาพอื่น ๆ การ scaling ถือว่าเป็นเทคนิคที่ช่วยให้ความแม่นยำมีประสิทธิภาพมากขึ้น

แล้วจากการศึกษางานวิจัยจำนวนรูปภาพถือว่าเป็นสิ่งสำคัญที่ใช้ในการเรียนรู้เชิงลึก เนื่องจากงานวิจัยนี้นำภาพมาจากฐานข้อมูลสาธารณะที่มีรูปจำนวนน้อย แต่เพื่อความการทำซ้ำงานวิจัยนี้จึงจำเป็นต้องยอมใช้ฐานข้อมูลสาธารณะที่มีรูปจำนวนน้อย ในอนาคตถ้าได้ภาพมาจากฐานข้อมูลสาธารณะหรือฐานข้อมูลปิตที่มีจำนวนมากขึ้นจะช่วยให้การแบ่งแยกพื้นที่บาดแผลมีความแม่นยำมากขึ้น



รายการอ้างอิง

- Confusion matrix. (4 February 2019, at 11:29 (UTC)). Retrieved from https://en.wikipedia.org/wiki/Confusion_matrix
- Jaccard index. (1 April 2019, at 01:20 (UTC)). Retrieved from https://en.wikipedia.org/wiki/Jaccard_index
- Liu, X., Wang, C., Li, F., Zhao, X., Zhu, E., & Peng, Y. (2017). *A framework of wound segmentation based on deep convolutional networks*. Paper presented at the International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), Shanghai, China. <https://ieeexplore.ieee.org/document/8302184/>
- Mukherjee, R., Manohar, D. D., Das, D. K., Achar, A., Mitra, A., & Chakraborty, C. (2014). Automated Tissue Classification Framework for eproducible Chronic Wound Assessment. *Hindawi Publishing Corporation BioMed Research International*, 2014.
- Pawara, Okafor, & Wiering. (2017). *Data Augmentation for Plant Classification*. Paper presented at the Advanced Concepts for Intelligent Vision Systems. ACIVS 2017. https://link.springer.com/chapter/10.1007/978-3-319-70353-4_52
- Pholberdee, N., Pathompatai, C., & Taeprasartsit, P. (2018). *Study of Chronic Wound Image Segmentation: Impact of Tissue Type and Color Data Augmentation*. Paper presented at the International Joint Conference on Computer Science and Software Engineering (JCSSE), Nakhon Pathom. <https://ieeexplore.ieee.org/document/8457392>
- Puttaruka, C., & Taeprasartsit, P. (2018). *Color Data Augmentation through Learning ColorMapping Parameters between Cameras*. Paper presented at the International Joint Conference on Computer Science and Software Engineering (JCSSE), Nakhon Pathom. <https://ieeexplore.ieee.org/document/8457355>
- Sørensen–Dice coefficient. (9 April 2019, at 14:17 (UTC)). Retrieved from https://en.wikipedia.org/wiki/Sørensen–Dice_coefficient
- Wang, C., Yan, X., Smith, M., Kochhar, K., Rubin, M., Warren, S. M., . . . Lee, H. (2015). A

Unified Framework for Automatic Wound Segmentation and Analysis with Deep Convolutional Neural Networks. Paper presented at the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Milan, Italy. <https://ieeexplore.ieee.org/document/7318881/>





ประวัติผู้เขียน

ชื่อ-สกุล	นันทิพัฒน์ พลบดี
วัน เดือน ปี เกิด	31 มีนาคม 2538
สถานที่เกิด	อำเภอเมือง จังหวัดกาญจนบุรี
วุฒิการศึกษา	สำเร็จการศึกษาปริญญาวิทยาศาสตรบัณฑิต สาขาวิทยาการคอมพิวเตอร์ มหาวิทยาลัยศิลปากร พ.ศ.2559 GPA: 3.15
ที่อยู่ปัจจุบัน	341/1 ถ.ปากแพรก ต.บ้านเหนือ อ.เมือง จ.กาญจนบุรี 71000

