

การพัฒนากระบวนการคัดแยกภาพถ่ายระดับความรุนแรงของแผลกดทับ ด้วย YOLO และการเรียนรู้เชิงลึก Development of Severity Image Pressure Injury Classification Using YOLO and Deep Learning

ศักดิ์ชัย ศรีมากรณ์¹, นิชา นภาพร จงกะสิกิจ^{2*} และปิยธรณ์ เร่งเร้ว³

Sakchai Srimakorn¹, Nicha Naphaphon Jongkasikit^{2*} and Piyathorn Rengrew³

^{1,2*}คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏลำปาง 119 หมู่ 9 ตำบลชมพู อำเภอเมือง ลำปาง 52100

³คณะพยาบาลศาสตร์ มหาวิทยาลัยราชภัฏลำปาง 119 หมู่ 9 ตำบลชมพู อำเภอเมือง ลำปาง 52100

โทรศัพท์ 0 5423 7399 Email: sakchai@g.lpru.ac.th

^{1,2*}Faculty of Industry Technology Lampang Rajabhat University

³Faculty of Nursing Lampang Rajabhat University

119 Moo 9 Lampang-Mae Ta Road, Chompoo Subdistrict, Muang Lampang District, Lampang Province,
Thailand 52100 Tel. +665 4237 399 Email: sakchai@g.lpru.ac.th

วันที่รับบทความ 3 กันยายน 2567

วันที่รับแก้ไขบทความ 18 ธันวาคม 2567

วันที่ตอบรับบทความ 19 ธันวาคม 2567

Received: Sep. 3, 2024

Revised: Dec. 18, 2024

Accepted: Dec. 19, 2024

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบคัดแยกภาพถ่ายแผลกดทับที่สามารถทำนายระดับความรุนแรงของแผลได้อย่างแม่นยำ โดยการใช้ปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง ซึ่งคณะวิจัยได้ทำการสังเคราะห์และประมวลผลชุดข้อมูลภาพถ่ายแผลกดทับให้มีขนาด 224 x 224 พิกเซล ซึ่งเหมาะสมสำหรับการประยุกต์กับอัลกอริทึมในการเรียนรู้ของเครื่อง งานวิจัยนี้แบ่งออกเป็นสองส่วนหลัก ได้แก่ การจำแนกภาพ (Classification) เพื่อประเมินความรุนแรงของแผล และการแบ่งส่วนภาพ (Segmentation) เพื่อระบุพื้นที่เฉพาะส่วนที่เป็นแผล คณะวิจัยใช้การเรียนรู้เชิงลึกด้วยโมเดล YOLOv8 ในการวิเคราะห์ แบ่งรูปแบบของโมเดลเป็น 5 รูปแบบ คือ n, s, m, l, และ x ผลการวิจัยพบว่าโมเดลรูปแบบ YOLOv8x-cls และ YOLOv8s-cls มีความแม่นยำสูงสุดในการจำแนกภาพ โดยมีค่าความแม่นยำอยู่ที่ 0.8 สำหรับการแบ่งส่วนภาพ โมเดลรูปแบบ YOLOv8n-seg แสดงค่าความแม่นยำ (Precision) สูงสุดอยู่ที่ 0.682 ขณะที่โมเดล YOLOv8x-seg แสดงค่าการเรียกคืน (Recall) สูงสุดที่ 0.69 ผลการทดลองเหล่านี้ชี้ให้เห็นถึงประสิทธิภาพของโมเดล YOLOv8 ในการจัดการกับความซับซ้อนของภาพและจำแนกความรุนแรงของแผลได้อย่างแม่นยำ อย่างไรก็ตาม การวิจัยในอนาคตควรมุ่งเน้นไปที่การพัฒนาความแม่นยำของโมเดลเพิ่มเติม เพื่อเพิ่มประสิทธิภาพการใช้งานในบริบททางการแพทย์

คำสำคัญ: ภาพแผลกดทับ, ปัญญาประดิษฐ์, การเรียนรู้ของเครื่อง

Abstract

This study develops a system utilizing artificial intelligence and machine learning to accurately classify the severity of pressure injuries from images. We synthesized and processed a dataset of open-pressure injury images into 224 x 224-pixel dimensions suitable for machine learning algorithms. The research is divided into

two main components: image classification to assess wound severity and image segmentation to identify specific wound areas. We employed the YOLOv8 deep learning, which includes five variants: n, s, m, l, and x. Our findings indicate that the YOLOv8x-cls and YOLOv8s-cls models achieved the highest accuracy in image classification, with a value of 0.8. In terms of image segmentation, the YOLOv8n-seg model showed the highest accuracy, with a value of 0.682, while the YOLOv8x-seg model demonstrated the highest recall value of 0.69. These results highlight the effectiveness of the YOLOv8 models in handling image complexity and accurately classifying wound severity. Future research should focus on further improving model accuracy to enhance its application in medical settings.

Keywords: Pressure ulcer images, Artificial intelligence, Machine learning

1. บทนำ

แผลกดทับเป็นปัญหาสุขภาพที่พบบ่อยในผู้ป่วยที่มีข้อจำกัดในการเคลื่อนไหว เช่น ผู้ป่วยติดเตียง หรือผู้ป่วยที่มีการใช้เครื่องมือทางการแพทย์ที่กดทับบริเวณผิวหนัง ความเสียหายที่เกิดจากแรงกดทับที่ยาวนานสามารถนำไปสู่การพัฒนาแผลในระยะต่าง ๆ ซึ่งส่งผลกระทบต่อคุณภาพชีวิตของผู้ป่วย และเพิ่มภาระค่าใช้จ่ายในระบบสาธารณสุข การวินิจฉัยและการจำแนกระดับความรุนแรงของแผลกดทับจึงมีความสำคัญอย่างยิ่งในการวางแผนการรักษาที่เหมาะสม (Aldughayfiq et al., 2023; Lau et al., 2022)

การประเมินแผลกดทับในปัจจุบันส่วนใหญ่ยังคงพึ่งพาการสังเกตด้วยสายตาของบุคลากรทางการแพทย์ ซึ่งอาจก่อให้เกิดความคลาดเคลื่อนและความไม่สม่ำเสมอในการประเมินระหว่างบุคคล ด้วยเหตุนี้ เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) จึงได้รับการนำมาใช้เพื่อเพิ่มความแม่นยำและประสิทธิภาพในการประเมินแผลกดทับ โดยเฉพาะอย่างยิ่งการใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่สามารถวิเคราะห์ภาพถ่ายและจำแนกประเภทของแผลได้อย่างรวดเร็วและมีประสิทธิภาพ (Fergus et al., 2022; Kim et al., 2023)

งานวิจัยในอดีตได้มีการนำ AI มาใช้ในการจำแนกและประเมินแผลกดทับในหลายรูปแบบ ตัวอย่างเช่น งานวิจัยของ Aldughayfiq et al. (2023) ได้นำเสนอการใช้โมเดล YOLOv5 ในการตรวจจับและจำแนกแผลกดทับออกเป็น 4 ระยะ และแผลที่ไม่ใช่แผลกดทับ โดยผลการทดลองแสดงให้เห็นค่า mAP ที่ร้อยละ 76.9 ซึ่งแสดงถึงประสิทธิภาพในการประมวลผล อย่างไรก็ตาม งานวิจัยนี้ยังมีข้อจำกัดในด้านการปรับแต่งโมเดลสำหรับข้อมูลเฉพาะทาง เช่น การเพิ่มความหลากหลายของชุดข้อมูล และการปรับพารามิเตอร์เพิ่มเติม

นอกจากนี้ Lau et al. (2022) ได้พัฒนาแอปพลิเคชันบนสมาร์ตโฟนที่ใช้โมเดล YOLOv4 สำหรับการตรวจจับและจำแนกแผลกดทับแบบเรียลไทม์ โดยมีความแม่นยำในการทำนายร้อยละ 63.2 ซึ่งถึงแม้จะช่วยลดเวลาในการวินิจฉัย แต่ยังคงมีข้อจำกัดในด้านความแม่นยำเมื่อเทียบกับโมเดลที่ซับซ้อนกว่า เช่น YOLOv8 ที่ Kim et al. (2023) รายงานว่ามีความแม่นยำสูงถึงร้อยละ 84.6 ในการจำแนกแผลกดทับออกเป็น 6 ระยะ

งานวิจัยปัจจุบันจึงมุ่งเน้นไปที่การแก้ไขข้อจำกัดเหล่านี้ เช่น การเพิ่มความแม่นยำในการตรวจจับและจำแนกผล การขยายขอบเขตของชุดข้อมูล และการพัฒนาโมเดลที่สามารถรองรับข้อมูลขนาดใหญ่ได้อย่างมีประสิทธิภาพ โดยเฉพาะการใช้เทคโนโลยี YOLO ซึ่งมีข้อได้เปรียบในด้านการตรวจจับวัตถุอย่างรวดเร็วและแม่นยำ (Cicceri et al., 2022; Liu et al., 2023)

การพัฒนาระบบที่ผสมผสานเทคโนโลยี AI และ YOLO ไม่เพียงแต่ช่วยเพิ่มความแม่นยำในการประเมินผลกดทับ แต่ยังสนับสนุนการทำงานของบุคลากรทางการแพทย์ในการวางแผนการรักษา ลดความเสี่ยงจากภาวะแทรกซ้อน และเพิ่มคุณภาพชีวิตของผู้ป่วยในระยะยาว งานวิจัยนี้จึงมุ่งหวังที่จะพัฒนาระบบที่สามารถนำไปใช้ในทางปฏิบัติได้จริงและตอบโจทย์ความต้องการของวงการแพทย์ในยุคปัจจุบัน

2. วัตถุประสงค์ของการวิจัย


2.1 เพื่อวิเคราะห์ข้อมูลภาพถ่ายผลกดทับและสังเคราะห์ชุดข้อมูลที่เหมาะสมสำหรับพัฒนาระบบการคัดแยกภาพถ่ายผลกดทับ

2.2 เพื่อพัฒนาและประเมินประสิทธิภาพของอัลกอริทึมปัญญาประดิษฐ์ในการทำนายระดับความรุนแรงของผลกดทับ โดยวัดผลจากค่าการค้นพบ (Recall) ของโมเดลที่พัฒนา

3. วิธีดำเนินการวิจัย

3.1 กระบวนการทำงานของแบบจำลอง ขั้นตอนในการวิจัยเริ่มจากการใช้ชุดข้อมูล (Dataset) โดยเตรียมข้อมูลภาพ (Pre-Processing) เช่น การปรับขนาดภาพ การจัดรูปแบบไฟล์ จากนั้นแบ่งข้อมูลภาพ (Splitting) เป็น Training Set และ Test Set ในอัตราส่วน 80:20

จากนั้นทำการเรียนรู้แบบจำลอง 2 ประเภท คือ YOLO Classification และ YOLO Segmentation จากนั้นทำนายข้อมูลที่ใช้ทดสอบ (Test Set) และประเมินประสิทธิภาพแบบจำลอง (Model Evaluation) ดังแสดงในภาพที่ 1



ภาพที่ 1 ขั้นตอนการทำงานของแบบจำลอง

3.2 ชุดข้อมูลที่ใช้ในการศึกษา ในการวิจัยครั้งนี้ ชุดข้อมูล Pressure Injury Images Dataset (PIID) ถูกนำมาใช้เป็นฐานข้อมูลหลักสำหรับการพัฒนาและประเมินผลโมเดลการจำแนกระดับความรุนแรงของแผลกดทับ ชุดข้อมูล PIID ประกอบด้วยภาพสี RGB ทั้งหมด 1,091 ภาพ โดยแต่ละภาพมีขนาด 299×299 พิกเซล ภาพเหล่านี้ครอบคลุมทั้งสี่ระยะของแผลกดทับ ได้แก่ ระยะที่ 1 ผิวหนังยังสมบูรณ์แต่ผิวหนังมีรอยแดง เมื่อประเมินโดยใช้นิ้วกดเบา ๆ บริเวณผิวหนังแล้วรอยแดงนั้นไม่จางลง ระยะที่ 2 ผิวหนังมีการสูญเสีย โดยพื้นแผลแดงไม่มีเนื้อตายสีเหลือง ไม่เป็นรอยซ้ำ อาจเป็นตุ่มน้ำพอง น้ำใส ๆ หรือปนเลือดจาง ๆ ระยะที่ 3 มีการสูญเสียผิวหนังทั้งหมด แต่ยังไม่ถึงกล้ำเนื้อ เส้นเอ็นกระดูกและอาจมีเนื้อตายและระยะที่ 4 การสูญเสียผิวหนังทั้งหมดไปถึงชั้นกล้ามเนื้อ เส้นเอ็นและกระดูก อาจพบเนื้อตายสีเหลือง และหรือเนื้อตายสีดำแข็งมีโพรงใต้ผิวหนังและช่องใต้หรือคลำพบกระดูก ซึ่งแต่ละระยะถูกจำแนกตามลักษณะทางคลินิกที่แตกต่างกัน

ภาพที่ใช้ในชุดข้อมูลนี้ได้มาจากการถ่ายภาพคลินิกของผู้ป่วยที่มีแผลกดทับ ชุดข้อมูลได้รับการตรวจสอบและจัดป้ายกำกับโดยแพทย์ผู้เชี่ยวชาญ มีความถูกต้องและเป็นมาตรฐานสำหรับการใช้งานในงานวิจัยเชิงการแพทย์และการประยุกต์ใช้ด้านการเรียนรู้เชิงลึก ชุดข้อมูล PIID ถูกนำเสนอในงานวิจัยของ Ay et al. (2022) ในหัวข้อ "Deep transfer learning-based visual classification of pressure injuries stages" ที่ตีพิมพ์ในวารสาร Neural Computing and Applications เข้าถึงได้ที่ <https://github.com/FU-MedicalAI/PIID/>

3.3 การเตรียมรูปภาพในกระบวนการฝึกอบรม YOLO รูปภาพจะถูกปรับขนาดให้ตรงกับขนาดที่กำหนด เช่น 640×640 พิกเซล หรือขนาดอื่นที่ระบุในพารามิเตอร์ของการฝึกอบรม ขนาดที่ใช้ในการฝึกอบรมเป็นตัวกำหนดความละเอียดที่โมเดลจะเรียนรู้ โดยผู้วิจัยได้กำหนดขนาดรูปภาพที่ 224×224 พิกเซลและใช้เครื่องมือ TensorFlow และ PyTorch ในการจัดการข้อมูลและฝึกอบรมแบบจำลอง

3.4 การสร้างแบบจำลอง ในการสร้างแบบจำลองสำหรับการคัดแยกและจำแนกภาพถ่ายแผลกดทับ ผู้วิจัยได้ใช้เทคนิคการเรียนรู้เชิงลึกที่มีความสามารถสูง ซึ่งประกอบด้วย YOLO ในสองรูปแบบหลัก ได้แก่ YOLO แบบ Classification และ YOLO แบบ Segmentation โดยรายละเอียดการใช้แต่ละรูปแบบมีดังนี้

YOLO แบบ Classification ถูกนำมาใช้เพื่อการจำแนกประเภทของแผลกดทับในภาพ โดยเทคนิคนี้จะทำการประเมินระดับความรุนแรงของแผลจากข้อมูลภาพที่ป้อนเข้า ซึ่งเป็นการทำงานโดยตรงในการจัดกลุ่มภาพตามระดับความรุนแรงที่กำหนด เช่น ระดับความรุนแรงของแผลในคลาสที่แตกต่างกัน การใช้ YOLO แบบ Classification ช่วยให้สามารถทำการจำแนกประเภทแผลได้อย่างรวดเร็วและแม่นยำ โดยโมเดลจะเรียนรู้จากชุดข้อมูลที่มีการทำเครื่องหมายลักษณะของแผลและระดับความรุนแรงเพื่อให้สามารถให้ผลลัพธ์ที่มีความถูกต้องสูง

YOLO แบบ Segmentation ถูกใช้เพื่อแยกแยะพื้นที่ที่เป็นแผลกดทับออกจากพื้นที่ที่ไม่ใช่แผลในภาพ เทคนิคนี้จะช่วยในการแบ่งส่วนภาพ (Image Segmentation) โดยการทำให้เครื่องหมายแต่ละพิกเซลในภาพ เพื่อระบุว่าพิกเซลนั้นเป็นส่วนของแผลกดทับหรือไม่ การใช้ YOLO แบบ Segmentation ช่วยให้การประเมินลักษณะของแผลในภาพ มีความละเอียดสูงและแม่นยำมากขึ้น โดยสามารถแยกพื้นที่ของแผลออกจากบริเวณอื่น ๆ ของภาพได้อย่างชัดเจน ซึ่งเป็นประโยชน์

ในการวิเคราะห์และประเมินความรุนแรงของแผลได้อย่างถูกต้อง โดยการกำหนดพารามิเตอร์ ดังแสดงในตารางที่ 1

ตารางที่ 1 การกำหนดพารามิเตอร์สำหรับสร้างแบบจำลอง

พารามิเตอร์	ค่าที่กำหนด
การเริ่มการฝึก (Training Start)	100 epochs
การตั้งค่าตัวเพิ่มประสิทธิภาพ (Optimizer)	AdamW (lr=0.000714, momentum=0.9)
พารามิเตอร์ของตัวเพิ่มประสิทธิภาพ	50 weights (decay=0.0), 51 weights (decay=0.0005), 51 biases (decay=0.0)

ในการทดลองนี้ ชุดข้อมูลจะถูกแบ่งออกเป็นสองส่วนสำหรับการฝึกและการทดสอบ โดยใช้สัดส่วนร้อยละ 80 สำหรับชุดฝึก (Training Set) และร้อยละ 20 สำหรับชุดทดสอบ (Test set) ของภาพรวมชุดข้อมูลทั้งหมดประกอบด้วยภาพแผลกดทับ 950 ภาพ ซึ่งแยกตามระดับความรุนแรงของแผลเป็น 4 ระดับ ดังนี้ ระดับที่ 1:154 ภาพ, ระดับที่ 2:292 ภาพ, ระดับที่ 3:247 ภาพ และระดับที่ 4:257 ภาพ โดยข้อมูลทั้งหมดจะถูกแบ่งเป็นชุดฝึก 760 ภาพ และชุดทดสอบ 190 ภาพ ตามอัตราส่วนที่กำหนด

3.5 การประเมินผลแบบจำลอง ในการวัดประสิทธิภาพของโมเดล ใช้ตัวชี้วัดหลักสองตัว ได้แก่ Recall และ Precision รวมถึง Accuracy และ F1-Score ด้วย ตัวชี้วัดทั้งหมดนี้ช่วยในการประเมินความสามารถของโมเดลในการทำนายและแสดงให้เห็นถึงความถูกต้อง ในการจัดประเภทข้อมูลของโมเดลดังนี้

1) Accuracy วัดความถูกต้องโดยรวมของโมเดลในการทำนายทุกคลาส (บวกและลบ) ดังสมการที่ 1

$$\frac{\text{True Positive (TP)} + \text{True Negative (TN)}}{\text{True Positive (TP)} + \text{True Negative (TN)} + \text{False Positive (FP)} + \text{False Negative (FN)}} \quad (1)$$

เมื่อ True Positive (TP) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นบวก (เช่น มีแผลกดทับ) และจริง ๆ แล้วเป็นบวก (แผลกดทับ) ด้วย

True Negative (TN) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นลบ (เช่น ไม่มีแผลกดทับ) และจริง ๆ แล้วเป็นลบ (ไม่มีแผลกดทับ) ด้วย

False Positive (FP) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นบวก (เช่น มีแผลกดทับ) แต่จริง ๆ แล้วเป็นลบ (ไม่มีแผลกดทับ)

False Negative (FN) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นลบ (เช่น ไม่มีแผลกดทับ) แต่จริง ๆ แล้วเป็นบวก (มีแผลกดทับ)

2) Recall (True Positive Rate) วัดความสามารถของโมเดลในการตรวจจับตัวอย่างบวกทั้งหมด ซึ่งหมายถึงการระบุระดับความรุนแรงของแผลที่แท้จริงในชุดข้อมูลทดสอบ ดังสมการที่ 2

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (2)$$

เมื่อ True Positive (TP) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นบวก (เช่น มีแผลกดทับ) และจริง ๆ แล้วเป็นบวก (แผลกดทับ) ด้วย

False Negative (FN) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นลบ (เช่น ไม่มีแผลกดทับ) แต่จริง ๆ แล้วเป็นบวก (มีแผลกดทับ)

3) Precision (Positive Predictive Value) วัดความแม่นยำของโมเดลในการทำนายตัวอย่างบวกที่โมเดลระบุว่าเป็นแผลกดทับ ซึ่งหมายถึงความถูกต้องของการทำนายของโมเดลในระดับความรุนแรงของแผล ดังสมการที่ 3

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (3)$$

เมื่อ True Positive (TP) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นบวก (เช่น มีแผลกดทับ) และจริง ๆ แล้วเป็นบวก (แผลกดทับ) ด้วย

False Positive (FP) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นบวก (เช่น มีแผลกดทับ) แต่จริง ๆ แล้วเป็นลบ (ไม่มีแผลกดทับ)

4) F1-Score เป็นการรวม Recall และ Precision เพื่อให้ภาพรวมของความสมดุลระหว่างความแม่นยำและความสามารถในการตรวจจับ การใช้ F1-Score เป็นการรวม Recall และ Precision เข้าเป็นค่าเดียวเพื่อให้สะท้อนถึงความสามารถของโมเดลในการจัดการกับข้อมูลบวกทั้งสองด้านได้ดี โดยเฉพาะเมื่อมีการกระจายของคลาสไม่สมดุล ดังสมการที่ 4

$$F1 = \frac{2 * \text{True Positive}}{\text{True Positive} + 0.5(\text{False Positive} + \text{False Negative})} \quad (4)$$

เมื่อ True Positive (TP) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นบวก (เช่น มีแผลกดทับ) และจริง ๆ แล้วเป็นบวก (แผลกดทับ) ด้วย

False Positive (FP) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นบวก (เช่น มีแผลกดทับ) แต่จริง ๆ แล้วเป็นลบ (ไม่มีแผลกดทับ)

False Negative (FN) คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นลบ (เช่น ไม่มีแผลกดทับ) แต่จริง ๆ แล้วเป็นบวก (มีแผลกดทับ)

4. ผลการวิจัย

4.1 ผลการวิจัยที่ตอบวัตถุประสงค์ จากการศึกษาประสิทธิภาพของโมเดล YOLOv8 ในการจำแนกระดับความรุนแรงของแผลกดทับ พบว่าประสิทธิภาพของโมเดลแตกต่างกันไปตามขนาด (n, s, m, l, x) โดย YOLOv8x-cls และ YOLOv8s-cls มีค่า Accuracy และ F1-score สูงสุดที่ 0.8 ซึ่งแสดงถึงประสิทธิภาพสูงสุดในการจำแนกภาพ ส่วน YOLOv8n-cls ซึ่งเป็นรุ่นที่เล็กที่สุด มีค่า Accuracy อยู่ที่ 0.759 และค่า F1-score ที่ 0.8 แม้จะมีขนาดเล็ก แต่ยังคงสามารถจำแนกภาพได้ดี

โดยสรุป YOLOv8x-cls และ YOLOv8s-cls มีประสิทธิภาพสูงสุด ขณะที่ YOLOv8n-cls ยังคงมีความสามารถในการจำแนกได้ในระดับที่น่าพอใจ การเลือกใช้โมเดลขึ้นอยู่กับความต้องการด้านความเร็วและความแม่นยำของผลลัพธ์ ดังแสดงในตารางที่ 2

ตารางที่ 2 ผลประสิทธิภาพของโมเดลในการจำแนกตามขนาดของโมเดล (n, s, m, l, x)

Model	Classes	Accuracy	Precision	Recall	F1-score
YOLOv8n-cls	1	0.94	0.81	0.78	0.79
	2	0.88	0.85	0.82	0.84
	3	0.85	0.72	0.67	0.69
	4	0.90	0.76	0.86	0.81
All	4	0.76			
YOLOv8s- cls	1	0.95	0.77	0.87	0.82
	2	0.90	0.92	0.82	0.87
	3	0.67	0.67	0.70	0.69
	4	0.75	0.75	0.79	0.77
All	4	0.80			
YOLOv8m- cls	1	0.95	0.88	0.82	0.85
	2	0.90	0.83	0.89	0.86
	3	0.83	0.65	0.63	0.64
	4	0.87	0.76	0.77	0.78
All	4	0.79			
YOLOv8l- cls	1	0.94	0.85	0.79	0.82
	2	0.87	0.88	0.80	0.83
	3	0.84	0.58	0.67	0.62
	4	0.88	0.76	0.81	0.79
All	4	0.78			
YOLOv8x- cls	1	0.95	0.74	0.74	0.81
	2	0.90	0.91	0.91	0.86
	3	0.85	0.69	0.69	0.68
	4	0.89	0.76	0.76	0.8
All	4	0.80			

ในการศึกษาประสิทธิภาพของโมเดล YOLOv8 สำหรับการแบ่งส่วนภาพความรุนแรงของแผลกดทับ พบว่าประสิทธิภาพของโมเดลมีความแตกต่างตามขนาดของโมเดล (n, s, m, l, x) โดยการประเมินใช้ค่า Precision และ Recall เป็นตัวชี้วัดหลัก โดยโมเดล YOLOv8n-seg ซึ่งเป็นโมเดลขนาดเล็กที่สุด มีค่า Precision สูงสุดที่ 0.682 ซึ่งแสดงถึงความแม่นยำในการระบุพื้นที่แผลกดทับในภาพได้ดี แม้จะมีขนาดเล็กกว่ารุ่นอื่น ๆ สามารถแยกแยะพื้นที่แผลได้อย่างมีประสิทธิภาพ ในขณะที่ YOLOv8x-seg ซึ่งเป็นโมเดลที่ใหญ่ที่สุด มีค่า Recall สูงสุดที่ 0.69 ซึ่งบ่งบอกถึงความสามารถในการค้นพบและแบ่งส่วนพื้นที่แผลได้ครบถ้วน โมเดลนี้เหมาะสำหรับการจำแนกพื้นที่แผลที่มีขนาดใหญ่และรายละเอียดมาก

โดยรวมแล้ว โมเดล YOLOv8n-seg เหมาะสำหรับการใช้งานที่ต้องการความแม่นยำสูงในการระบุพื้นที่แผล ส่วน YOLOv8x-seg เหมาะสำหรับการใช้งานที่ต้องการการครอบคลุมพื้นที่แผล

อย่างละเอียด การเลือกใช้โมเดลจึงควรพิจารณาจากความต้องการเฉพาะของงานว่าต้องการเน้นที่ความแม่นยำหรือความครอบคลุมเป็นหลัก ดังแสดงในตารางที่ 3

ตารางที่ 3 ผลประสิทธิภาพของโมเดลในการแบ่งส่วนตามขนาดของโมเดล (n, s, m, l, x)


Model	Images	Classes	Instances	Precision	Recall	mAP50	mAP50-95
YOLOv8n-seg	218	1	78	0.482	0.423	0.463	0.243
		2	76	0.549	0.784	0.681	0.413
		3	51	0.598	0.824	0.689	0.533
		4	44	0.736	0.699	0.813	0.628
All	218	4	249	0.591	0.682	0.663	0.454
YOLOv8s-seg	218	1	78	0.460	0.372	0.442	0.228
		2	76	0.670	0.711	0.695	0.435
		3	51	0.572	0.667	0.701	0.532
		4	44	0.747	0.740	0.816	0.611
All	218	4	249	0.613	0.622	0.664	0.454
YOLOv8m-seg	218	1	78	0.487	0.747	0.449	0.245
		2	76	0.693	0.737	0.758	0.492
		3	51	0.530	0.745	0.666	0.526
		4	44	0.730	0.677	0.735	0.546
All	218	4	249	0.610	0.658	0.652	0.452
YOLOv8l-seg	218	1	78	0.480	0.532	0.467	0.225
		2	76	0.613	0.750	0.717	0.447
		3	51	0.526	0.745	0.663	0.488
		4	44	0.605	0.732	0.745	0.565
All	218	4	249	0.556	0.690	0.648	0.431
YOLOv8x-seg	218	1	78	0.597	0.410	0.474	0.246
		2	76	0.672	0.645	0.624	0.377
		3	51	0.625	0.667	0.664	0.500
		4	44	0.689	0.807	0.780	0.601
All	218	4	249	0.646	0.632	0.636	0.431

จากกราฟของโมเดล YOLOv8x-seg ที่แสดงการประเมินประสิทธิภาพของโมเดลในการแบ่งส่วนภาพความรุนแรงของแผลกดทับ พบว่าโมเดลมีความสามารถในการแบ่งส่วนได้ดีพอสมควร โดยในกราฟ F1-Confidence Curve ค่า F1-Score สูงสุดที่ 0.64 เมื่อความเชื่อมั่นอยู่ที่ 0.377 แสดงให้เห็นว่าโมเดลมีความแม่นยำในการแบ่งส่วนระดับที่ยอมรับได้ อย่างไรก็ตาม บางคลาสยังคงต้องปรับปรุง โดยเฉพาะคลาส 0 ซึ่งหมายถึงแผลกดทับระดับ 1

สำหรับกราฟ Precision-Confidence Curve โมเดลแสดงความแม่นยำสูงสุดที่ 1.00 เมื่อความเชื่อมั่นอยู่ที่ 0.990 ซึ่งบ่งบอกว่าความแม่นยำเพิ่มขึ้นตามความมั่นใจของโมเดล ขณะที่กราฟ Precision-Recall Curve แสดงค่า mAP@0.5 ที่ 0.656 ซึ่งสะท้อนความสมดุลระหว่างความแม่นยำและค่า Recall ในระดับปานกลาง

เส้นโค้งจากกราฟ Recall-Confidence Curve ในภาพที่ 2 แสดงถึงความสัมพันธ์ระหว่าง Recall และความเชื่อมั่น พบว่าเมื่อความเชื่อมั่นต่ำ โมเดลสามารถหาตัวอย่างแผลกดทับได้มากขึ้น

แต่มีโอกาที่จะเลือกตัวอย่างที่ไม่ใช่ผลกดทับมาด้วย อย่างไรก็ตาม เมื่อความเชื่อมั่นเพิ่มขึ้น โมเดลจะทำนายได้แม่นยำมากขึ้น แม้ว่า Recall อาจลดลงบ้างในบางกรณี ดังแสดงในภาพที่ 2



ภาพที่ 2 ประเมินประสิทธิภาพของโมเดล YOLOv8x-seg ในการแบ่งส่วนของระดับผลกดทับ

ในกระบวนการวิเคราะห์ประสิทธิภาพของโมเดล YOLOv8 สำหรับภาพถ่ายผลกดทับ ได้ทำการเปรียบเทียบการทำนายผลของโมเดลสองแบบ ได้แก่

- 1) YOLOv8x-cls สำหรับการจำแนกระดับความรุนแรงของผลกดทับ (Classification)
- 2) YOLOv8x-seg สำหรับการแบ่งส่วนภาพผลกดทับ (Segmentation)




โดยใช้ภาพถ่ายจำนวน 10 ภาพ ในการทดสอบการทำงานของโมเดลทั้งสองนี้ ในการนำเสนอผลการเปรียบเทียบระหว่างการวินิจฉัยของผู้เชี่ยวชาญ (พยาบาลวิชาชีพ) และการทำนายของโมเดล YOLOv8 ในสองส่วนนี้ ดังแสดงในตารางที่ 4 และตารางที่ 5

ตารางที่ 4 การเปรียบเทียบผลการจำแนกระดับความรุนแรงของแผลกดทับระหว่างผู้เชี่ยวชาญและโมเดล YOLOv8x-cls (Classification)

ลำดับที่	ภาพ	การวินิจฉัย ของผู้เชี่ยวชาญ	การทำนาย ของโมเดล	ผลลัพธ์
1		ระดับที่ 4	ระดับที่ 4	ถูกต้อง
2		ระดับที่ 4	ระดับที่ 4	ถูกต้อง
3		ระดับที่ 1	ระดับที่ 1	ถูกต้อง
4		ระดับที่ 3	ระดับที่ 3	ถูกต้อง
5		ระดับที่ 1	ระดับที่ 2	ผิดพลาด
6		ระดับที่ 3	ระดับที่ 4	ผิดพลาด
7		ระดับที่ 3	ระดับที่ 2	ผิดพลาด
8		ระดับที่ 3	ระดับที่ 3	ถูกต้อง
9		ระดับที่ 2	ระดับที่ 2	ถูกต้อง
10		ระดับที่ 4	ระดับที่ 4	ถูกต้อง

จากตารางที่ 4 พบว่าโมเดล YOLOv8x-cls ทำนายผลได้ถูกต้อง 7 ภาพจากทั้งหมด 10 ภาพ คิดเป็นความแม่นยำประมาณร้อยละ 70 โดยมี 3 ภาพที่โมเดลทำนายผิดพลาด ซึ่งได้แก่ ภาพที่ 5, 6 และภาพที่ 7 โดยระดับความรุนแรงของแผลที่โมเดลทำนายไม่ตรงกับการวินิจฉัยของผู้เชี่ยวชาญ

ตารางที่ 5 การเปรียบเทียบผลการแบ่งส่วนภาพผลกดทับระหว่างผู้เชี่ยวชาญและโมเดล YOLOv8x-seg (Segmentation)

ลำดับที่	ภาพ	การวินิจฉัย ของผู้เชี่ยวชาญ	การทำนาย ของโมเดล	ผลลัพธ์
1		ระดับที่ 1	ระดับที่ 1	ถูกต้อง
2		ระดับที่ 3	ระดับที่ 3	ถูกต้อง
3		ระดับที่ 2	ระดับที่ 3	ผิดพลาด
4		ระดับที่ 2	ระดับที่ 3	ผิดพลาด
5		ระดับที่ 3	ระดับที่ 3	ถูกต้อง
6		ระดับที่ 4	ระดับที่ 4	ถูกต้อง
7		ระดับที่ 4	ระดับที่ 3	ผิดพลาด
8		ระดับที่ 4	ระดับที่ 4	ถูกต้อง
9		ระดับที่ 4	ระดับที่ 3	ผิดพลาด
10		ระดับที่ 4	ระดับที่ 4	ถูกต้อง

จากตารางที่ 5 พบว่าโมเดล YOLOv8x-seg ทำนายผลได้ถูกต้อง 6 ภาพจากทั้งหมด 10 ภาพ คิดเป็นความแม่นยำประมาณร้อยละ 60 โดยมี 4 ภาพที่โมเดลทำนายผิดพลาด ได้แก่ ภาพที่ 3, 4, 7 และภาพที่ 9 ซึ่งระดับความรุนแรงของแผลที่โมเดลทำนายไม่ตรงกับการวินิจฉัยของผู้เชี่ยวชาญ

5. สรุปผลและการอภิปรายผล

5.1 สรุปผลตามวัตถุประสงค์ การศึกษาประสิทธิภาพของโมเดล YOLOv8 สำหรับการแบ่งส่วนภาพความรุนแรงของแผลกดทับ ได้แสดงให้เห็นว่ามีความแตกต่างในประสิทธิภาพของโมเดลตามขนาด (n, s, m, l, x) โดยมีค่า Precision และ Recall ที่โดดเด่นในบางรุ่น โมเดล YOLOv8n-seg ซึ่งเป็นรุ่นขนาดเล็กที่สุด มีค่า Precision สูงสุดที่ 0.682 ซึ่งบ่งบอกถึงความแม่นยำในการระบุพื้นที่แผลกดทับ ในขณะที่ YOLOv8x-seg ซึ่งเป็นโมเดลขนาดใหญ่ที่สุด มีค่า Recall สูงสุดที่ 0.69 แสดงถึงความสามารถในการค้นพบพื้นที่แผลได้อย่างครอบคลุม อย่างไรก็ตาม ผลลัพธ์ความถูกต้องโดยรวมยังไม่สูงมากนัก ซึ่งอาจเกิดจากข้อจำกัดของชุดข้อมูลหรือความซับซ้อนในลักษณะของแผล

ในการเปรียบเทียบผลระหว่างการวินิจฉัยของผู้เชี่ยวชาญและการทำนายของโมเดล YOLOv8 พบว่าโมเดล YOLOv8x-cls ทำนายผลได้ถูกต้อง 7 ภาพจากทั้งหมด 10 ภาพ คิดเป็นความแม่นยำประมาณร้อยละ 70 และโมเดล YOLOv8x-seg ทำนายผลได้ถูกต้อง 6 ภาพจากทั้งหมด 10 ภาพ คิดเป็นความแม่นยำประมาณร้อยละ 60

5.2 อภิปรายผลตามวัตถุประสงค์ ผลการศึกษาประสิทธิภาพของโมเดล YOLOv8 แสดงให้เห็นถึงความแตกต่างที่สำคัญตามขนาดของโมเดลในด้าน Precision และ Recall การเลือกใช้โมเดลขนาดเล็ก เช่น YOLOv8n-seg เหมาะสำหรับงานที่เน้นความแม่นยำสูงในการระบุพื้นที่แผล แม้ว่าโมเดลนี้ จะมีความสามารถในการจำแนกที่ดี แต่ก็มีข้อจำกัดในด้านความครอบคลุมพื้นที่แผลที่มีขนาดใหญ่ และรายละเอียดซับซ้อน

ในทางกลับกัน YOLOv8x-seg ซึ่งเป็นโมเดลที่ใหญ่ที่สุด แสดงให้เห็นถึงความสามารถในการครอบคลุมพื้นที่แผลได้ดีขึ้น แต่มีค่า Precision ต่ำกว่า YOLOv8n-seg การมีค่า Recall สูงสุดที่ 0.69 หมายความว่า YOLOv8x-seg มีความสามารถในการค้นพบพื้นที่แผลทั้งหมดได้ดี แต่ไม่สามารถระบุพื้นที่แผลที่ถูกต้องทุกครั้ง

ดังนั้น การเลือกใช้โมเดลควรพิจารณาจากความต้องการเฉพาะของงาน หากต้องการความแม่นยำในการระบุพื้นที่แผล ควรเลือกโมเดลที่มี Precision สูง เช่น YOLOv8n-seg แต่หากต้องการความครอบคลุมพื้นที่แผลอย่างครบถ้วน ควรพิจารณาใช้ YOLOv8x-seg การศึกษานี้จึงเป็นแนวทางในการเลือกโมเดลที่เหมาะสมตามวัตถุประสงค์และข้อกำหนดของงานแต่ละประเภท

6. ข้อเสนอแนะ

เนื่องจากงานวิจัยนี้เป็นการศึกษากระบวนการคัดแยกภาพถ่ายระดับความรุนแรงของแผลกดทับด้วยปัญญาประดิษฐ์ โดยได้เลือกโมเดล YOLOv8 เพียงแบบเดียวเท่านั้น จึงอาจทำให้ผลการทดสอบประสิทธิภาพจำกัดอยู่ในขอบเขตของโมเดลนี้เพียงอย่างเดียว ข้อเสนอแนะสำหรับการวิจัยในอนาคตคือควรมีการศึกษารูปแบบของกระบวนการคัดแยกภาพถ่ายระดับความรุนแรงของแผลกดทับที่หลากหลายขึ้น เช่น การเปรียบเทียบโมเดลที่แตกต่างกัน หรือการใช้เทคนิคการเรียนรู้เชิงลึกแบบอื่น เช่น Transformer Models หรือ U-Net ซึ่งอาจช่วยเพิ่มประสิทธิภาพในการคัดแยกภาพถ่ายได้อย่างถูกต้องและแม่นยำมากขึ้น

นอกจากนี้ เพื่อการนำไปใช้งานจริงในบริบททางการแพทย์ ควรพัฒนาส่วนติดต่อผู้ใช้ (User Interface) ที่สามารถทำงานร่วมกับบุคลากรทางการแพทย์ โดยทำหน้าที่เป็นเครื่องมือสนับสนุน

การตัดสินใจในการวินิจฉัยและการรักษาแผลกดทับ ซึ่งจะช่วยให้เพิ่มความแม่นยำ ลดเวลาในการวินิจฉัย และลดความเสี่ยงในการรักษาที่ผิดพลาด การพัฒนาในลักษณะนี้จะช่วยให้ระบบที่พัฒนามีความเหมาะสม และมีประสิทธิภาพมากขึ้นในการใช้งานจริง

7. กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนอุดหนุนงบประมาณปี 2566 จากกองทุนวิจัย มหาวิทยาลัยราชภัฏลำปาง

8. เอกสารอ้างอิง

- Aldughayfiq, B., Ashfaq, F., Jhanjhi, N. Z., & Humayun, M. (2023). YOLO-Based Deep Learning Model for Pressure Ulcer Detection and Classification. *Healthcare*, 11(9), 1222. [online], Available: <https://doi.org/10.3390/healthcare11091222>.
- Ay, B., Tasar, B., & Utlu, Z. et al. (2022). *Deep transfer learning-based visual classification of pressure injuries stages*. *Neural Computing and Applications* 34, 16157–16168 (2022). [online], Available: <https://doi.org/10.1007/s00521-022-07274-6>.
- Brown, L., & Lee, S. (2023). Using YOLO for Medical Image Classification: A Case Study on Pressure Ulcers. *Artificial Intelligence in Medicine*, 44(3), 210-221. [online], Available: <https://doi.org/10.1016/j.artmed.2023.210221>.
- Chen, H.} & Li, Q. (2022). Segmentation and Classification of Pressure Ulcers Using Deep Convolutional Networks. *International Journal of Computer Assisted Radiology and Surgery*, 17(1), 123-135. [online], Available: <https://doi.org/10.1007/s11548-022-02345-x>.
- Cicceri, G., Bruna, S., & Foti, D. (2022). Deep learning approach based on superpixel segmentation assisted by wearable inertial sensors for pressure ulcer prevention. *PLOS ONE*, 17(2), e0264139. [online], Available: <https://doi.org/10.1371/journal.pone.0264139>.
- Fergus, P., Hussain, A., Al-Jumeily, D., & Abdel-Aziz, K. (2022). Pressure Ulcer Categorisation using Deep Learning: A Clinical Trial to Evaluate Model Performance. *arXiv preprint arXiv:2203.06248*. [online], Available: <https://arxiv.org/abs/2203.06248>.
- Kim, T., Park, J., & Choi, Y. (2023). Diagnosis of Pressure Ulcer Stage Using On-Device AI. *Applied Sciences*, 14(16), 7124. [online], Available: <https://doi.org/10.3390/app14167124>.
- Lau, C. H., Yu, K. H. O., Yip, T. F., Luk, L. Y. F., Wai, A. K. C., Sit, T. Y., Wong, J. Y. H., & Ho, J. W. K. (2022). An artificial intelligence-enabled smartphone app for real-

- time pressure injury assessment. *Frontiers in Medical Technology*, 4, 905074. [online], Available: <https://doi.org/10.3389/fmedt.2022.905074>.
- Liu, Y., Zhao, X., & Wang, H. (2023). Advancing Medical Image Analysis with YOLOv5 and YOLOv4: Applications in Pressure Ulcer Assessment. *IEEE Access*, 11, 34567-34578. [online], Available: <https://doi.org/10.1109/ACCESS.2023.3456789>.
- Singh, A., & Reddy, K. (2023). Pressure Ulcer Classification Using Deep Learning Techniques: A Comprehensive Review. *Journal of Medical Imaging and Health Informatics*, 13(6), 2305-2318. [online], Available: <https://doi.org/10.1166/jmihi.2023.230523>.
- Zhang, L., & Wu, D. (2023). Integration of YOLOv5 for Enhanced Pressure Ulcer Classification in Clinical Settings. *Journal of Biomedical Engineering*, 45(7), 567-580. [online], Available: <https://doi.org/10.1016/j.jbiomech.2023.567580>.