

การตรวจจับความรุนแรงของแผลไหม้โดยใช้โมเดลการแบ่งส่วน: การเปรียบเทียบระหว่าง U-NET และ YOLOv8

Burn Wound Severity Detection using Segmentation Model: A Comparative Study Between U-NET and YOLOv8

ขวัญกมล ดิฐกัญจน์¹, สรวิตญ์ หนูคง^{1,*}

Kwankamon Dittakan¹, Sorawit Nookong^{1,*}

¹ วิทยาลัยการคอมพิวเตอร์ มหาวิทยาลัยสงขลานครินทร์ วิทยาเขตภูเก็ต ภูเก็ต 83120 ประเทศไทย

¹ College of Computing, Prince of Songkla University, Phuket Campus, Phuket 83210, Thailand

* Corresponding Author: Sorawit Nookong, s6330611015@phuket.psu.ac.th

Received:

12 December 2023

Revised:

30 January 2024

Accepted:

2 April 2024

คำสำคัญ:

ผิวหนังไหม้, แผลไหม้, การตรวจจับความรุนแรงของผิวหนังไหม้, การวิเคราะห์ภาพ, U-Net, การเรียนรู้เชิงลึก

Keywords:

Skin burn, Burn wound, Skin burn severity detection, Image analytics, U-Net, Deep Learning

บทคัดย่อ การตรวจจับความรุนแรงแผลไหม้ โดยใช้วิธีการทำการตรวจจับพื้นที่ที่สนใจ โดยมีการแบ่งพื้นที่ของแผลไหม้ออกเป็นสามระดับที่แตกต่างกัน: (i) แผลไหม้ระดับที่หนึ่ง (ii) แผลไหม้ระดับที่สอง และ (iii) แผลไหม้ระดับที่สาม ซึ่งแต่ละระดับจะมีลักษณะของแผลไหม้แตกต่างกัน เพื่อต้องการตรวจจับความรุนแรงแผลไหม้ จึงมีการนำเทคโนโลยีปัญญาประดิษฐ์ (AI) มาใช้ในการสร้างโมเดลปัญญาประดิษฐ์ นั่นคือโมเดล U-Net และ YOLOv8 ซึ่งจะมีชุดข้อมูลภาพที่เป็นภาพแผลไหม้ทั้งหมด 2,000 รูปภาพ และมีรูปภาพแผลไหม้ทั้งสามระดับ เนื่องจากต้องการที่จะเปรียบเทียบประสิทธิภาพระหว่าง U-Net ที่เป็นโมเดลยอดนิยมที่ใช้ในการตรวจจับพื้นที่ที่สนใจ กับ YOLOv8 ที่เป็นโมเดลที่พัฒนามาในปี 2023 ซึ่งเป็นโมเดลมาใหม่เมื่อไม่นานมานี้ โดยผลลัพธ์ในการทดลองของ U-Net และ YOLOv8 พบว่าผลลัพธ์ที่ดีที่สุดของ U-Net มีความแม่นยำสูงถึง 79.1% และมีค่าสูญเสีย 79.8% ส่วน YOLOv8 มีผลลัพธ์ที่ดีที่สุดคือ ค่า mAP 0.5 ดีที่สุดเท่ากับ 0.657 และมีค่าสูญเสียของการแบ่งภาพอยู่ที่ 3.231 และค่าความสูญเสียของการทำนายคลาสอยู่ที่ 1.961 ซึ่งเป็นผลลัพธ์ที่ดีที่สุดของทั้งสองโมเดล

ABSTRACT: This research focuses on detecting burn severity using an area of interest detection approach. The burn areas are categorized into three levels: (i) first-degree burns, (ii) second-degree burns, and (iii) third-degree burns, each with distinct visual characteristics. To detect burn severity, artificial intelligence (AI) techniques were applied through the development of two models: U-Net and YOLOv8. A dataset of 2,000 images

representing all three levels of burns was used in the experiments. The goal was to compare the performance of U-Net, a widely used model for segmenting areas of interest, with YOLOv8, a newer model introduced in 2023. Experimental results show that the best performance of U-Net achieved an accuracy of 79.1% and a loss value of 79.8%. In contrast, YOLOv8 achieved its best result with an mAP@0.5 of 0.657, a segmentation loss of 3.231, and a classification loss of 1.961. These results represent the optimal performance of both models in this study.

1. บทนำ

อาการบาดเจ็บจากไฟไหม้เป็นปัญหาด้านสาธารณสุขที่สำคัญ และมีผลกระทบอย่างมากต่อบุคคลทั่วโลกซึ่งอาจจะเกิดขึ้นเมื่อผิวโดนความร้อน เช่น แผลไหม้ที่เกิดจากเปลวไฟหรือการสัมผัสกับสารเคมีอันตราย แผลไหม้แบบฉับพลัน สัมผัสกับวัตถุร้อน น้ำมันกระเด็น น้ำร้อนลวก หรือการสัมผัสกับกระแสไฟฟ้า (Toussaint *et al.*, 2014) และจากรายงานขององค์การอนามัยโลก (World Health Organization: WHO) จากการสำรวจขององค์การอนามัยโลก (WHO) ในแต่ละปีมีผู้ป่วยเกือบ 11 ล้านคนได้รับบาดเจ็บจากแผลไหม้ โดยในจำนวนนี้ 180,000 คน เป็นจำนวนยอดผู้เสียชีวิตเนื่องจากบาดเจ็บดังกล่าว การที่มีจำนวนผู้ป่วยที่ต้องเผชิญกับการบาดเจ็บจากแผลไหม้มากขนาดนี้ส่งผลให้เป็นปัญหาสาธารณสุขที่ต้องรับมืออย่างจริงจัง (Markiewicz-Gospodarek *et al.*, 2022) และปัญหาที่ตามมาที่เกิดจากแผลไหม้หากนำส่งหรือผู้ป่วยได้รับการจัดการที่ไม่ดี จะส่งผลให้ผู้ป่วยได้รับการรักษาล่าช้า อาจเกิดผลกระทบต่ออาการทางจิต และอาการปวดเรื้อรัง และอาการบาดเจ็บจากแผลไหม้ เป็นสาเหตุอันดับที่สี่ของอาการบาดเจ็บทั่วโลก (Kotecha *et al.*, 2022) กล่าวได้ว่า

การรักษาผู้ป่วยแผลไหม้นั้น จำเป็นที่จะต้องใช้ประสบการณ์ทางการแพทย์ ซึ่งแพทย์แต่ละท่านนั้นมีการตีความหรือวินิจฉัยแตกต่างกัน (Connolly & Gangahar, 2021) การรักษาผู้ป่วยจากแผลไหม้นั้นเกี่ยวข้องกับความเสี่ยงทางการแพทย์ที่มีความแตกต่างกันไปตามลักษณะของแผลไหม้และความรุนแรงของการบาดเจ็บ แต่ความหลากหลายนี้บางครั้งทำให้การรักษาล่าช้า และในบางกรณีอาจส่งผลต่อผลลัพธ์ของการรักษา ทำให้จำเป็นต้องมีการพัฒนาวิธีการที่มีประสิทธิภาพในการจัดการและรักษาผู้ป่วยจากแผลไหม้

ในปัจจุบันการก้าวหน้าทางเทคโนโลยีได้สร้างโอกาสที่ยิ่งใหญ่ในการประยุกต์ใช้ปัญญาประดิษฐ์ในหลายด้านของชีวิตประจำวัน ซึ่งส่งผลให้ปัญญาประดิษฐ์เข้ามามีส่วนช่วยในด้านต่างๆ รวมไปถึงการแพทย์ เนื่องจากปัญญาประดิษฐ์สามารถให้การตัดสินใจทางการแพทย์ที่มีประสิทธิภาพ และปัญญาประดิษฐ์มีความสามารถที่จะประมวลผลข้อมูลขนาดใหญ่และทำความเข้าใจรูปภาพ ข้อความ และข้อมูลทางการแพทย์อื่นๆ อย่างมีประสิทธิภาพ เพื่อใช้ในการรักษาผู้ป่วย (Haleem *et al.*, 2019) และการใช้งานปัญญาประดิษฐ์เกี่ยวกับอุปกรณ์ทางการแพทย์เพิ่มขึ้นเป็นอย่างมาก และเชื่อว่าเทคโนโลยีปัญญาประดิษฐ์จะเข้ามามีส่วนช่วยทางการแพทย์เพิ่มมากขึ้น และมีการปรับปรุงปัญญาประดิษฐ์อย่างต่อเนื่องเพื่อช่วยเหลือผู้ป่วย (Hamamoto *et al.*, 2020; Chang *et al.*, 2021) ในด้านการแพทย์ ปัญญาประดิษฐ์ถูกนำมาใช้เพื่อช่วยในการวินิจฉัย การรักษา และการดูแลผู้ป่วย การตัดสินใจทางการแพทย์ที่เร็วและแม่นยำมีผลในการรักษาที่มีประสิทธิภาพและลดความเสี่ยง ปัญญาประดิษฐ์ยังช่วยในการวิเคราะห์ข้อมูลที่ซับซ้อน เช่น ภาพจากรังสีเอกซเรย์ การตรวจจีโนม จากรูปภาพทางการแพทย์ และการจัดการประวัติแพทย์ของผู้ป่วย (Naqvi *et al.*, 2023; Pandya *et al.*, 2019) ในเชิงทางการแพทย์แผลไหม้ปัญญาประดิษฐ์ได้เข้ามามีบทบาทสำคัญในการช่วยในการ

วินิจฉัยและการดูแลผู้ป่วย มีการพัฒนาโมเดลปัญญาประดิษฐ์ที่สามารถตรวจจับและประเมินความรุนแรงของแผลไหม้อย่างมีประสิทธิภาพ นี้ช่วยลดภาระงานของแพทย์และเพิ่มความแม่นยำในการประเมิน (Moura *et al.*, 2021; Tail *et al.*, 2023) เพื่อให้ปัญญาประดิษฐ์ในการแพทย์มีประสิทธิภาพมากขึ้น การวิจัยและพัฒนาต่อยอดในด้านนี้มีความสำคัญ นักวิจัยจึงดำเนินการเพื่อปรับปรุงปัญญาประดิษฐ์ที่มีอัลกอริทึมที่ทันสมัยและมีประสิทธิภาพในการให้บริการด้านการแพทย์ นอกจากนี้ การแสดงผลที่ชัดเจนและการทดสอบความเสถียรของโมเดลปัญญาประดิษฐ์ก็เป็นสิ่งสำคัญ

งานวิจัยนี้มุ่งเน้นการพัฒนาโมเดลปัญญาประดิษฐ์โดยมีการประยุกต์ใช้การตรวจจับพื้นที่ (Segmentation) เพื่อตรวจจับแผลไหม้ในระดับที่หลากหลาย คือ (i) แผลไหม้ระดับที่หนึ่ง (ii) แผลไหม้ระดับที่สอง (iii) แผลไหม้ระดับที่สาม เพื่อช่วยให้การประเมินแผลไหม้เป็นไปอย่างถูกต้องและมีประสิทธิภาพมากยิ่งขึ้น ด้วยวิธีนี้เราหวังว่าจะมีผลการวิจัยที่สามารถนำไปใช้ในการดูแลผู้ป่วยประสพภัยจากแผลไหม้ได้อย่างเหมาะสมและทันทั่วทั้งการพัฒนาโมเดลปัญญาประดิษฐ์ที่มีประสิทธิภาพในการตรวจจับแผลไหม้จะเป็นปัจจัยสำคัญในการลดภาระงานของแพทย์ ทำให้การรักษามีประสิทธิภาพมากขึ้น และลดความเสี่ยงต่อผู้ป่วยจากภาวะแทรกซ้อนที่อาจเกิดขึ้น

ส่วนที่เหลือของบทความนี้มีการนำเสนอต่อต่อไปนี้ รายละเอียดของงานวิจัยก่อนหน้าหรือเกี่ยวข้องกับงานวิจัยที่นำเสนอในบทความนี้นำเสนอในหัวข้อที่ 2 รายละเอียดของกรอบการดำเนินงานวิจัยได้แสดงในหัวข้อที่ 3 หัวข้อที่ 4 นำเสนอรายละเอียดของการเก็บรวบรวมข้อมูล หัวข้อที่ 5 แสดงรายละเอียดของการเตรียมความพร้อมของภาพก่อนที่จะนำไปในการพัฒนาโมเดล การลาเบลรูปภาพเพื่อใช้สำหรับการพัฒนาโมเดลได้นำเสนอในหัวข้อที่ 6 หัวข้อที่ 7 นำเสนอการพัฒนาโมเดลปัญญาประดิษฐ์ด้วยโครงข่าย

ประสาทเทียมแบบสังวัตนาการ หัวข้อที่ 8 ได้นำเสนอผลการทดลองและประเมินผล และสุดท้ายหัวข้อที่ 9 นำเสนอการอภิปรายและสรุปผล

2. งานวิจัยที่เกี่ยวข้อง

ในงานวิจัยของ Cirillo *et al.* (2021) ได้สาธิตถึงประสิทธิภาพของปัญญาประดิษฐ์ (Artificial Intelligence: AI) โดยใช้โครงข่ายประสาทเทียมชนิด Convolutional Neural Network (CNN) แบบ U-Net ในการประเมินความลึกของแผลไหม้ด้วยการใช้การแบ่งส่วนค่านำของภาพจากกล้องแสงโพลาไรซ์ความสามารถสูงของแผลไหม้ โดยมุ่งเน้นในการแยกแยะลึกของแผลไหม้ในเด็กที่ได้รับการทำลายจากน้ำร้อน เพื่อแยกแยะระดับของแผลไหม้เป็น 4 ระดับ: 1) Superficial partial-thickness (รักษาภายใน 0–7 วัน) 2) Superficial to intermediate partial-thickness (รักษาภายใน 8–13 วัน) 3) Intermediate to deep partial-thickness (รักษาภายใน 14–20 วัน) 4) Deep partial-thickness (รักษาหลัง 21 วัน) และ 5) แผลไหม้ทั้งหมด (full-thickness burns) โดยอิงจากเวลาการหายของแผลที่สังเกตได้รวมทั้ง 100 รูปภาพแผลไหม้ได้รับการเก็บรวบรวม 17 รูปภาพที่มีทุก 4 ระดับของแผลไหม้ถูกนำไปใช้ในการเรียนรู้โครงข่าย และสร้างรายงาน leave-one-out cross-validation ซึ่งได้ผลความแม่นยำและ dice coefficient โดยเฉลี่ยเกือบ 97% จากนั้น 83 รูปภาพแผลไหม้ที่เหลือถูกประเมินโดยใช้โครงข่ายในขั้นตอน cross-validation และได้ค่าความแม่นยำและ dice coefficient โดยเฉลี่ยทั้งคู่ที่ประมาณ 92% เทคนิคนี้แนะนำเสนอทางเลือกใหม่ที่น่าสนใจสำหรับการสนับสนุนการตัดสินใจทางคลินิกในการประเมินและระบุความลึกของแผลไหม้ในภาพดิจิทัล 2 มิติ การเรียนรู้เพิ่มเติมและการปรับปรุงอัลกอริทึมในฐานะพื้นฐานเพิ่มเติมด้วยรูปภาพที่มีจำนวนมากอาจเป็นไปได้และดังนั้นเป็นที่น่าสนใจสำหรับอนาคต

ในงานวิจัย Chang *et al.* (2021) เน้นที่การประเมินขนาดของแผลไหม้ด้วยการใช้ร้อยละของพื้นที่ผิวหนังรวมของร่างกาย (%TBSA) เป็นจุดสำคัญในการจัดการผู้ป่วยที่ได้รับการเผาไหม้ การต้องการของของน้ำทำลายและโภชนาการของผู้ป่วย, ความจำเป็นในการดูแลรักษาที่หน่วยดูแลระดับสูง และความเป็นไปได้ของการเสียชีวิตมีความเชื่อมโยงตรงต่อ %TBSA (percent of total body surface area) การประมาณการพื้นที่แผลที่มีรูปร่างไม่ปกติด้วยการสังเกตเป็นเรื่องที่ทำหาย มีหลายบทความรายงานถึงความไม่เที่ยงตรงในการประมาณ %TBSA โดยแพทย์ที่แตกต่างกัน ในขั้นตอนแรก, ใช้กระบวนการ 2 ขั้นตอนเพื่อแปลงการวินิจฉัยแผลไหม้เป็น %TBSA รูปภาพของแผลไหม้ถูกเก็บรวบรวมจากบันทึกการแพทย์และได้รับการป้ายชื่อจากแพทย์ผู้เชี่ยวชาญทางการแพทย์ ชุดข้อมูลจากนั้นถูกนำไปใน 2 โครงสร้างการเรียนรู้เชิงลึกคือ U-Net และ Mask R-CNN ทั้งสองมีการกำหนดค่าด้วย backbones 2 แบบต่างๆ เพื่อแยกแผลไหม้ ในขั้นตอนที่สอง สร้างชุดข้อมูลอีกครั้งจากรูปภาพของมือและได้ทำการป้ายชื่อเช่นเดียวกัน ข้อมูลนี้ถูกนำไปใน U-Net และ Mask R-CNN เพื่อแบ่งส่วนมือ จากนั้น %TBSA ของแผลไหม้ถูกคำนวณโดยเปรียบเทียบพิกเซลของพื้นที่มาร์คบนรูปภาพของแผลไหม้และมือของผู้ป่วยตามกฎของมือที่ระบุว่ามือหนึ่งเท่ากับ 0.8% ของ %TBSA มีการรวบรวมรวมทั้งหมด 2591 รูปภาพของแผลไหม้และมีการป้ายชื่อเพื่อสร้างชุดข้อมูลแผลไหม้ ชุดข้อมูลถูกแบ่งเป็นชุดฝึก ชุดตรวจสอบ, และชุดทดสอบอย่างสุ่มในอัตราส่วน 8:1:1 นอกจากนี้ได้รวบรวมภาพมือ 400 รูปที่ป้ายชื่อเพื่อสร้างชุดข้อมูลมือ ซึ่งถูกแบ่งเป็น 3 ชุดโดยใช้วิธีเดียวกัน สำหรับรูปภาพของแผลไหม้ Mask R-CNN ด้วย ResNet101 ได้ผลลัพธ์การแบ่งส่วนที่ดีที่สุดด้วย Dice coefficient (DC) ที่ 0.9496, ในขณะที่ U-Net ด้วย ResNet101 มี DC ที่ 0.8545 สำหรับรูปภาพมือ, U-Net และ Mask R-CNN มีประสิทธิภาพที่เทียบเท่ากันด้วยค่า DC ที่ 0.9920

และ 0.9910 ตามลำดับ ในทางสุดท้าย, ทดสอบการวินิจฉัยในผู้ป่วยที่ได้รับการเผาไหม้, Mask R-CNN ด้วย ResNet101 มีค่าเฉลี่ยของการหลุด (deviation) จากค่าจริงน้อยกว่า (0.115% TBSA) เมื่อเปรียบเทียบกับแพทย์ผู้เชี่ยวชาญทางการแพทย์

งานวิจัยของ Jiao *et al.* (2019) มุ่งเน้นการพัฒนาวิธีการวินิจฉัยบาดแผลไหม้ที่เป็นอันตรายต่อชีวิตและมีโอกาสทำให้เกิดภาวะเจริญเติบโตขึ้นโดยการใช้เทคโนโลยีการเรียนรู้เชิงลึกเพื่อช่วยในการประเมินพื้นที่และความลึกของบาดแผลไหม้อย่างแม่นยำ วิธีปัจจุบันเช่นวัดด้วยไม้บรรทัดตรง (straight-ruler method) วิธีตัดฟิล์มแอสป์เทิร์ม (aseptic film trimming method) และวิธีถ่ายรูปด้วยกล้องดิจิทัลมีปัญหาในการทำซ้ำและเปรียบเทียบได้น้อย ทำให้มีความแตกต่างมากในการประเมินบาดแผลไหม้ และทำให้ยากต่อการกำหนดเกณฑ์การประเมินที่เหมือนกันในการลดผลกระทบจากความผิดพลาดของมนุษย์และเพิ่มความแม่นยำในการวินิจฉัย งานวิจัยนี้นำเทคโนโลยีการเรียนรู้เชิงลึกมาช่วยในกระบวนการวินิจฉัยบาดแผลไหม้โดยใช้โครงข่ายพินหลัง R101FA ซึ่งได้ผลลัพธ์ที่แม่นยำสูงสุดที่ 84.51% ใน 150 รูปภาพ การใช้โครงข่ายนี้ยังแสดงผลลัพธ์ที่ดีในการแบ่งส่วนของบาดแผลไหม้ในระดับต่างๆ เช่น การแบ่งส่วนที่เป็นบาดแผลที่ผิวเป็น บาดแผลที่ผิวเป็นทึบ และบาดแผลที่ลึกบางส่วน โครงข่ายการเรียนรู้เชิงลึกนี้แสดงให้เห็นถึงความแม่นยำในการแบ่งส่วนของบาดแผลไหม้และมีความทนทานมากในบาดแผลที่ลึกต่างๆ ทั้งนี้โครงข่ายนี้ต้องการภาพบาดแผลที่เหมาะสมเพียงอย่างเดียวในการวิเคราะห์ ทำให้สะดวกและเหมาะสมมากขึ้นเมื่อนำไปใช้ในคลินิกเทียบ

งานวิจัยของ (Wang *et al.* (2020) เสนอโมเดลพื้นฐานในการแยกส่วนของแผลเป็นโครงสร้างที่เบาและไม่ใช้ทรัพยากรคำนวณมากนัก โดยใช้โครงสร้าง MobileNetV2 และ connected component

labelling (CCL) เพื่อทำ segmentation ของพื้นที่แผลจากรูปภาพธรรมชาติ ความสามารถในการทำงานของโมเดลนี้ไม่ถูกทำลายและเทียบเท่ากับโมเดลที่ลึกขึ้นการทำงานนี้สามารถช่วยในการวินิจฉัยและรักษาแผลได้ดียิ่งขึ้น โดยการให้ข้อมูลเชิงปริมาณเกี่ยวกับพื้นที่ของแผลและพารามิเตอร์ที่จำเป็นในการรักษาทำให้สามารถลดความผิดพลาดที่อาจเกิดขึ้นจากขาดความเชี่ยวชาญการทดลองทั้งหมดได้ถูกดำเนินการในช่วงของ SegNet, VGG16, U-Net, Mask-RCNN และโมเดลที่พัฒนาขึ้นโดยใช้ MobileNetV2 และ CCL เพื่อประเมินประสิทธิภาพในการแยกส่วนของแผลโรคเรื้อรัง โมเดลที่พัฒนาขึ้นแสดงให้เห็นถึงประสิทธิภาพและคล่องตัวในการทำ segmentation ของภาพเนื่องจากมีโครงสร้างที่เป็นทั้งพื้นฐานและสามารถทำงานได้ดีในสาขาการทำ segmentation รูปภาพในอนาคตผู้วิจัยมีแผนที่จะพัฒนางานต่อไปโดยใช้โมเดล multi-stream neural network ที่สกัดลักษณะรูปที่แตกต่างจากการสกัดค่า convolution ที่แตกต่างกันในโมเดลปัจจุบัน โดยในอนาคต การพัฒนาโมเดลที่ลึกขึ้นจะถูกทดสอบในชุดข้อมูลที่พวกเขาสร้างขึ้น และความสามารถในการใช้งานกับอุปกรณ์เคลื่อนที่และการคำนวณบนมือถือจะเป็นไปได้ ทั้งนี้ การเพิ่มข้อมูลในชุดข้อมูลเพื่อเสถียรภาพและความแม่นยำในการพยากรณ์ของวิธีการจะเป็นแนวทางการวิจัยในอนาคต

งานวิจัยของ Liang *et al.* (2022) ได้นำเสนอโมเดล Spiking Neural Networks (SNNs) ที่มีพื้นฐานบน Retinal Ganglion Cells (RGC) เพื่อการ Segmentation ของรูปภาพการไหม้ (burn) และพื้นที่ที่ไม่ไหม้ โดยมีการใช้โมดูลที่มีโครงสร้าง Cross-layer Skip Concatenation เพื่อเพิ่มประสิทธิภาพในการทำงาน ผลลัพธ์จากการทดลองแสดงให้เห็นว่าความแม่นยำของโมเดลมีค่า pixel accuracy ที่ถึง 92.89% โดยที่พารามิเตอร์ของโมเดลมีขนาดเพียง 16.6 Mbytes เท่านั้น นอกจากนี้ยังมีความสามารถในการทำงานกับการประมวลผลที่

ต่ำกว่าของ hardware บนขอบ (edge hardware) ซึ่งทำให้เหมาะสมสำหรับการนำโมเดลไปใช้ในสิ่งที่ขอบ (edge) ได้งานวิจัยนี้มีความสำคัญในด้านการรักษาผู้ป่วยไหม้ เนื่องจากการคำนวณปริมาณน้ำที่ต้องให้ผู้ป่วยไหม้ในระยะแรก จำเป็นต้องพิจารณาพื้นที่ที่ไหม้เทียบกับพื้นที่ผิวรวมของร่างกาย (Total Body Surface Area - TBSA%) อย่างถูกต้อง ซึ่งการใช้ CNNs ในงานนี้มีข้อจำกัดในด้านทรัพยากรคอมพิวเตอร์บนขอบ จึงทำให้ SNNs ที่พัฒนาขึ้นเป็นตัวเลือกที่ดี เนื่องจากมีประสิทธิภาพสูงและสามารถทำงานได้ดีกับทรัพยากรที่มีขนาดเล็กในงานวิจัยข้างต้นได้สร้างข้อมูลภาพใหม่และนำเสนอโมเดลที่มีประสิทธิภาพสูงในการแบ่งแยกพื้นที่ไหม้และพื้นที่ปกติ โดยมีความพยายามที่จะทำให้โมเดลมีขนาดเล็ก และทำงานได้ดีกับ hardware บนขอบเพื่อให้สามารถนำไปใช้ในอุปกรณ์ที่มีขนาดเล็กและมีต้นทุนต่ำ นอกจากนี้ยังมีแผนการที่จะพัฒนาอุปกรณ์พกพาที่สามารถใช้โมเดลในการช่วยในการวินิจฉัยพื้นที่ไหม้ ในงานวิจัยข้างต้นได้รับการยอมรับอย่างแพร่หลายและมีบทบาทที่สำคัญในกระบวนการวินิจฉัยทั้งหมดของการรักษาผู้ป่วยที่ไหม้ ในอนาคตจะมีการพัฒนาต่อยอดโดยพิจารณาวิธีการเร่งความเร็วในกระบวนการเรียนรู้ (training) และใช้เทคนิคต่างๆ เพื่อทำให้โมเดลมีขนาดเล็กยิ่งขึ้น เพื่อให้เหมาะสมกับการใช้งานบน hardware ที่มีขนาดเล็กยิ่งขึ้น และยังมีแผนที่จะพัฒนาอุปกรณ์พกพาที่สามารถนำโมเดลไปใช้ในการวินิจฉัยพื้นที่ไหม้ได้อย่างสะดวก

งานวิจัยของ Chauhan & Goyal (2021) ได้นำเสนอวิธีการที่ใช้โครงข่ายประสาทเทียม (CNN) เพื่อทำการ Segmentation ของพื้นที่ที่ได้รับการเผาไหม้ในภาพสี โดยใช้ชุดข้อมูลภาพที่เตรียมไว้ล่วงหน้า ผลลัพธ์ที่ได้มีประสิทธิภาพที่สูงเมื่อเทียบกับวิธีการที่มีอยู่แล้ว ด้วยค่า Mathews correlation coefficient (MCC) ที่ถึง 77.6% และความแม่นยำที่ 93.4% ซึ่งมีการปรับปรุงขึ้นถึง 11.6/5.8/6.9/1.2% ในความแม่นยำของ precision, Dice similarity

coefficient, Jaccard index และ specificity เมื่อเทียบกับประสิทธิภาพที่ดีที่สุดที่สองผลลัพธ์จากการทดลองแสดงให้เห็นถึงประสิทธิภาพของวิธีการที่เสนอเมื่อเทียบกับวิธีที่มีอยู่แล้ว นอกจากนี้ วิธีการ Segment ระดับพิกเซลที่เสนอยังสามารถช่วยในการประเมินพื้นที่ผิวที่ได้รับการเผาไหม้และความรุนแรงของการเผาไหม้ได้อย่างแม่นยำและมีประสิทธิภาพที่ดีในเวลาที่รวดเร็ว

งานวิจัยของ Ameli *et al.* (2023) ในงานวิจัยนี้ได้รวบรวมรูปภาพที่มีการกักร่อนจากระบบโครงสร้างสะพานทั้งหมด 514 รูป ที่มีความรุนแรงของการกักร่อนต่างๆ และทำการปิดประกาศที่ละพิกเซลบนแต่ละรูปภาพ โดยการปิดประกาศนี้ถูกแบ่งเป็นสามหมวดหลักคือ “Fair”, “Poor”, และ “Severe” โดยกระบวนการปิดประกาศนี้ได้ปฏิบัติตามคำแนะนำที่ระบุในคู่มือของผู้ตรวจสอบสะพาน (BIRM) และกฎระเบียบของสมาคมทางหลวงและขนส่งรัฐ (AASHTO) สำหรับการกักร่อน (defect #1000) การปิดประกาศที่ระดับพิกเซลนี้ทำให้สามารถนำขั้นตอนการประเมินสภาพการกักร่อนโดยตรงไปใช้ในการประเมินสภาพการกักร่อนในทางปฏิบัติได้ เส้นทางรูปภาพที่รวบรวมและปิดประกาศที่เกี่ยวข้องสามารถพบออนไลน์และนำมาให้การสนับสนุนที่มีประโยชน์ในการพัฒนาโมเดล segmentation โดยการให้รูปภาพคุณภาพสูงและปิดประกาศที่เกี่ยวข้อง สองอัลกอริทึม segmentation ที่ทันสมัย Mask RCNN และ YOLOv8 ถูกเลือกและฝึกฝนบนชุดข้อมูลที่ได้ปิดประกาศเพื่อทำ segmentation ระดับพิกเซลและการจัดอันดับสภาพการกักร่อน กระบวนการฝึกนี้ได้รวมถึงการปรับพารามิเตอร์หลายประการเพื่อให้ได้น้ำหนักที่ดีที่สุดของเลเยอร์คอนโวลูชันสำหรับการประเมินความรุนแรงของการกักร่อนที่แม่นยำและเชื่อถือได้ โมเดล Mask RCNN และ YOLOv8 ที่ได้ฝึกฝนได้รับค่า mAP50 ที่ 0.674 และ 0.726 บนรูปภาพทดสอบ ซึ่งเป็นสัญญาณที่ว่า

โมเดลสามารถทำ segmentation โดยให้ค่าความแม่นยำที่มีระดับมีเหตุอยู่ (IoU = 50%) ผลลัพธ์เหล่านี้แสดงให้เห็นถึงประสิทธิภาพของ Mask RCNN และ YOLOv8 ที่ถูกฝึกฝนในการทำ segmentation และการจัดอันดับของการกักร่อน

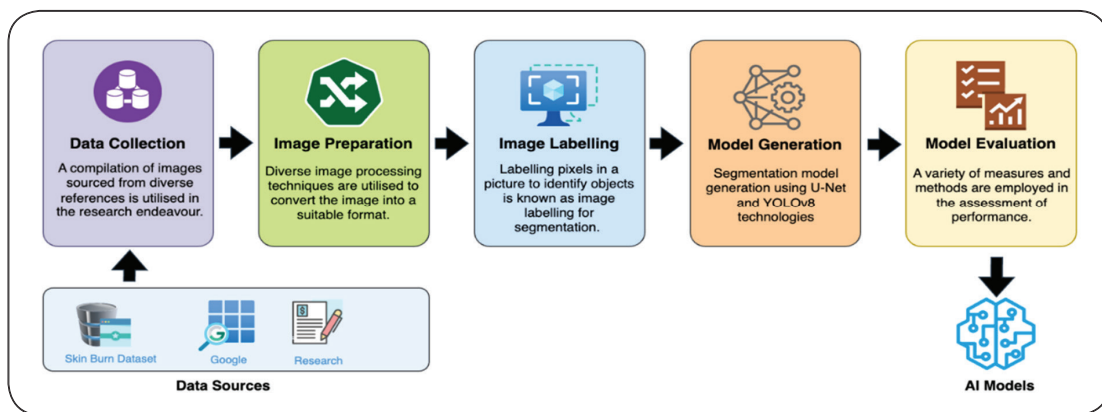
งานวิจัยของ Che *et al.* (2023) ได้นำเสนอการทำ segmentation รูปภาพได้น้ำหนักกับปัญหาที่ซับซ้อน เช่น ประเภทเป้าหมาย จำนวน ขนาด และการบดบังจากสิ่งแวดล้อม วิธี segmentation ที่พึ่งพาการปิดประกาศมือถือและความเชี่ยวชาญมากมาย มีความแม่นยำและประสิทธิภาพต่ำ จึงเลือกใช้วิธี segmentation รูปภาพที่พึ่งพา deep learning บน YOLOv8 โดยเพิ่มโมดูล adaptive self-supervised learning (Convnext V2), lightweight network (Slim Neck), และ dynamic sparse attention mechanism (Biformer) เพื่อปรับปรุง YOLOv8 สำหรับ segmentation ระดับเดียวของเป้าหมาย ได้น้ำหนักที่แตกต่าง โมดูล Convnext V2 นำเข้าหน่วย global response normalization (GRN) เพื่อเสริมความแข็งแกร่งของลักษณะและลดการคำนวณของโมเดล นอกจากนี้ นี่ยังออกแบบ slim neck network ที่ประสิทธิภาพสูง ด้วย dense convolution ใน lightweight convolution module (GSConv) และ cross-level network structure (VoV-GSCSP) การนำเข้า dynamic sparse attention mechanism ของ Biformer ทำให้ได้การจัดสรรการคำนวณที่ยืดหยุ่นและการรับรู้เนื้อหาที่มีประสิทธิภาพมากขึ้น การทดลองเปรียบเทียบแสดงว่า อัลกอริทึมที่ปรับปรุงเพิ่มประสิทธิภาพในการทำ segmentation ทำให้เพิ่มความเร็วของ segmentation และปรับปรุงความแม่นยำบน dual-target dataset mAP ปรับปรุงขึ้น 3.5% จาก 0.753 เป็น 0.779 และ FPS ปรับปรุงขึ้น 86% จาก 63 เป็น 117 การทดลองยืนยันว่า อัลกอริทึมที่ปรับปรุงนี้สามารถใช้สำหรับ segmentation รูปภาพ ได้น้ำหนักที่แตกต่างได้อย่างมีประสิทธิภาพ

งานวิจัยของ Liszka & Sofie (2023) ในงานวิจัยนี้สำรวจความเป็นไปได้ของการใช้โมเดล computer vision เช่น YOLO และ U-Net ในการตรวจจับและแบ่งแยกต้นไม้ที่ปลูกใหม่ในพื้นที่ที่ถูกตัดล้าง เรายังเปรียบเทียบประสิทธิภาพของโมเดลทั้งสองกับและโดยไม่เพิ่มข้อมูลเพื่อดูว่าการปรับปรุงโมเดลได้ดีขึ้นหรือไม่ รูปภาพ RGB และ RGB-D ถูกเก็บรวบรวมโดยใช้กล้องสเตอริโอ ZED 2i stereo มีโมเดลทั้งสองที่น่าเสนอ โดยหนึ่งในการตรวจจับต้นไม้ในภาพ RGB ที่ถ่ายจากมุมมองด้านบนและอีกหนึ่งในการแบ่งแยกลำต้นต้นไม้จากรูปภาพ RGB-D ที่ถ่ายจากมุมมองด้านข้าง จุดประสงค์ของงานวิจัยนี้คือเพื่อให้สามารถใช้โมเดลในการประเมินการปลูกต้นไม้ใหม่เพื่อให้สามารถทำการปลูกต้นไม้อัตโนมัติได้ผลลัพธ์ของงานวิจัยนี้แสดงให้เห็นว่า YOLOv8s มีศักยภาพที่ดีในการตรวจจับต้นไม้จากมุมมองด้านบนและโมเดล YOLOv8s-seg ในการแบ่งแยกลำต้นต้นไม้โมเดล YOLOv8s-seg ทำงานได้ดีมากขึ้นในการแบ่งแยกลำต้นเมื่อเทียบกับโมเดล U-Net งานวิจัยนี้นำเสนอข้อมูลที่เกี่ยวข้องกับการใช้ computer vision ในการปลูกต้นไม้ที่มีประสิทธิภาพและทำได้ในทางนิเวศที่มีความรับผิดชอบ ซึ่งเป็นการเปลี่ยนรูปแบบของการบริหารจัดการที่ยั่งยืนในอนาคต

3. กรอบการดำเนินงานวิจัย

ในหัวข้อนี้แสดงขั้นตอนวิธีการดำเนินงานวิจัย การตรวจจับความรุนแรงแผลไหม้ ขั้นตอนการดำเนินงานวิจัยประกอบด้วย 5 ขั้นตอนดังนี้ (i) การเก็บรวบรวมข้อมูล (Data Collection) (ii) การประมวลผลภาพ (Image Processing) (iii) การระบุประเภทข้อมูล (Data Labelling) (iv) การสร้างโมเดลปัญญาประดิษฐ์สำหรับการตรวจจับความรุนแรงแผลไหม้ (Model Generation) (v) การประเมินประสิทธิภาพของโมเดลปัญญาประดิษฐ์ (Evaluation) ซึ่งสามารถแสดงดังภาพประกอบ 1

จากแผนภาพการดำเนินงานวิจัย ดังภาพประกอบ 1 เริ่มต้นด้วยขั้นตอนที่ 1 การเก็บรวบรวมข้อมูลเป็นขั้นตอนแรก ในงานวิจัยนี้นั้นมีการรวมชุดข้อมูลสองชุดข้อมูลเข้าด้วยกัน คือ ชุดข้อมูลที่รวบรวมจาก Kaggle ซึ่งเป็นชุดข้อมูลสาธารณะ ซึ่ง Kaggle เป็นเว็บไซต์ที่นักวิจัยหรือผู้ที่ต้องการพัฒนาโปรแกรมเข้ามาแลกเปลี่ยนความรู้ ข้อมูลและเครื่องมือที่เกี่ยวข้อง และชุดข้อมูลที่รวบรวมด้วยตนเองจาก Google ซึ่งเป็นรูปภาพแผลไหม้ระดับความรุนแรงต่างๆ จากการค้นหาด้วยคำต่างๆ ที่เกี่ยวข้องกับแผลไหม้ โดยรายละเอียดของการเก็บรวบรวมข้อมูลนั้นแสดงไว้ในหัวข้อที่ 4



ภาพประกอบ 1 กรอบการดำเนินงานวิจัยของการตรวจจับความรุนแรงของแผลไหม้

การเตรียมความพร้อมของภาพ เนื่องจากในงานวิจัยนี้มีการเก็บข้อมูลมาจากหลายแหล่งบน Google ร่วมกับข้อมูลจาก Kaggle ทำให้ข้อมูลที่ได้เก็บรวบรวมมา มีรูปแบบที่ไม่เหมือนกัน ทั้งรูปแบบของภาพ ขนาดของภาพ ทำให้ต้องมีการเตรียมความพร้อมของภาพเสียก่อน จึงจะนำไปประมวลผลในขั้นต่อไปได้ ซึ่งในงานวิจัยนี้ภาพแต่ละภาพต้องมีการเปลี่ยนนามสกุลของรูปภาพ และมีการปรับมาตราส่วนของรูปภาพ เพื่อให้ชุดข้อมูลเหมาะสมแก่การนำไปตรวจหาระดับความรุนแรงแผลไหม้ตนเอง รายละเอียดของ เมื่อมีการเตรียมความพร้อมของภาพไปแล้ว ก่อนที่จะนำภาพไปใช้ในการสร้างโมเดล จำเป็นต้องมีการเตรียมไฟล์กำกับพื้นที่บริเวณที่สนใจ เพื่อนำข้อมูลไปเป็นชุดข้อมูลนำเข้าในการเรียนรู้ของโมเดลปัญญาประดิษฐ์ ซึ่งการระบุประเภทข้อมูลนั้น จะเป็นการระบุว่าภาพแผลไหม้ในรูปนั้นเป็นภาพแผลไหม้ระดับความรุนแรงระดับใด

การสร้างโมเดลปัญญาประดิษฐ์ในงานวิจัยนี้ มีการสร้างและพัฒนาโมเดลปัญญาประดิษฐ์ในการตรวจจับความรุนแรงแผลไหม้ ซึ่งใช้ชุดข้อมูลที่รวบรวมมาเป็นข้อมูลนำเข้าในการเรียนรู้โมเดลปัญญาประดิษฐ์ จากนั้นโมเดลจะระบุความรุนแรงของแผลไหม้ โดยในงานวิจัยนี้จะมีการประยุกต์ใช้การเรียนรู้เชิงลึก 2 วิธี ได้แก่ U-Net และ YOLOv8 เพื่อใช้เป็นอัลกอริทึมในการพัฒนาโมเดลดังกล่าว และก่อนที่จะนำโมเดลปัญญาประดิษฐ์ไปใช้ได้นั้น ต้องมีการประเมินประสิทธิภาพ เนื่องจากในงานวิจัยนี้เป็นการเปรียบเทียบเพื่อหาว่าโมเดลปัญญาประดิษฐ์ใดที่ตรวจจับความรุนแรงแผลไหม้ได้ดีกว่า จึงทำให้ขั้นตอนนี้เป็นขั้นตอนสุดท้ายหลังจากการสร้างโมเดลและพัฒนาเสร็จเรียบร้อยแล้ว และมีการประเมินประสิทธิภาพ

ของโมเดลในการตรวจจับแผลไหม้ และนำมาเปรียบเทียบประสิทธิภาพ

4. การเก็บรวบรวมข้อมูล

ในหัวข้อนี้แสดงรายละเอียดของการเก็บรวบรวมชุดข้อมูลที่จะนำมาใช้ในงานวิจัยนี้ ข้อมูลทั้งหมดที่ใช้ในงานวิจัยนี้จะมีจำนวน 2,000 ภาพ ซึ่งมีการเก็บรวบรวมมาจาก 2 แหล่ง ได้แก่ (i) ข้อมูลสาธารณะ (Open Data), (ii) ข้อมูลจาก Google และ (iii) ข้อมูลจากงานวิจัย โดยรายละเอียดของการรวบรวมนั้นจะแสดงไว้ในหัวข้อย่อยที่ 4.1 ถึงหัวข้อย่อยที่ 4.3 ตามลำดับ

4.1 ข้อมูลสาธารณะ (Open Data)

ข้อมูลภาพจำนวน 1,300 ภาพได้ทำการดาวน์โหลดจากแหล่ง ข้อมูลสาธารณะ kaggle.com โดยข้อมูลชุดนี้ได้เก็บข้อมูลรูปภาพที่มีแผลไหม้มาจากผู้ที่ได้รับแผลไหม้แบบต่างๆ ซึ่งชื่อของชุดข้อมูลดังกล่าวมีชื่อว่า Skin Burn Dataset¹ โดยชุดข้อมูลจะประกอบไปด้วยรูปภาพที่มีระดับความรุนแรงของแผลไหม้ในระดับต่างๆ โดย และจะมีป้ายกำกับอยู่ในรูปแบบของ YOLO โดยจะมีคลาส 0, 1, และ 2 ซึ่งแสดงถึงการไหม้ระดับหนึ่ง การไหม้ระดับสอง และการไหม้ระดับสามตามลำดับ โดยตัวอย่างของภาพที่มาจาก Skin Burn Dataset นั้น สามารถแสดงได้ดังภาพประกอบ 2


4.2 ข้อมูลจาก Google

ข้อมูลภาพจำนวน 650 ภาพ ได้ถูกรวบรวมเพิ่มเติมจากการค้นหาค้นหาบน Google.com โดยจะมีคำสำคัญที่ใช้ในค้นหาเกี่ยวข้องกับ แผลไหม้ เพราะถ้าหากค้นหาแผลไหม้ตรงๆ ข้อมูลรูปภาพแผลไหม้

¹ <https://www.kaggle.com/datasets/shubhambaid/skin-burn-dataset>

ที่ได้จะไปตรงกับรูปภาพแผลไหม้จากข้อมูลสาธารณะเป็นจำนวนมาก โดย Key word ในการรวบรวมข้อมูลรูปภาพแผลไหม้ ได้แก่ Chemical burn, Sun burn, Skin burn form falling, Burn form hot water, Skin burn from ice และ Skin burn from chemical เป็นต้น แต่เนื่องด้วยข้อมูลที่คั่นหานั้นมีจำกัด นอกจากจะทำการคั่นหาด้วยภาษาภาษาอังกฤษแล้วก็ยังมีการคั่นหาด้วยภาษาต่างๆ กัน ตัวอย่างเช่น ภาษาเกาหลี

ภาษาญี่ปุ่น ภาษาจีน ภาษายูเครน และภาษาฝรั่งเศส เข้ามาช่วยในการรวบรวมข้อมูลรูปภาพแผลไหม้ เพื่อช่วยในการรวบรวมข้อมูล คำสำคัญในการคั่นหาของแต่ละภาษาสามารถสรุปได้ดังตาราง 1 ต่อไปนี้ และสามารถแสดงตัวอย่างของภาพที่ได้จาก Google ได้ภาพประกอบ 3



ภาพประกอบ 2 ตัวอย่างข้อมูลภาพจาก Skin Burn Dataset

ตาราง 1 ตัวอย่างของคำสำคัญที่ใช้ในการคั่นหา


ภาษา	คำสำคัญที่ใช้ในการ Search
อังกฤษ	Chemical burn, Sun burn, Skin burn form falling, Burn form hot water, Skin burn from ice และ Skin burn from chemical
ญี่ปุ่น	化学火傷、日焼け、転倒による皮膚火傷、熱湯による火傷、氷による皮膚火傷 และ 化学物質による皮膚火傷
จีน	化學燒傷、曬傷、掉落皮膚燒傷、熱水燒傷、冰燒傷皮膚 และ 化學燒傷皮膚
ยูเครน	Хімічний опік, Сонячний опік, Опік шкіри від падіння, Опік від гарячої води, Опік шкіри від льоду และ Опік шкіри від хімічних речовин
ฝรั่งเศส	Brûlure chimique, Coup de soleil, Brûlure cutanée due à une chute, Brûlure causée par l'eau chaude, Brûlure cutanée causée par la glace และ Brûlure cutanée causée par un produit chimique
เกาหลี	화학화상, 일광화상, 낙하로 인한 화상, 뜨거운 물에 의한 화상, 얼음으로 인한 화상, 화학물질로 인한 화상



ภาพประกอบ 3 ตัวอย่างข้อมูลภาพจาก Google



(Suha & Sanam, 2022)



(Tran et al., 2016)



(Pabitha & Vanathi, 2020)

ภาพประกอบ 4 ตัวอย่างข้อมูลภาพจากงานวิจัย

4.3 ข้อมูลจากงานวิจัยที่เกี่ยวข้อง

ข้อมูลภาพจำนวน 50 ภาพ ได้ใช้วิธีการรวบรวมข้อมูลรูปภาพแปลใหม่จะทำได้โดยการตัดภาพจากงานวิจัยที่เกี่ยวข้อง (Suha & Sanam, 2022; Tran et al., 2016; Şevik evik et al., 2019; Pabitha & Vanathi, 2020) ซึ่งสามารถแสดงตัวอย่างของภาพที่ได้จาก Google ได้ภาพประกอบ 4

5. การเตรียมความพร้อมของภาพ

หัวข้อนี้แนะนำเสนอการเตรียมความพร้อมของภาพก่อนที่จะนำไปใช้ในการสร้างโมเดลปัญญาประดิษฐ์ ทั้งนี้ดังที่กล่าวมาแล้วในหัวข้อที่ 4 ข้อมูลที่ใช้ในการวิจัยมีการรวบรวมมาจากหลายวิธี ทำให้ข้อมูลเนื่องจากข้อมูลที่ได้มาจากการรวบรวมชุดข้อมูลเพื่อใช้ในการวิจัยนั้น เป็นการรวบรวมข้อมูลมาจากหลายแหล่ง ทำให้ข้อมูลที่ได้มานั้นไม่มี

ความสอดคล้องกันเช่น รูปแบบของภาพ และขนาดของภาพไม่เหมือนกัน จึงต้องมีกระบวนการเตรียมความพร้อมของข้อมูล โดยหัวข้อย่อยที่ 5.1 นำเสนอการแปลงรูปแบบรูปภาพ และหัวข้อย่อยที่ 5.2 นำเสนอการปรับมาตราส่วนของภาพ

5.1 การแปลงรูปแบบรูปภาพ

จากที่กล่าวไปแล้วก่อนหน้านี้ว่า ชุดข้อมูลที่ได้รวบรวมมาจากหลายแหล่งและมีไฟล์ที่มีนามสกุลต่างกัน เช่น PNG, JPEG, JPG, JFIF, BMP, AVIF และ HTML Document ในการประมวลผลภาพถ่ายและจัดหมวดหมู่ประเภทข้อมูล จำเป็นต้องมีภาพถ่ายที่มีความละเอียดสูงในระดับพิกเซล และเพื่อให้ง่ายต่อการนำไปใช้ในการพัฒนาโมเดลปัญญาประดิษฐ์ต่อไป จึงมีการเปลี่ยนนามสกุลไฟล์เป็น .TIF เนื่องจากไฟล์ .TIF เป็นที่รู้จักดีในเรื่องความละเอียดที่เหนือกว่า ทำให้สามารถจัดเก็บข้อมูลรูปภาพได้ในปริมาณ

Algorithm 1: File Format Transformation

```
function convertToTIFRecursive(currentFolder):  
  for each file in listFiles(currentFolder):  
    if isDirectory(file):  
      convertToTIFRecursive(file)  
    else:  
      fileExtension = getFileExtension(file)  
      if isImageFile(fileExtension) or  
        isHTMLDocument(fileExtension):  
        convertToTIF(file)  
      endif  
    endif  
  end for  
end
```

Algorithm 2: File Name Converter

```
function FilenamesConverter(currentFolder):  
  FileNo = 1  
  for each file in listFiles(currentFolder):  
    if isDirectory(file):  
      FilenamesConverter(file)  
    else:  
      newFilename = genFilename(file, FileNo)  
      renameFile(file, newFilename)  
      FileNo = FileNo + 1  
    endif  
  end for  
end
```

ที่มากขึ้นเมื่อเปรียบเทียบกับรูปแบบอื่น นอกจากนี้ การเปลี่ยนแปลงนี้ยังนำไปสู่การเพิ่มขนาดข้อมูล อันเป็นผลมาจากความละเอียดของภาพที่ปรับปรุงแล้ว กระบวนการแปลงรูปแบบข้อมูลภาพ สามารถแสดงได้ดังขั้นตอนวิธีที่ 1 ต่อไปนี้

จากขั้นตอนวิธีที่ 1 สามารถสรุปฟังก์ชันต่างๆ ได้ดังต่อไปนี้ (i) isDirectory(path) เป็นฟังก์ชันใช้ตรวจสอบว่า path ที่กำหนดให้เป็นไดเรกทอรีหรือไม่ (ii) listFiles(folder) เป็นฟังก์ชันที่ทำหน้าที่แสดงรายการของไฟล์ที่อยู่ใน folder ที่กำหนด

(iii) getFileExtension(filePath) เป็นฟังก์ชันที่ใช้ดึงนามสกุลของไฟล์จาก filePath ที่กำหนด (iv) isImageFile(fileExtension) เป็นฟังก์ชันที่ใช้ตรวจสอบว่านามสกุลของไฟล์ที่กำหนดสอดคล้องกับรูปภาพหรือไม่ (v) isHTMLDocument(fileExtension) เป็นฟังก์ชันที่ใช้ตรวจสอบว่านามสกุลของไฟล์ที่กำหนดสอดคล้องกับเอกสาร HTML หรือไม่ (vi) convertToTIF(inputFilePath) เป็นฟังก์ชันที่ใช้ดำเนินการแปลงไฟล์ที่กำหนดให้เป็นไฟล์ TIF

5.2 การเปลี่ยนชื่อรูปภาพ

เนื่องจากการพัฒนาโมเดลปัญญาประดิษฐ์สำหรับตรวจจับความรุนแรงของแผลไหม้ จำเป็นที่จะต้องเตรียมข้อมูลนำเข้าเป็น 2 ข้อมูลด้วยกัน ได้แก่ ข้อมูลภาพ และข้อมูลลาเบลระบุพื้นที่บริเวณแผลไหม้และระดับของแผลไหม้ ซึ่งทั้ง 2 ข้อมูลนี้ จำเป็นต้องมีชื่อไฟล์ที่เหมือนกันระหว่างรูปภาพที่เป็นต้นฉบับ และรูปภาพลาเบล ดังนั้น จึงมีการเปลี่ยนชื่อรูปภาพระหว่างรูปภาพที่เป็นต้นฉบับ และรูปภาพที่ระบุประเภทข้อมูลให้มีชื่อที่เหมือนกัน โดยจะตั้งชื่อไฟล์เป็นตัวเลข ดังมีการทำงานตามขั้นตอนวิธีการที่ 2 ต่อไปนี้

จากขั้นตอนวิธีที่ 2 สามารถสรุปฟังก์ชันต่างๆ ได้ดังต่อไปนี้ (i) FilenamesConverter(currentFolder) เป็นฟังก์ชันหลักที่รับที่อยู่ของโฟลเดอร์เริ่มต้นและเริ่มกระบวนการแปลงชื่อไฟล์ในโฟลเดอร์นี้และโฟลเดอร์ย่อยทั้งหมด (ii) if isDirectory(file) เป็นฟังก์ชันที่ตรวจสอบว่าไฟล์นั้นเป็นโฟลเดอร์หรือไม่ (iii) FilenamesConverter(file) เป็นฟังก์ชันที่ถ้าเป็นโฟลเดอร์ ทำการเรียกตัวเองเพื่อทำการแปลงชื่อไฟล์ในโฟลเดอร์ย่อย (iv) genFilename(file, FileNo) เป็นฟังก์ชันที่ถ้าไม่ใช่โฟลเดอร์ให้สร้างชื่อไฟล์ใหม่โดย

เพิ่ม running number ที่ได้จาก genFilename และ (v) renameFile(file, newFilename) เป็นฟังก์ชันการเปลี่ยนชื่อไฟล์เดิมเป็นชื่อไฟล์ใหม่

5.3 การปรับมาตราส่วนของภาพ

ตามที่กล่าวไปก่อนหน้านี้ ชุดข้อมูลภาพที่ได้รับรวบรวมมานั้นมีขนาดและความละเอียดไม่เท่ากัน หากทำการปรับรูปภาพด้วยการเพิ่มหรือลดขนาด อาจจะทำให้ข้อมูลเพี้ยนไปจากเดิมได้ ดังนั้น เพื่อแก้ปัญหาดังกล่าว จึงได้มีการเลือกใช้การปรับมาตราส่วนหรือปรับอัตราส่วนของรูปภาพให้อยู่ในอัตราส่วน 16:9 เหมือนกันทุกรูปภาพ และผลลัพธ์จากการปรับอัตราส่วน โดยการปรับอัตราส่วนนั้น มีการใช้งานโปรแกรม Adobe Photoshop 2023 ในการปรับอัตราส่วนของรูปภาพ เนื่องจากโปรแกรมดังกล่าวนี้ สามารถยืดหยุ่นในการปรับอัตราส่วนได้ และสามารถสลับอัตราส่วนระหว่าง 16:9 กับ 9:16 ได้อีกด้วย หลังจากปรับอัตราส่วนเสร็จแล้ว ทำการเซฟไฟล์เป็นนามสกุล .TIF ตัวอย่างของภาพที่ผ่านการปรับมาตราส่วนสามารถแสดงได้ดังภาพประกอบ 5 โดยชุดภาพทางซ้ายเป็นภาพดั้งเดิม และ ชุดภาพทางขวาเป็นภาพที่ปรับมาตราส่วนแล้วเป็น 16:9




ภาพประกอบ 5 ตัวอย่างของภาพที่ปรับมาตราส่วนเป็น 16:9

6. การติดป้ายกำกับรูปภาพ

ในหัวข้อนี้จะอธิบายการติดป้ายกำกับ หรือ การลาเบลข้อมูลสำหรับ Image Segmentation เป็นกระบวนการที่มีความสำคัญในการสร้างชุดข้อมูล เพื่อใช้ในการสร้างโมเดลปัญญาประดิษฐ์ โดยในงานวิจัยนี้ Adobe Photoshop 2023 เป็นเครื่องมือ ที่ถูกใช้ในการลาเบลภาพ โดยลาเบลพื้นที่หรือวัตถุ ที่ต้องการให้โมเดลทำนายหรือตรวจจับ โดยการ กำหนดตัวเลือกหรือป้ายกำกับตามเครื่องมือที่ใช้ โดยใช้เครื่องมือลาเบลที่เลือกเพื่อวาดพื้นที่หรือเส้นโค้ง รอบตัวของวัตถุที่ต้องการ Segment และมีขั้นตอน ในการดำเนินการลาเบลข้อมูลดังนี้ (i) เพิ่มรูปภาพ แผลไหม้เข้าไปใน Adobe Photoshop 2023 (ii) เลือกใช้ Tool ที่มีชื่อว่า Polygonal Lasso tool ในการกำหนดพื้นที่ในรูปภาพแผลไหม้ โดยทำการ

ล้อมรอบพื้นที่แผลไหม้ (iii) เมื่อระบุพื้นที่ที่สนใจได้ แล้ว จะทำการสร้าง Layer ใหม่ขึ้นมา เพื่อที่จะทำให้ พื้นหลังของรูปภาพเป็นสีขาว (iv) เลือกใช้ Tool ที่มีชื่อว่า Quick Selection tool ในการเลือกพื้นที่ที่ สนใจทั้งหมดในรูปภาพนั้น หลังจากนั้นจะทำการ เทสีลงไปในพื้นที่ที่สนใจ ซึ่งสีที่ใช้ในการระบุประเภท ข้อมูล มีทั้งหมด 3 สีด้วยกัน ซึ่งมีเฉดสี RGB ได้แก่ สีน้ำเงิน (0, 0, 255), สีเขียว (0, 255, 0), และสีแดง (255, 0, 0) ซึ่งในแต่ละสีจะมีความหมายที่แตกต่างกัน นั่นคือ (i) สีน้ำเงิน หมายถึง ความรุนแรงแผลไหม้ ระดับที่หนึ่ง (ii) สีเขียว หมายถึง ความรุนแรงแผลไหม้ระดับที่สอง (iii) สีแดง หมายถึง ความรุนแรง แผลไหม้ระดับที่สาม ซึ่งสามารถแสดงตัวอย่างของ ภาพที่ระบุประเภทข้อมูล ได้ดังภาพประกอบ 6 โดย ชุดข้อมูลทางซ้ายคือภาพต้นฉบับ และชุดข้อมูลทาง ขวา คือภาพป้ายกำกับ



ภาพประกอบ 6 ตัวอย่างติดป้ายกำกับภาพ

7. การสร้างโมเดลปัญญาประดิษฐ์

ในหัวข้อนี้แสดงรายละเอียดของการพัฒนาโมเดลปัญญาประดิษฐ์ในการตรวจจับความรุนแรงของแผลไหม้โดยใช้โมเดลการแบ่งส่วน (Segmentation) โดยใช้สถาปัตยกรรม U-Net และ YOLOv8 ซึ่งพัฒนาโดยใช้ Python 3.11.0, Keras 3.0 และ Tensorflow 2.14.0 ตามลำดับและได้รับการเรียนรู้ด้วย NVIDIA GeForce GTX 1050 Laptop GPU – 3GB GDDR5 โดยในหัวข้อย่อยที่ 7.1 นำเสนอรายละเอียดของการพัฒนาโมเดลปัญญาประดิษฐ์ด้วย U-Net หัวข้อย่อยที่ 7.2 นำเสนอรายละเอียดของการพัฒนาโมเดลปัญญาประดิษฐ์ด้วย YOLOv8

7.1 การสร้างโมเดลปัญญาประดิษฐ์ด้วย U-Net

การสร้างโมเดลด้วย U-Net เป็นกระบวนการที่ใช้เทคนิคการเรียนรู้เชิงลึก เพื่อให้โมเดลสามารถตรวจจับและแยกแยะวัตถุได้ดี ซึ่งโครงสร้างของ U-Net มีรูปแบบของ U ที่มีทางเดินทางสั้นสำหรับการนำข้อมูลออกมาหลังจากทำ Feature Extraction โดยมีขั้นตอนในการสร้างโมเดลดังนี้ในการสร้างโมเดล U-Net จำเป็นที่จะต้องมีการเตรียมภาพต้นฉบับและภาพที่ติดป้ายกำกับ โดยผู้วิจัยจะนำชุดข้อมูลไปเก็บไว้ที่ Google Drive เพื่อที่จะสามารถเรียกมาใช้ใน Google Colab ได้อย่างสะดวก การสร้างโมเดล U-Net จะมีส่วนประกอบหลัก 2 ส่วนด้วยกันได้แก่ ส่วนของเ็นโค้ดเดอร์ (Encoder) เป็นส่วนที่ใช้ในการทำ Feature Extraction ของภาพและทำการลดขนาดฟีเจอร์ ซึ่งผู้วิจัยมีการลดขนาดของฟีเจอร์โดยใช้ MaxPooling2D โดยแต่ละขนาดจะเท่ากับ 16, 32, 64, 128 ตามลำดับ และส่วนของดีโค้ดเดอร์ (Decoder) เป็นส่วนที่ใช้ในการขยายขนาดของฟีเจอร์ ซึ่งจะมีการขยายขนาดฟีเจอร์เท่ากับ 128, 64, 32, 16 ตามลำดับ (Singh & Nongmeikapam, 2022) นอกจากนี้มีการใช้คอนโวลูชันเลเยอร์ที่มีขนาดใหญ่กว่าคือ 160 เพื่อเพิ่มความซับซ้อนของโมเดล อยู่ระหว่าง

ส่วนของเ็นโค้ดเดอร์และดีโค้ดเดอร์ หลังจากนั้นทำการปรับไฮเปอร์พารามิเตอร์ เป็นตัวแปรการกำหนดค่าภายนอกเพื่อจัดการการเรียนรู้โมเดลปัญญาประดิษฐ์ โดยจะส่งผลให้โมเดลมีความแม่นยำเพิ่มมากขึ้นหรือต้องการลดค่าความสูญเสียของโมเดลให้มีค่าต่ำที่สุด ซึ่งผู้วิจัยจะทดลองการปรับแต่งไฮเปอร์พารามิเตอร์ออกเป็น 5 โมเดล ซึ่งในแต่ละโมเดลจะมีการปรับแต่งไฮเปอร์พารามิเตอร์ที่แตกต่างกัน โดยการปรับแต่งจะมีการเพิ่มจำนวนคอนโวลูชันและเพิ่มขนาดหรือลดขนาดของคอนโวลูชัน และวิธีการกำหนดน้ำหนัก (Kernel Initializer) มีรูปแบบที่แตกต่างกันในแต่ละโมเดล (Román *et al.*, 2023) เพื่อหาว่าการปรับไฮเปอร์พารามิเตอร์แบบใดให้ผลลัพธ์ที่ดีกว่า เมื่อทำการปรับไฮเปอร์พารามิเตอร์ตามที่ต้องการเสร็จแล้ว จากนั้นจะทำการตั้งค่าพารามิเตอร์ในการเรียนรู้ของโมเดล ซึ่งในแต่ละโมเดลจะมีการตั้งค่าพารามิเตอร์ที่เหมือนกัน คือ จำนวน Epochs เท่ากับ 100, Batch Size เท่า 8 และขนาดของข้อมูลที่ใช้เรียนรู้โมเดลมีอัตราส่วน 8:2 โดยอัตราส่วนในการเรียนรู้ข้อมูลคือ 80% และอัตราส่วนในการทดสอบข้อมูลคือ 20%

7.2 การสร้างโมเดลปัญญาประดิษฐ์ด้วย YOLOv8

ในการสร้างโมเดล YOLOv8 เป็นกระบวนการเรียนรู้เชิงลึกในการตรวจจับและแยกแยะวัตถุในภาพ ซึ่งพัฒนามาจาก YOLO ที่เป็นโมเดลในการตรวจจับวัตถุ ซึ่งขั้นตอนในการสร้างโมเดลมีดังนี้ทำการจัดการและปรับปรุงรูปภาพด้วย Roboflow จากนั้นนำข้อมูลเหล่านั้นเป็นฐานข้อมูลในการเรียนรู้ของโมเดล เนื่องจากผู้วิจัยอยากทราบว่า YOLOv8 เวอร์ชันใดให้ประสิทธิภาพในการตรวจจับความรุนแรงของแผลไหม้ได้ดีที่สุด จึงทำให้มีการใช้งานโมเดล YOLOv8 ทั้งหมด 5 โมเดลด้วยกัน ได้แก่ YOLOv8-S, YOLOv8-L, YOLOv8-M, YOLOv8-N และ YOLOv8-X เพื่อนำมาเปรียบเทียบประสิทธิภาพ

ระหว่างโมเดล YOLOv8 ด้วยกัน ซึ่งพารามิเตอร์ในการเรียนรู้ของโมเดลทั้ง 5 โมเดลจะมีการตั้งค่าที่เหมือนกัน คือ จำนวน Epochs เท่ากับ 100 รอบ ขนาดของ Batch Size เท่ากับ Auto และมี Image Size เท่ากับ 640 พิกเซล

8. การวัดและประเมินผล

ในหัวข้อนี้เพื่อต้องการเปรียบเทียบประสิทธิภาพของโมเดลปัญญาประดิษฐ์ U-Net และ YOLOv8 เนื้อหาของหัวข้อนี้จึงแบ่งออกเป็นผลของการสร้างโมเดลด้วย U-Net และ YOLOv8 โดยแสดงรายละเอียดในหัวข้อที่ 8.1 และในหัวข้อที่ 8.2 แสดงผลเปรียบเทียบของการนำเอาโมเดลทั้ง U-Net และ YOLOv8 ไปทดสอบกับข้อมูลทดสอบ

8.1 การสร้างโมเดลปัญญาประดิษฐ์ด้วย U-Net และ YOLOv8

เพื่อต้องการเปรียบเทียบประสิทธิภาพของโมเดลปัญญาประดิษฐ์ U-Net และปัจจัยที่ส่งผลต่อการตรวจจับความรุนแรงของแผลไหม้โดยใช้โมเดลการแบ่งส่วน ทางผู้วิจัยได้ทำการทดลองการด้วยสถาปัตยกรรม U-Net ที่แตกต่างกัน 5

โมเดล ซึ่งจะมีการปรับไฮเปอร์พารามิเตอร์ที่แตกต่างกัน ได้แก่ จำนวนของชั้นคอนโวลูชัน, ขนาดของคอนโวลูชันในแต่ละชั้น และวิธีการกำหนดน้ำหนัก (Lee *et al.*, 2022) สามารถแสดงข้อแตกต่างได้ดังตาราง 2

ตาราง 2 ข้อแตกต่างระหว่างสถาปัตยกรรม U-Net 5 โมเดล

Model Algorithm	Convolutional Layer Additional	Kernel_INITIALIZER
Unet_1	2 (160), (160)	he_normal
Unet_2	1 (160)	he_uniform
Unet_3	2 (160), (200)	zeros, he_uniform
Unet_4	4 (60), (30), (90), (160)	he_normal
Unet_5	2 (160), (200)	he_uniform, random_uniform

ตาราง 3 ผลการทดสอบประเมินผลลัพธ์โมเดล U-Net

Model Algorithm	Training		Validation	
	Accuracy	Loss	Accuracy	Loss
Unet_1	0.939	0.165	0.791	0.798
Unet_2	0.812	0.476	0.782	0.591
Unet_3	0.823	0.444	0.785	0.572
Unet_4	0.859	0.370	0.776	0.681
Unet_5	0.866	0.351	0.776	0.686

จากตาราง 2 แสดงรายละเอียดข้อแตกต่างระหว่างสถาปัตยกรรม U-Net 5 โมเดลได้ดังนี้ (i) โมเดลที่หนึ่ง มีการเพิ่มคอนโวลูชันเลเยอร์ที่มีขนาดใหญ่กว่า (16, 32, 64, 128) ออกเป็นสองส่วน โดยส่วนแรกจะเป็นส่วนของเอ็นโค้ดเดอร์ ซึ่งมีขนาด 160 และมีวิธีการกำหนดน้ำหนักเป็น he_normal และส่วนที่สองจะเป็นส่วนของดีโค้ดเดอร์ ซึ่งมีขนาด 160 และมีวิธีการกำหนดน้ำหนักเป็น he_normal (ii) โมเดลที่สอง มีการเพิ่มคอนโวลูชันเลเยอร์ 160 ในส่วนของเอ็นโค้ดเดอร์ และมีวิธีการกำหนดน้ำหนักเป็น he_uniform (iii) โมเดลที่สาม มีการเพิ่มคอนโวลูชันเลเยอร์ออกเป็นสองส่วน ส่วนแรกอยู่ที่เอ็นโค้ดเดอร์ ซึ่งมีขนาด 160 และมีวิธีการกำหนดน้ำหนักเป็น zeros ส่วนที่สองจะเป็นส่วนของดีโค้ดเดอร์ ซึ่งมีขนาด 200 และมีวิธีการกำหนดน้ำหนักเป็น he_uniform (iv) โมเดลที่สี่ มีการเพิ่มคอนโวลูชันเลเยอร์ทั้งหมด 4 เลเยอร์ โดยจะอยู่ที่เอ็นโค้ดเดอร์ทั้งหมด โดยมีขนาด 60, 30, 90, 160 ตามลำดับ และมีวิธีการกำหนดน้ำหนักเป็น he_uniform (v) โมเดลที่ห้า มีการเพิ่มคอนโวลูชันเลเยอร์ออกเป็นสองส่วน ส่วนแรกอยู่ที่เอ็นโค้ดเดอร์ ซึ่งมีขนาด 160 และมีวิธีการกำหนดน้ำหนักเป็น he_uniform ส่วนที่สองจะอยู่ที่ดีโค้ดเดอร์ มีขนาด 200 และมีวิธีการกำหนดน้ำหนักเป็น random_uniform

เนื่องจากงานวิจัยนี้ ผู้วิจัยต้องการเปรียบเทียบระหว่างโมเดลปัญญาประดิษฐ์ U-Net และ YOLOv8 จึงสามารถแสดงโมเดลที่มีค่าความแม่นยำมากที่สุดของโมเดล U-Net ได้ดังตาราง 3 และสามารถแสดงโมเดลที่มีค่าความแม่นยำที่สุดของโมเดล YOLOv8 ได้ดังตาราง 4






จากตาราง 3 แสดงผลการทดสอบประเมินผลลัพธ์ แสดงให้เห็นว่าโมเดลที่หนึ่งมีค่าความแม่นยำสูงถึง 79.1% และมีค่าสูญเสีย 79.8% โมเดลที่สองมีค่าความแม่นยำ 78.2% และมีค่าสูญเสีย 59.1% โมเดลที่สามมีค่าความแม่นยำ 78.5% และมีค่าสูญเสีย 57.2% โมเดลที่สี่ มีค่าความแม่นยำ 77.6% และมีค่าสูญเสีย 68.1% โมเดลที่ห้า มีค่าความแม่นยำ 77.6% และมีค่าสูญเสีย 68.6% ซึ่งแสดงให้เห็นว่าโมเดลที่หนึ่งมีค่าความแม่นยำดีที่สุด

จากตาราง 4 แสดงผลการทดสอบประเมินผลลัพธ์ แสดงให้เห็นว่า YOLOv8-S มีค่า mAP 0.5 เท่ากับ 0.424 และมีค่าสูญเสียของการแบ่งภาพอยู่ที่ 3.185 และค่าความสูญเสียของการทำนายคลาอยู่ที่ 1.760 YOLOv8-L มีค่า mAP 0.5 ดีที่สุดเท่ากับ 0.657 และมีค่าสูญเสียของการแบ่งภาพอยู่ที่ 3.231 และค่าความสูญเสียของการทำนายคลาอยู่ที่ 1.961 YOLOv8-M มีค่า mAP 0.5 เท่ากับ 0.371 และมีค่าสูญเสียของการแบ่งภาพอยู่ที่ 3.371 และค่าความสูญเสียของการ

ตาราง 4 ผลการทดสอบประเมินผลลัพธ์โมเดล YOLOv8

Model Algorithm	mAP 0.5	Segment Loss		Class Loss	
		Train	Validation	Train	Validation
YOLOv8-S	0.424	1.857	3.185	0.898	1.760
YOLOv8-L	0.657	1.005	3.231	0.414	1.961
YOLOv8-M	0.371	0.971	3.371	0.389	1.638
YOLOv8-N	0.368	2.654	2.994	1.083	2.019
YOLOv8-X	0.478	2.196	2.563	1.432	1.900

ตาราง 5 การเปรียบเทียบผลของการนำเอาโมเดล U-Net และ YOLOv8 ไปใช้

No	Original	Ground Truth	U-Net	Accuracy	YOLOv8	Accuracy
1				0.69		0.90
2				0.56		0.48
3				0.53		0.68
4				0.97		0.65
5				0.54		0.79
6				0.68		0.67
7				0.48		0.38
8				0.68		0.76
9				0.73		0.53
10				0.79		0.35
เฉลี่ยความถูกต้อง			U-Net	0.67	YOLOv8	0.62

ทำนายคลาสอยู่ที่ 1.638 YOLOv8-N มีค่า mAP 0.5 เท่ากับ 0.368 และมีค่าสูญเสียของการแบ่งภาพอยู่ที่ 2.994 และค่าความสูญเสียของการทำนายคลาสอยู่ที่ 2.019 YOLOv8-X มีค่า mAP 0.5 ดีที่รองลงมา เท่ากับ 0.478 และมีค่าสูญเสียของการแบ่งภาพอยู่ที่ 2.563 และค่าความสูญเสียของการทำนายคลาสอยู่ที่ 1.900

8.2 การเปรียบเทียบผลของการนำเอาโมเดล U-Net และ YOLOv8 ไปใช้งาน

ในการเปรียบเทียบผลของการนำเอาโมเดล U-Net โมเดลที่หนึ่ง และ YOLOv8-L มาเปรียบ

เทียบประสิทธิภาพกัน เนื่องจาก U-Net โมเดลที่หนึ่งนั้น มีค่าความแม่นยำทั้งในส่วนของการ Validation และ Training เมื่อเทียบกับ U-Net โมเดลอื่นๆ และ YOLOv8-L ซึ่งมีค่า mAP-50 มากกว่า YOLOv8 โมเดลตัวอื่นๆ จึงทำให้มีการนำทั้ง 2 โมเดลมาเปรียบเทียบประสิทธิภาพกัน โดยวิธีการที่ใช้เปรียบเทียบประสิทธิภาพคือ การทำนายรูปภาพที่เป็นภาพแผลไหม้ จำนวน 10 รูปภาพ ซึ่งทั้ง 10 รูปภาพจะไม่ได้อยู่ในชุดข้อมูลที่นำไป Train โดยจะเป็นการทำนายทั้ง U-Net และ YOLOv8 ด้วยรูปภาพเดียวกัน จากนั้นจะมีการเปรียบเทียบประสิทธิภาพ โดยการหาจำนวนพิกเซลทั้งหมดที่เป็นพื้นที่ที่สนใจมาคำนวณ ซึ่ง

จะหาพิกเซลในสีของความรุนแรงแผลไหม้ใหม่ๆ โดยจะมีการอ้างอิงสีที่ต้องหาจำนวนพิกเซลจาก Ground Truth ที่เป็นรูปภาพระบุประเภทความรุนแรงของแผลไหม้ จากนั้นจะนำข้อมูลที่น่าไปทำนายมาทับซ้อนกับ Ground Truth เพื่อหาค่าความถูกต้องในการทำนายของโมเดล ในวิธีการนี้จะมีการใช้การคำนวณเข้ามาช่วย โดยจะนำจำนวนพิกเซลในพื้นที่ที่ทำนายหารด้วยจำนวนพิกเซลของ Ground Truth จะได้ผลลัพธ์เป็นค่าความถูกต้องในการทำนายของโมเดล จากนั้นก็นำค่าความถูกต้องทั้งหมดมาหารกับจำนวนทั้งหมด ซึ่งจะได้ผลลัพธ์ของแต่ละโมเดลเพื่อนำไปเปรียบเทียบประสิทธิภาพ

9. อภิปรายและสรุปผล

การตรวจจับความรุนแรงของแผลไหม้โดยใช้โมเดลการแบ่งส่วน การเปรียบเทียบระหว่างโมเดล U-Net และ YOLOv8 เป็นงานวิจัยที่ศึกษาและพัฒนาโมเดลปัญญาประดิษฐ์เพื่อตรวจจับพื้นที่ที่สนใจของวัตถุเพื่อนำมาใช้ในการตรวจจับความรุนแรงของแผลไหม้ ในการพัฒนาโมเดลปัญญาประดิษฐ์ในการตรวจจับความรุนแรงของแผลไหม้นั้น ได้แสดงค่าความถูกต้องและค่าความสูญเสียของโมเดล โดยในการพัฒนามีการใช้งานโมเดลปัญญาประดิษฐ์สถาปัตยกรรม U-Net ซึ่งใช้ทั้งหมด 5 โมเดล เช่น โมเดลที่หนึ่ง โมเดลที่สอง โมเดลที่สาม โมเดลที่สี่ และโมเดลที่ห้า ซึ่งโมเดลที่หนึ่ง มีค่าความถูกต้องดีที่สุดไม่ว่าจะเป็นในส่วนของการ Training และ Validation ในส่วนของการสูญเสียอาจจะมีค่ามากกว่าโมเดลอื่นสำหรับการตรวจจับความรุนแรงแผลไหม้ และโมเดล YOLOv8 ทั้ง 5 โมเดลได้แก่ YOLOv8-S, YOLOv8-L, YOLOv8-M, YOLOv8-N และ YOLOv8-X แสดงให้เห็นว่า YOLOv8-L ให้ค่า mAP 0.5 ที่ดีที่สุด และเมื่อเปรียบเทียบระหว่างโมเดล U-Net และ YOLOv8 สามารถแสดงให้เห็นว่า โมเดล U-Net ให้ประสิทธิภาพในการตรวจจับแผลไหม้ได้ดีกว่า YOLOv8

โดยสรุปผลงานวิจัยนี้เป็นการตรวจจับความรุนแรงของแผลไหม้โดยใช้โมเดลการแบ่งส่วนการเปรียบเทียบระหว่าง U-Net และ YOLOv8 แสดงให้เห็นว่า U-Net มีความถูกต้องและมีประสิทธิภาพในการตรวจจับความรุนแรงของแผลไหม้ได้ดีกว่า YOLOv8 ซึ่งจะเห็นได้ว่าในงานวิจัยนี้ได้นำโมเดล U-Net และ YOLOv8 มาเปรียบเทียบประสิทธิภาพในการตรวจจับพื้นที่ที่สนใจกัน เพื่อที่จะต้องการทราบว่าระหว่างโมเดลที่เป็นที่นิยมในการใช้ในการตรวจจับพื้นที่ที่สนใจอย่าง U-Net กับ YOLOv8 ที่เพิ่งเปิดตัวมาใหม่ในปี 2023 โมเดลใดให้ประสิทธิภาพในการทำนายได้ดีกว่ากัน ซึ่งเมื่อเปรียบเทียบกันแล้ว U-Net มีข้อแตกต่างกับ YOLOv8 ตรงที่ U-Net ให้ความสำคัญในการตรวจจับพื้นที่ที่สนใจในระดับของพิกเซล โดยจะมีการปรับขนาดของคอนโวลูชันในแต่ละชั้นเพื่อความละเอียดของโมเดล ในขณะที่ YOLOv8 เป็นการตรวจจับพื้นที่ที่สนใจจากวัตถุที่ตรวจจับได้ จึงทำให้ประสิทธิภาพในการตรวจจับพื้นที่ที่สนใจมีความแตกต่างกัน โดยในการทดลองมีการนำรูปภาพทั้ง 10 รูปภาพเพื่อนำไปทำนายให้แก่ U-Net และ YOLOv8 และหาความถูกต้องในแต่ละรูปภาพ จากนั้นนำไปรวมกัน ผลลัพธ์ที่ได้จึงเป็นค่าความถูกต้องในการทำนายของ U-Net และ YOLOv8 ซึ่งค่าความถูกต้องที่ได้ของ U-Net คือ 0.67 ส่วน YOLOv8 มีค่าความถูกต้องที่ 0.62 จึงสรุปได้ว่า U-Net มีการตรวจจับพื้นที่ที่สนใจได้ละเอียดและแม่นยำกว่า YOLOv8

เอกสารอ้างอิง

- Ameli, Z., Nesheli, S. J., & Landis, E. N. (2023). Deep learning-based steel bridge corrosion segmentation and condition rating using mask RCNN and YOLOv8. *Infrastructures*, 9(1), 3. <https://doi.org/10.3390/infrastructures9010003>

- Chang, C. W., Lai, F., Christian, M., Chen, Y. C., Hsu, C., Chen, Y. S., Chang, D. H., Roan, T. L., & Yu, Y. C. (2021). Deep learning–assisted burn wound diagnosis: Diagnostic model development study. *JMIR Medical Informatics*, 9(12), e22798. <https://doi.org/10.2196/22798>
- Chauhan, J., & Goyal, P. (2021). Convolution neural network for effective burn region segmentation of color images. *Burns*, 47(4), 854–862. <https://doi.org/10.1016/j.burns.2020.08.016>
- Che, S., Li, Z., Shi, Z., Gao, M., & Tang, H. (2023). Research on an underwater image segmentation algorithm based on YOLOv8. *Journal of Physics: Conference Series*, 2644(1), 012013. <https://doi.org/10.1088/1742-6596/2644/1/012013>
- Cirillo, M. D., Mirdell, R., Sjöberg, F., & Pham, T. D. (2021). Improving burn depth assessment for pediatric scalds by AI based on semantic segmentation of polarized light photography images. *Burns*, 47(7), 1586–1593. <https://doi.org/10.1016/j.burns.2021.01.011>
- Connolly, M., & Gangahar, R. (2021). 640 Improving junior doctors’ knowledge and confidence in assessment, management and referral of burns patients in the Emergency Department, Royal Oldham Hospital. *British Journal of Surgery*, 108(Supplement_6). <https://doi.org/10.1093/bjs/znab259.703>
- Hamamoto, R., Suvarna, K., Yamada, M., Kobayashi, K., Shinkai, N., Miyake, M., Takahashi, M., Jinnai, S., Shimoyama, R., Sakai, A., Takasawa, K., Bolatkan, A., Shozu, K., Dozen, A., Machino, H., Takahashi, S., Asada, K., Komatsu, M., Sese, J., & Kaneko, S. (2020). Application of artificial intelligence technology in Oncology: Towards the establishment of precision medicine. *Cancers*, 12(12), 3532. <https://doi.org/10.3390/cancers12123532>
- Haleem, A., Javaid, M., & Khan, I. H. (2019). Current status and applications of artificial intelligence (AI) in medical field: An overview. *Current Medicine Research and Practice*, 9(6), 231–237. <https://doi.org/10.1016/j.cmrp.2019.11.005>
- Jiao, C., Su, K., Xie, W., & Ye, Z. (2019). Burn image segmentation based on mask regions with convolutional neural network deep learning framework: More accurate and more convenient. *Burns & Trauma*, 7. <https://doi.org/10.1186/s41038-018-0137-9>
- Kotecha, V. R., Opot, N. E., & Nangole, F. (2022). Assessment and management of pain in patients sustaining burns at Emergency Department Kenyatta National Hospital, Kenya: A descriptive study. *Trauma Care*, 2(1), 79–86. <https://doi.org/10.3390/traumacare2010007>

- Lee, Y., Sim, W., Park, J., & Lee, J. (2022). Evaluation of hyperparameter combinations of the U-Net model for land cover classification. *Forests*, 13(11), 1813. <https://doi.org/10.3390/f13111813>
- Liang, J., Li, R., Wang, C., Zhang, R., Yue, K., Li, W., & Li, Y. (2022). A spiking neural network based on retinal ganglion cells for automatic burn image segmentation. *Entropy*, 24(11), 1526. <https://doi.org/10.3390/e24111526>
- Liszka, S. (2023). Evaluation of tree planting using computer vision models YOLO and U-Net [Master Thesis, Umeå University]. Retrieved from <https://urn.kb.se/resolve?urn=urn:nbn:se:umu:diva-214842>
- Markiewicz-Gospodarek, A., Koziół, M., Tobiasz, M., Baj, J., Radzikowska-Büchner, E., & Przekora, A. (2022). Burn wound healing: Clinical complications, medical care, treatment, and dressing types: The current state of knowledge for clinical practice. *International Journal of Environmental Research and Public Health*, 19(3), 1338. <https://doi.org/10.3390/ijerph19031338>
- Moura, F. S. E., Amin, K., & Ekwobi, C. (2021). Artificial intelligence in the management and treatment of burns: a systematic review. *Burns & Trauma*, 9. <https://doi.org/10.1093/burnst/tkab022>
- Naqvi, M., Gilani, S. Q., Syed, T., Marques, O., & Kim, H.-C. (2023). Skin cancer detection using deep learning—A review. *Diagnostics*, 13(11), 1911. <https://doi.org/10.3390/diagnostics13111911>
- Pandya, M. D., Shah, P. D., & Jardosh, S. (2019). Medical image diagnosis for disease detection: A deep learning approach. *U-Healthcare Monitoring Systems*, 37–60. <https://doi.org/10.1016/b978-0-12-815370-3.00003-7>
- Pabitha, C., & Vanathi, B. (2020). Densemask RCNN: A hybrid model for skin burn image classification and Severity grading. *Neural Processing Letters*, 53(1), 319–337. <https://doi.org/10.1007/s11063-020-10387-5>
- Román, K., Llumiquinga, J., Chancay, S., & Morocho-Cayamcela, M. E. (2023). Hyperparameter tuning in a dual channel U-Net for medical image segmentation. *Information and Communication Technologies*, 337–352. https://doi.org/10.1007/978-3-031-45438-7_23
- Şevik, U., Karakullukçu, E., Berber, T., Akbaş, Y., & Türkyılmaz, S. (2019). Automatic classification of skin burn colour images using texture-based feature extraction. *IET Image Processing*, 13(11), 2018–2028. Portico. <https://doi.org/10.1049/iet-ipr.2018.5899>
- Singh, N. J., & Nongmeikapam, K. (2022). Semantic segmentation of satellite images using Deep-Unet. *Arabian Journal for Science and Engineering*, 48(2), 1193–1205. <https://doi.org/10.1007/s13369-022-06734-4>

- Suha, S. A., & Sanam, T. F. (2022). A deep convolutional neural network-based approach for detecting burn severity from skin burn images. *Machine Learning with Applications*, 9, 100371. <https://doi.org/10.1016/j.mlwa.2022.100371>
- Toussaint, J., & Singer, A. J. (2014). The evaluation and management of thermal injuries: 2014 update. *Clinical and Experimental Emergency Medicine*, 1(1), 8–18. <https://doi.org/10.15441/ceem.14.029>
- Son Tran, H., Hoang Le, T., & Thanh Nguyen, T. (2016). The degree of skin burns images recognition using convolutional neural network. *Indian Journal of Science and Technology*, 9(45). <https://doi.org/10.17485/ijst/2016/v9i45/106772>
- Wang, C., Anisuzzaman, D. M., Williamson, V., Dhar, M. K., Rostami, B., Niezgoda, J., Gopalakrishnan, S., & Yu, Z. (2020). Fully automatic wound segmentation with deep convolutional neural networks. *Scientific Reports*, 10(1). <https://doi.org/10.1038/s41598-020-78799-w>