



การพัฒนาโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้การถ่ายโอนการเรียนรู้
เพื่อจำแนกระดับความรุนแรงของสิ่วบนภาพใบหน้า

DEVELOPMENT OF TRANSFER LEARNING-BASED CONVOLUTIONAL
NEURAL NETWORK MODELS FOR ACNE SEVERITY
CLASSIFICATION ON FACIAL IMAGES

ธราดล ขวัญศิริ

วิทยาศาสตร์มหาบัณฑิต

สาขาวิชาวิทยาการวิเคราะห์ทางสุขภาพและชีวการแพทย์

สำนักวิชาวิทยาศาสตร์สุขภาพ

มหาวิทยาลัยแม่ฟ้าหลวง

2568

©ลิขสิทธิ์ของมหาวิทยาลัยแม่ฟ้าหลวง

การพัฒนาโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้การถ่ายโอนการเรียนรู้
เพื่อจำแนกระดับความรุนแรงของสิ่วบนภาพใบหน้า

DEVELOPMENT OF TRANSFER LEARNING-BASED CONVOLUTIONAL
NEURAL NETWORK MODELS FOR ACNE SEVERITY
CLASSIFICATION ON FACIAL IMAGES



ธราดล ขวัญศิริ

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาการวิเคราะห์ทางสุขภาพและชีวการแพทย์

สำนักวิชาวิทยาศาสตร์สุขภาพ

มหาวิทยาลัยแม่ฟ้าหลวง

2568

©ลิขสิทธิ์ของมหาวิทยาลัยแม่ฟ้าหลวง



หน้าอนุมัติวิทยานิพนธ์
มหาวิทยาลัยแม่ฟ้าหลวง

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการวิเคราะห์ทางสุขภาพและชีวการแพทย์
วิทยานิพนธ์เรื่อง การพัฒนาโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้การถ่ายโอน
การเรียนรู้เพื่อจำแนกระดับความรุนแรงของสิวนภาพใบหน้า
Development of Transfer Learning-based Convolutional Neural Network
Models for Acne Severity Classification on Facial Images

ผู้ประพันธ์ ธาราดล ขวัญศิริ

คณะกรรมการสอบ

ผู้ช่วยศาสตราจารย์ ดร.กิตติชัย วรรณนะจิตตกุล	ประธานกรรมการ
ผู้ช่วยศาสตราจารย์ ดร.วุฒิชัย นาชัยเวียง	กรรมการ
ผู้ช่วยศาสตราจารย์ ดร.ภัทรมน วุฒิพิทยามงคล	กรรมการ
ผู้ช่วยศาสตราจารย์ ดร.วิภาพ สุทชนะ	กรรมการ
ผู้ช่วยศาสตราจารย์ ดร.นิเวศน์ กุลวงศ์	กรรมการ

อาจารย์ที่ปรึกษา

.....อาจารย์ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.วุฒิชัย นาชัยเวียง)

.....อาจารย์ที่ปรึกษาร่วม
(ผู้ช่วยศาสตราจารย์ ดร.ภัทรมน วุฒิพิทยามงคล)

คณบดี

.....
(ผู้ช่วยศาสตราจารย์ ดร.วิภาพ สุทชนะ)

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องด้วยได้รับความร่วมมือจากอาสาสมัคร การสนับสนุนทุนวิจัยจากมหาวิทยาลัยแม่ฟ้าหลวง และด้วยความช่วยเหลือ รวมถึงคำแนะนำอันมี คุณค่าจากหลายฝ่ายที่ได้กรุณาให้การสนับสนุนแก่ผู้วิจัย

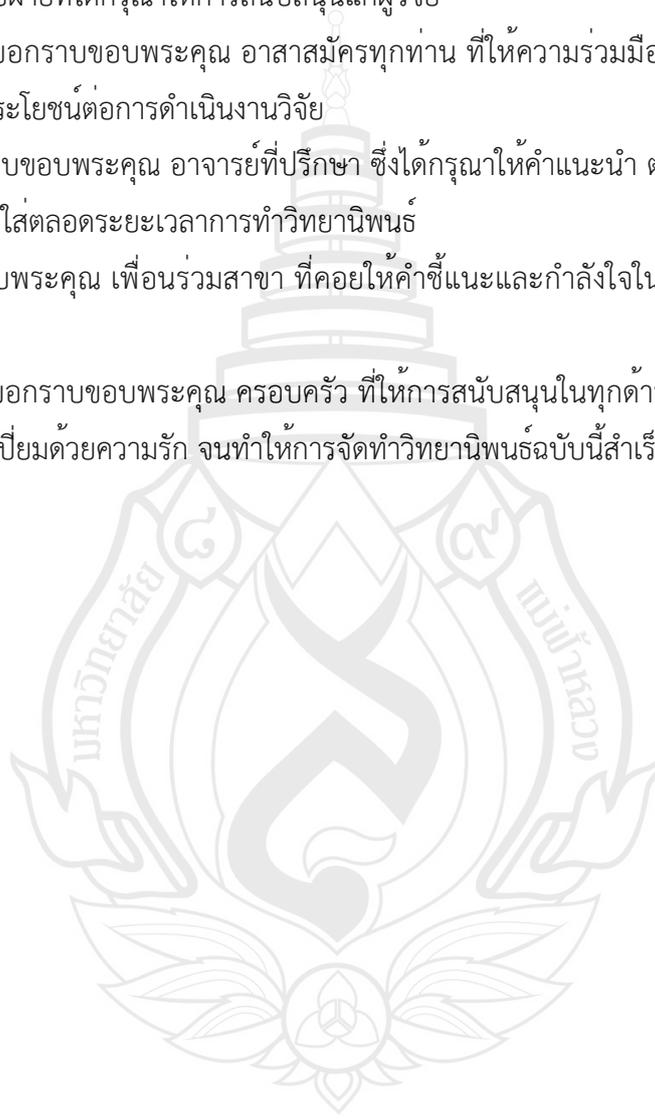
ผู้วิจัยขอกราบขอบพระคุณ อาสาสมัครทุกท่าน ที่ให้ความร่วมมือและอนุเคราะห์ในการให้ ข้อมูลอันเป็นประโยชน์ต่อการดำเนินงานวิจัย

ขอกราบขอบพระคุณ อาจารย์ที่ปรึกษา ซึ่งได้กรุณาให้คำแนะนำ ตรวจสอบแก้ไข และให้กำลังใจ ด้วยความเอาใจใส่ตลอดระยะเวลาการทำวิทยานิพนธ์

ขอขอบพระคุณ เพื่อนร่วมสาขา ที่คอยให้คำชี้แนะและกำลังใจในการทำงานอย่างต่อเนื่อง สุดท้ายนี้

ผู้วิจัยขอกราบขอบพระคุณ ครอบครัว ที่ให้การสนับสนุนในทุกด้าน ทั้งร่างกาย แรงใจ และความเข้าใจอันเปี่ยมด้วยความรัก จนทำให้การจัดทำวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

ธราดล ขวัญศิริ



ชื่อเรื่องวิทยานิพนธ์	การพัฒนาโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้การถ่ายโอนการเรียนรู้เพื่อจำแนกระดับความรุนแรงของสิ่วบนภาพใบหน้า
ผู้ประพันธ์	ธราดล ขวัญศิริ
หลักสูตร	วิทยาศาสตร์มหาบัณฑิต (วิทยาการวิเคราะห์ทางสุขภาพและชีวการแพทย์)
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.วุฒิชัย นาชัยเวียง
อาจารย์ที่ปรึกษาร่วม	ผู้ช่วยศาสตราจารย์ ดร.ภัทรমন วุฒิพิทยามงคล

บทคัดย่อ

สิ่วเป็นภาวะความผิดปกติของผิวหนังที่เกิดจากการอักเสบเรื้อรัง ซึ่งพบได้บ่อยโดยเฉพาะในวัยรุ่น และส่งผลกระทบต่อทางจิตใจและสังคมเป็นอย่างมาก การศึกษาครั้งนี้มีวัตถุประสงค์เพื่อพัฒนาโมเดลจำแนกระดับความรุนแรงของสิ่วบนใบหน้าโดยใช้เทคนิคการเรียนรู้เชิงลึก และแสดงให้เห็นถึงการประยุกต์ใช้โมเดลดังกล่าวในรูปแบบเว็บแอปพลิเคชัน การทดสอบหลายขั้นตอนซึ่งรวมถึงการใช้เทคนิคการปรับสมดุลข้อมูล (Resampling) เพื่อเพิ่มประสิทธิภาพของแบบจำลอง ชุดข้อมูลที่ใช้ประกอบด้วยภาพใบหน้าจำนวน 442 ภาพ แบ่งเป็นชุดฝึกสอน 354 ภาพ และชุดทดสอบ 88 ภาพ ซึ่งได้รับการประเมินระดับความรุนแรงโดยแพทย์ผิวหนังตามเกณฑ์ IGA ระดับ 0-4 โดยมีการจัดการข้อมูลเป็น ระดับความรุนแรงที่ 1-3 ผลการทดลองพบว่าเทคนิคการเพิ่มข้อมูลด้วย GANs ให้ผลลัพธ์ดี มีค่า Test Accuracy = 51.12%, Precision เฉลี่ย = 0.57, Recall = 0.50, F1-score = 0.49, และ Specificity = 0.75 แม้ประสิทธิภาพยังถูกจำกัดด้วยขนาดและความหลากหลายของชุดข้อมูล ผลลัพธ์ยังสะท้อนศักยภาพการเรียนรู้เชิงลึกในการประเมินความรุนแรงของสิ่วจากภาพถ่าย และมีแนวโน้มพัฒนาเพื่อการใช้งานจริงในอนาคต

คำสำคัญ: การเรียนรู้แบบถ่ายโอน, ข้อมูลไม่สมดุล, การจำแนกสิ่ว, การเรียนรู้เชิงลึก

Thesis Title	Development of Transfer Learning-Based Convolutional Neural Network Models for Acne Severity Classification on Facial Images
Author	Taradon Khonsiri
Degree	Master of Science (Health and Biomedical Analytics)
Advisor	Assistant Professor Woottichai Nachaiwieng, Ph. D.
Co-Advisor	Assistant Professor Pattaramon Vottipittayamongkol, Ph. D.

ABSTRACT

Acne is a common chronic inflammatory skin disorder that predominantly affects adolescents and can lead to significant psychological and social impacts. This study aimed to develop a deep learning-based model for classifying facial acne severity and to demonstrate its practical application through a web-based application. The dataset consisted of 442 facial images, including 354 images for training and 88 images for testing, with severity levels classified by dermatologists according to the Investigator's Global Assessment (IGA) scale (levels 0–4), and the data were then categorized into severity levels 1–3. Experimental results demonstrated that GAN-based data augmentation yielded good performance, achieving a test accuracy of 51.12%, with an average precision of 0.57, recall of 0.50, F1-score of 0.49, and specificity of 0.75. Although model performance remains constrained by the limited size and diversity of the dataset, the findings highlight the potential of deep learning approaches for facial acne severity assessment from images and indicate promising prospects for real-world clinical and consumer applications in the future.

Keywords: Transfer Learning, Imbalanced Data, Acne Classification, Deep Learning

สารบัญ

บทที่	หน้า
1 บทนำ	1
1.1 ความสำคัญและความเป็นมาของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย	5
1.3 ประโยชน์ที่คาดว่าจะได้รับจากการวิจัย	5
1.4 ขอบเขตของการวิจัย	5
2 การทบทวนวรรณกรรม ผลงานวิจัยต่าง ๆ ที่เกี่ยวข้อง	6
2.1 ลักษณะของสิวและการเกิดสิว	6
2.2 <i>Cutibacterium acnes</i> และความผิดปกติของหน่วยย่อยของรูขุมขน-ต่อมไขมัน (Pilosebaceous Unit) ต่อการเกิดสิวอักเสบ	7
2.3 การรักษาสิว	8
2.4 การจำแนกระดับความรุนแรงของสิว	10
2.5 การอธิบายภาพรวมและองค์ประกอบในส่วนต่าง ๆ ของปัญญาประดิษฐ์ (Artificial Intelligence หรือ AI)	11
2.6 การเรียนรู้แบบถ่ายโอน (Transfer Learning)	16
2.7 โครงสร้างของโมเดลที่ใช้สำหรับ Transfer Learning	17
2.8 ไฮเปอร์พารามิเตอร์ (Hyperparameters)	18
2.9 เทคนิค Grad-CAM (Gradient-weighted Class Action Mapping)	21
2.10 การวิเคราะห์เชิงคาดการณ์ (Predictive Analytics)	22
2.11 การทบทวนวรรณกรรมสำหรับการเรียนรู้เชิงลึกในการจัดระดับความรุนแรงของสิว	23
3 ระเบียบวิธีวิจัย	25
3.1 รูปแบบการศึกษาวิจัย	25
3.2 พื้นที่การศึกษา	26
3.3 ระยะเวลาที่ใช้ในการศึกษา	26
3.4 ประชากรและกลุ่มตัวอย่าง	26
3.5 เครื่องมือที่ใช้ในการศึกษา	29
3.6 ขั้นตอนการดำเนินการวิจัย	30

สารบัญ

บทที่	หน้า
3.7 จริยธรรมสำหรับการวิจัย	43
4 ผลการศึกษาวิจัยและอภิปรายผล	44
4.1 การเปรียบเทียบประสิทธิภาพของแบบจำลองระหว่างข้อมูลดิบ (Raw Data) และข้อมูลที่ผ่านการเตรียมข้อมูล (Preprocessed Data)	44
4.2 การปรับแต่งพารามิเตอร์และการเปรียบเทียบประสิทธิภาพของแบบจำลอง (Model Optimization and Performance Comparison)	47
4.3 การประเมินแบบจำลองด้วย 5-Fold Cross Validation	54
4.4 การปรับสมดุลข้อมูล (Resampling Technique)	57
5 สรุปผลการศึกษาและข้อเสนอแนะ	70
5.1 สรุปผลการวิจัย	70
5.2 ข้อจำกัดของการวิจัย	71
5.3 ข้อเสนอแนะ	72
รายการอ้างอิง	74
ภาคผนวก	83
ภาคผนวก ก หนังสือรับรองจริยธรรมวิจัยในมนุษย์	83
ภาคผนวก ข เอกสารข้อมูลและขอความยินยอมเข้าร่วมการวิจัย	87
ภาคผนวก ค เอกสารประชาสัมพันธ์รับอาสาสมัครเข้าร่วมโครงการวิจัย	94
ภาคผนวก ง แบบฟอร์มกรอกข้อมูลสำหรับอาสาสมัครที่สแกนคิวอาร์โค้ด	95
ภาคผนวก จ แบบฟอร์มกรอกข้อมูลสำหรับแพทย์เฉพาะทางด้านผิวหนังในการแยกระดับความรุนแรงของสิว	98
ภาคผนวก ฉ ข้อมูลสำหรับการดูแลรักษาสิวเบื้องต้นที่ต้องใช้แนะนำใน Web Application	99
ภาคผนวก ช ข้อมูลการเรียกใช้ Face Parsing สำหรับขั้นตอนการเตรียมข้อมูล	110
ภาคผนวก ซ หน้า UI (User Interface) ของ Web Application	111
ภาคผนวก ฅ การอธิบายการตัดสินใจของแบบจำลองด้วยเทคนิค Grad-CAM	112
ประวัติผู้ประพันธ์	118

สารบัญตาราง

ตาราง	หน้า
3.1 อธิบายรายละเอียดเกณฑ์ในการจำแนกระดับความรุนแรงของสิวจาก Investigator's Global Assessment Scale (IGA)	31
3.2 ข้อมูลคลาสแต่ละระดับความรุนแรงของสิว โดยใช้ IGA Scale ในการจำแนก	32
3.3 Augmentation Setting	33
3.4 แสดง Confusion Matrix แบบ Binary Classification	40
4.1 การประเมินประสิทธิภาพของแบบจำลองจำแนกระดับความรุนแรงของสิว	45
4.2 การปรับพารามิเตอร์ของแต่ละแบบจำลอง	47
4.3 ผลการเปรียบเทียบประสิทธิภาพของอัลกอริทึมการปรับค่าน้ำหนัก ในการจำแนกระดับความรุนแรงของ	52
4.4 การประเมินประสิทธิภาพของแบบจำลองด้วยการตรวจสอบแบบ 5-Fold Cross Validation	55
4.5 การเปรียบเทียบประสิทธิภาพของแบบจำลอง Baseline กับ 5-Fold Cross Validation	56
4.6 การเปรียบเทียบค่าเฉลี่ยประสิทธิภาพของแบบจำลองภายใต้จำนวนข้อมูลที่ผ่านการสุ่มซ้ำ ROS	59
4.7 ผลการเปรียบเทียบค่าเฉลี่ยประสิทธิภาพของแบบจำลองภายใต้จำนวนข้อมูลที่สร้างด้วยเทคนิค SMOTE	60
4.8 การเปรียบเทียบค่าเฉลี่ยประสิทธิภาพของแบบจำลองภายใต้จำนวนข้อมูลที่สร้างด้วยเทคนิค GANs	62
4.9 การเปรียบเทียบผลการปรับสมดุลข้อมูลของทั้ง 3 เทคนิค	64

สารบัญภาพ

ภาพ	หน้า
2.1 การอธิบายองค์ประกอบสำหรับปัญญาประดิษฐ์	11
2.2 โครงสร้างพื้นฐานของโครงข่ายประสาทเทียม Multi-layer neural network	13
2.3 แสดงรายละเอียดองค์ประกอบของ Convolutional neural networks (CNN)	15
2.4 ตัวอย่างโครงสร้างการทำ Model Fine-Tuning	16
3.1 ขั้นตอนการดำเนินการศึกษา	30
3.2 ตัวอย่างการถ่ายภาพทั้ง 3 ด้านของใบหน้า	31
3.3 Image Segmentation by Face Parsing	33
3.4 การแบ่งชุดข้อมูล (Data splitting)	35
3.5 ขั้นตอนการทดลอง (Experimental Procedure Diagram)	37
4.1 แสดงกราฟผลการฝึกของแบบจำลอง (Training Progress Graph)	45
4.2 Heatmap แสดงค่า Test Accuracy สูงสุดของแบบจำลองในแต่ละค่าพารามิเตอร์ (MAX Test Accuracy)	50
4.3 การวิเคราะห์พื้นที่สนใจของแบบจำลองด้วยเทคนิค Grad-CAM (Gradient-weighted Class Activation Mapping)	68

บทที่ 1

บทนำ

1.1 ความสำคัญและความเป็นมาของปัญหา

สิวเป็นโรคผิวหนังอักเสบเรื้อรังที่พบได้บ่อยและเป็นโรคที่มีสาเหตุมาจาก Pilosebaceous units ในชั้นของผิวหนังที่เกิดการอักเสบ สาเหตุหลัก ๆ มีอยู่ด้วยกัน 4 ปัจจัย ได้แก่ (1) การผลิตไขมันบนผิวหนังที่เพิ่มขึ้นและมากเกินไป (2) การสร้างชั้นของ Keratin ที่มากเกินไปในรูขุมขนและชั้นของผิวหนัง (3) การกระตุ้นการอักเสบจากเชื้อ *Cutibacterium acnes* หรือ *C. acnes* ที่อยู่ภายในรูขุมขน (4) การอักเสบของรูขุมขน (Feldman et al., 2004) และสิวยังสามารถจำแนกความรุนแรงออกเป็น 4 ประเภทหลักๆ ดังนี้ (1) สิวที่ไม่อักเสบ ประกอบด้วย สิวแบบเปิด (สิवादุดันหัวดำ) และ สิวแบบปิด (สิवादุดันหัวขาว) (2) สิวอักเสบเล็กน้อยมีลักษณะอาการ คือ มีสิवादุดัน มีเลือดคั่งและตุ่มหนองเล็กน้อย (3) สิวอักเสบปานกลางมีลักษณะอาการ คือ มีสิवादุดัน ตุ่มนูน และ ตุ่มหนองหลายลักษณะรวมไปถึงสิิวอักเสบขนาดใหญ่สีแดงเล็กน้อย และ (4) สิวอักเสบรุนแรงมีลักษณะอาการ คือ มีสิवादุดัน มีเลือดคั่ง มีตุ่มนูน ตุ่มหนอง และสิิวอักเสบขนาดใหญ่สีแดงหลายที่รวมถึงมีรอยแผลเป็นจากการเกิดสิว (Titus & Hodge, 2012)

ในยุโรปและสหรัฐอเมริกามีการประเมินความชุกของโรคนี้โดยคิดเป็นจำนวนประมาณ 17 ถึง 45 ล้านคน ซึ่งตัวเลขดังกล่าวอ้างอิงจากงานวิจัยของ Kraning and Odland (1979) ได้ประเมินความชุกของการเกิดสิวของประชากรในช่วงอายุ 12-24 ปี คิดเป็นร้อยละ 85 มักพบในกลุ่มของคนผิวขาวร้อยละ 29.5 และคนผิวสีร้อยละ 27.7 การศึกษาเพิ่มเติมเกี่ยวกับสิวสำหรับวัยรุ่นผู้ใหญ่ในสหราชอาณาจักรและสิงคโปร์ได้ระบุความชุกของการเกิดสิวในวัยรุ่นผู้ใหญ่คิดเป็นร้อยละ 13.7 ของผู้ป่วยผิวสี และ 10.9 ของผู้ป่วยชาวอินเดียและเอเชีย นอกจากนี้ยังแสดงให้เห็นว่าอาการของการอักเสบจากสิวที่ส่งผลให้เกิดลักษณะทางคลินิกคือ Nodulocystic และมักพบได้บ่อยในผู้ป่วยชาวผิวขาว (Caucasian) และชาวสเปน (Hispanic) มากกว่าในผู้ป่วยผิวสี (Goldberg & Berlin, 2012) จากการสำรวจของ Tan and Bhat (2015) พบว่า การเป็นสิวมักมีแนวโน้มที่จะเพิ่มขึ้น โดยคิดเป็นร้อยละ 9.4 ของประชากรโลก และส่งผลให้เกิดโรคทางผิวหนังที่มีการอัตราการเกิดมากเป็นอันดับที่แปด และจากการศึกษาทางด้านการระบาดวิทยาแสดงให้เห็นว่า การเป็นสิวบพบได้บ่อยที่สุดในช่วงอายุ 15-25 ปี ซึ่งเป็นวัยเจริญพันธุ์ โดยเฉพาะเพศชายมักได้รับผลกระทบมากกว่าเพศหญิง อาการแสดงของผู้ที่เป็นสิวที่พบได้บ่อย คืออาการอักเสบบริเวณที่เกิดสิว โดยมีลักษณะ ปวด บวม และแดง นำไปสู่การเกิดเป็น

สิวหัวหนอง รวมไปถึงรอยแผลเป็นที่เกิดขึ้นหลังจากการรักษา ซึ่งสิวกุ่มนี้มักก่อให้เกิดผลกระทบต่อภาพลักษณ์ มีผลต่อความรู้สึกทางใจ และหน้าที่การงาน นอกจากนี้การดูแลและรักษาต้องมีค่าใช้จ่ายที่เพิ่มเข้ามาซึ่งผู้ป่วยต้องแบกรับภาระดังกล่าว จนอาจนำไปสู่ความผิดปกติทางสุขภาพจิต ภาวะซึมเศร้า และการฆ่าตัวตายได้ (Tan & Bhat, 2015)

การเกิดสิวพบได้บ่อยในช่วงวัยรุ่นถึงวัยผู้ใหญ่ เนื่องจากการเปลี่ยนแปลงของฮอร์โมนแอนโดรเจน ปัจจัยการใช้ชีวิต และอาจพบในเด็กด้วย (Zaenglein et al., 2016) โดยมักพบในช่วงอายุ 14–30 ปี สิวในเพศหญิงพบมากกว่าเพศชาย โดยเฉพาะหญิงอายุมากกว่า 25 ปี ซึ่งอาจเกี่ยวข้องกับการใช้เครื่องสำอางและการทำความสะอาดที่ไม่หมดจนเกิดการอุดตันของรูขุมขน (พลูศรี เขตโสภณ, 2549) สิวส่งผลต่อความมั่นใจและก่อให้เกิดความวิตกกังวล แพทย์ควรให้ความรู้เกี่ยวกับทางเลือกการรักษา เช่น ยาทาภายนอกกลุ่มเรตินอยด์ เบนซอยล์เปอร์ออกไซด์ ซัลฟาเซตามายด์ อะเซเลอิกแอซิด และยาปฏิชีวนะชนิดทา (Erythromycin, Clindamycin) สำหรับสิวลเล็กน้อยถึงปานกลาง รวมถึงยาปฏิชีวนะชนิดรับประทาน (Doxycycline, Tetracycline, Minocycline) และยาคุมกำเนิดแอนโดรเจนต่ำในรายที่มีสิวปานกลางถึงรุนแรง ส่วน Isotretinoin ใช้ในสิวอักเสบรุนแรง (Feldman et al., 2004) งานวิจัยนี้จึงนำการเรียนรู้ของเครื่องมาประยุกต์เพื่อวิเคราะห์ระดับความรุนแรงของสิวต่อไป

การเรียนรู้ของเครื่อง (Machine learning) เป็นแกนหลักของสาขาปัญญาประดิษฐ์ที่เป็นวิชาสหสาขาวิชาที่เกี่ยวกับทฤษฎีความน่าจะเป็น สถิติ ทฤษฎีการประมาณ การวิเคราะห์แบบคอนเวกซ์ ทฤษฎีความซับซ้อนของอัลกอริทึม และสาขาวิชาอื่น ๆ ที่เชี่ยวชาญในการจำลองคอมพิวเตอร์หรือใช้พฤติกรรมการเรียนรู้ของมนุษย์เพื่อให้ได้ความรู้หรือทักษะใหม่ ๆ และการจัดระเบียบใหม่ของโครงสร้างความรู้ที่มีอยู่เพื่อปรับปรุงประสิทธิภาพของตนเองโดยทั่วไปแล้วการเรียนรู้ของเครื่อง คือการเรียนรู้กฎระเบียบจากประวัติข้อมูลจำนวนมากผ่านทางอัลกอริทึมที่เกี่ยวข้องและการสร้างการคาดคะเนหรือการตัดสินใจเกี่ยวกับข้อมูลตัวอย่างใหม่ โดยการเรียนรู้แบบสมองของมนุษย์

การเรียนรู้เชิงลึก (Deep learning) เป็นสาขาใหม่ในการเรียนรู้ของเครื่อง ซึ่งเป็นต้นแบบสำหรับการสร้างและจำลองโครงข่ายประสาทของสมองมนุษย์เพื่อการวิเคราะห์และการเรียนรู้ โดยจะเลียนแบบกลไกของสมองของมนุษย์เพื่อตีความข้อมูล เช่น ข้อความ เสียง และภาพ ซึ่งเป็นการเรียนรู้แบบไม่มีผู้ดูแล โดยแนวคิดนี้มาจากการวิจัยโครงข่ายประสาทเทียม ดังนั้นจึงเรียกอีกอย่างว่าโครงข่ายประสาทเทียมแบบลึก เพอร์เซปตรอนหลายชั้นพร้อมเลเยอร์ที่ซ่อนอยู่หลายชั้น คือ โครงสร้างการเรียนรู้เชิงลึกชนิดหนึ่ง คุณสมบัติของการเรียนรู้เชิงลึกที่ได้รับจะแสดงออกผ่านระดับตามระดับและเป็นนามธรรมในระดับสูงมากขึ้น ซึ่งในเชิงความหมายเกิดขึ้นจากการรวมคุณสมบัติระดับต่ำเข้ากับการแสดงการจำแนกคุณลักษณะหรือคุณสมบัติต่าง ๆ เพื่อค้นหาคุณลักษณะที่กระจายของข้อมูล การจำแนกประเภทของรูปภาพเป็นหัวข้อการวิจัยที่ได้รับความนิยมในสังคมปัจจุบันและเป็นทิศทางที่สำคัญในด้านการวิจัยการประมวลผลรูปภาพผ่าน Convolutional neural network (CNN)

เป็นโครงข่ายประสาทเทียมแบบ feedforward ที่มีการคำนวณแบบบิดและมีโครงสร้างที่ลึก ซึ่งมันเป็นหนึ่งในอัลกอริทึมตัวแทนของการเรียนรู้เชิงลึก โดยใช้ SVM และ CNN เป็นตัวอย่าง (Wang et al., 2020) อย่างไรก็ตาม แม้แบบจำลอง Deep Learning จะมีประสิทธิภาพสูง แต่โครงสร้างที่มีความซับซ้อนและจำนวนพารามิเตอร์จำนวนมากทำให้การอธิบายเหตุผลเบื้องหลังการตัดสินใจของแบบจำลองเป็นไปได้ยาก และมักถูกมองว่าเป็นระบบลักษณะ “กล่องดำ” (black box) ซึ่งอาจส่งผลกระทบต่อความน่าเชื่อถือในการนำไปใช้งานจริง โดยเฉพาะในบริบทที่เกี่ยวข้องกับการแพทย์และการดูแลสุขภาพ (Samek et al., 2021) เพื่อตอบโจทย์ข้อจำกัดดังกล่าว ได้มีการพัฒนาเทคนิคสำหรับการอธิบายผลลัพธ์ของแบบจำลองเชิงลึก (Explainable Artificial Intelligence: XAI) ขึ้น โดยหนึ่งในเทคนิคที่ได้รับความนิยมอย่างแพร่หลาย คือ Grad-CAM (Gradient-weighted Class Activation Mapping) ซึ่งเป็นวิธีการอธิบายการตัดสินใจของแบบจำลอง CNN ผ่านการวิเคราะห์ค่า gradient ของคะแนนการทำนายคลาสเป้าหมายที่ไหลย้อนกลับไปยังชั้น convolution สุดท้ายของแบบจำลอง จากนั้นนำมาสร้างเป็นแผนที่การกระตุ้นของคลาสในรูปแบบของแผนที่ความร้อน (heatmap) เพื่อแสดงบริเวณของภาพที่แบบจำลองให้ความสำคัญในการตัดสินใจ (Selvaraju et al., 2017) การประยุกต์ใช้ Grad-CAM ร่วมกับแบบจำลอง Deep Learning ช่วยเพิ่มความโปร่งใสและความสามารถในการตีความผลลัพธ์ของแบบจำลอง ทำให้ผู้วิจัยสามารถตรวจสอบได้ว่าแบบจำลองมุ่งเน้นไปยังบริเวณที่มีความสอดคล้องกับลักษณะเชิงกายภาพหรือพยาธิสภาพที่แท้จริงของข้อมูลภาพ แทนที่จะอาศัยข้อมูลรบกวนหรือปัจจัยภายนอกที่ไม่เกี่ยวข้อง ดังนั้น การนำเทคนิค Grad-CAM มาใช้ร่วมกับแบบจำลอง Deep Learning จึงมีบทบาทสำคัญในการเสริมสร้างความน่าเชื่อถือและความเหมาะสมในการนำแบบจำลองไปประยุกต์ใช้ในงานวิจัยเชิงวิทยาศาสตร์และการแพทย์

ในช่วงทศวรรษที่ผ่านมา การประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning: ML) และการเรียนรู้เชิงลึก (Deep Learning: DL) ในด้านการแพทย์ โดยเฉพาะงานด้านโรคผิวหนังได้รับความสนใจอย่างกว้างขวาง อันเนื่องมาจากความก้าวหน้าของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs) ซึ่งมีประสิทธิภาพสูงในการวิเคราะห์ข้อมูลภาพ จากการศึกษาของงานวิจัยก่อนหน้ารายงานว่าโมเดล CNN สามารถเรียนรู้ลักษณะเชิงซ้อนของรอยโรคผิวหนังจากภาพถ่ายได้อย่างแม่นยำ และให้ผลการจำแนกที่ใกล้เคียงกับการประเมินโดยแพทย์ผู้เชี่ยวชาญ (Esteva et al., 2017; Han et al., 2018) สำหรับงานวิจัยด้านการทำนายและประเมินความรุนแรงของสิว (Acne Prediction and Severity Assessment) นักวิจัยได้พัฒนาโมเดลการเรียนรู้เชิงลึกเพื่อจำแนกชนิดและระดับความรุนแรงของสิวจากภาพถ่ายใบหน้า โดยอาศัยข้อมูลภาพที่มีการกำกับป้ายกำกับจากแพทย์ผิวหนังเป็นข้อมูลอ้างอิง ซึ่งผลการศึกษาล้วนใหญ่ชี้ให้เห็นว่าโมเดล CNN สามารถแยกแยะสิวประเภทต่าง ๆ เช่น สิวอุดตันและสิวกักเสกได้ และมีความสอดคล้องกับการประเมินตามมาตรฐานทางคลินิก (Li et al., 2019) นอกจากนี้ แนวโน้มของงานวิจัยสมัยใหม่ยังให้

ความสำคัญกับการพัฒนาระบบประเมินสิ่วในรูปแบบแอปพลิเคชันหรือเว็บแอปพลิเคชัน เพื่อเพิ่มการเข้าถึงของประชาชนทั่วไป ลดข้อจำกัดด้านเวลาและสถานที่ และสนับสนุนการคัดกรองสุขภาพในระดับเบื้องต้น ซึ่งสอดคล้องกับแนวคิดด้านเศรษฐศาสตร์สาธารณสุข เนื่องจากสิ่วเป็นโรคผิวหนังที่มีความชุกสูงและก่อให้เกิดภาระค่าใช้จ่ายด้านการรักษาในระบบบริการสุขภาพของหลายประเทศ (Bhate & Williams, 2013)

วิทยานิพนธ์ฉบับนี้มุ่งพัฒนาระบบการเรียนรู้เชิงลึกสำหรับวิเคราะห์และจำแนกระดับความรุนแรงของสิ่วบนใบหน้า ผ่านแพลตฟอร์มเว็บแอปพลิเคชันที่ใช้งานได้ง่าย ผู้ใช้เพียงอัปโหลดภาพถ่ายใบหน้าที่ย้ายตามเงื่อนไขที่กำหนด ระบบจะประมวลผลภาพด้วยโมเดลการเรียนรู้เชิงลึกที่ผ่านการฝึกจากข้อมูลตัวอย่างจำนวนมาก แสดงผลการประเมินระดับความรุนแรงของสิ่วเบื้องต้นให้ผู้ใช้งานทันที ข้อเด่นคือสามารถใช้งานได้ทุกที่ทุกเวลาเพียงมีอินเทอร์เน็ตและอุปกรณ์สมาร์ทโฟนหรือคอมพิวเตอร์ ช่วยลดภาระในการเดินทาง เข้าคิวรอพบแพทย์ และลดความแออัดในแผนกโรคผิวหนังของสถานพยาบาลต่าง ๆ ในมิติด้านเศรษฐศาสตร์สาธารณสุข ผลงานวิจัยก่อนหน้านี้รายงานว่า ค่าใช้จ่ายด้านการรักษาสิ่วในบางประเทศ เช่น สหรัฐอเมริกา มีมูลค่าสูงถึงหลายล้านดอลลาร์สหรัฐต่อปี (Bhate & Williams, 2013) การมีเครื่องมือประเมินความรุนแรงของสิ่วเบื้องต้นที่ประชาชนเข้าถึงได้โดยไม่มีค่าใช้จ่าย จึงสามารถช่วยลดค่าใช้จ่ายโดยรวม ทั้งสำหรับผู้ป่วยรายบุคคลและระบบบริการสุขภาพ โดยระบบที่พัฒนาขึ้นไม่เพียงรายงานระดับความรุนแรงของสิ่วเท่านั้น แต่ยังสามารถแนะนำผลิตภัณฑ์ดูแลผิวหรือแนวทางการดูแลสิ่วเบื้องต้นที่เหมาะสมกับระดับความรุนแรงที่ตรวจพบ เพื่อให้ผู้ใช้เริ่มปรับพฤติกรรมและดูแลตนเองได้อย่างถูกต้องมากขึ้น อย่างไรก็ตาม ระบบที่พัฒนาขึ้นไม่ได้มีวัตถุประสงค์เพื่อทดแทนการวินิจฉัยจากแพทย์ผิวหนังโดยตรง หากผลการวิเคราะห์ชี้ให้เห็นว่าสิ่วมีแนวโน้มรุนแรง หรือควรได้รับยารับประทานหรือการรักษาขั้นสูง ผู้ใช้ยังจำเป็นต้องเข้าพบแพทย์ผู้เชี่ยวชาญเพื่อรับการตรวจเพิ่มเติมและรับยาตามความเหมาะสม ในการวิจัยครั้งนี้จึงได้ออกแบบการประเมินความถูกต้องของระบบโดยการจำแนกระดับความรุนแรงของสิ่วจากโมเดลจากการวินิจฉัยภาพถ่ายโดยผู้เชี่ยวชาญด้านผิวหนัง เพื่อทดสอบความสอดคล้องและความน่าเชื่อถือของโมเดลที่พัฒนา ผลจากการพัฒนาโมเดลกล่าวคาค่าจะช่วยยืนยันให้เห็นว่าโมเดลการเรียนรู้เชิงลึกสามารถเป็นเครื่องมือเสริมในการคัดกรองและประเมินสิ่วเบื้องต้นได้อย่างเหมาะสม ช่วยให้ผู้ใช้ได้รับข้อมูลเชิงวัตถุประสงค์เกี่ยวกับสภาพผิวของตนเอง และสามารถนำคำแนะนำเบื้องต้นไปใช้เป็นแนวทางก่อนการตัดสินใจเข้ารับการรักษาได้

1.2 วัตถุประสงค์ของการวิจัย

เพื่อพัฒนาโมเดลจำแนกระดับความรุนแรงของสิวนบนใบหน้าโดยใช้เทคนิคการเรียนรู้เชิงลึก และแสดงให้เห็นถึงการประยุกต์ใช้โมเดลดังกล่าวในรูปแบบเว็บแอปพลิเคชัน

1.3 ประโยชน์ที่คาดว่าจะได้รับการวิจัย

1.3.1 งานวิจัยนี้ก่อให้เกิดแบบจำลองการเรียนรู้เชิงลึก (Deep Learning Model) ที่สามารถจำแนกระดับความรุนแรงของสิวนบนใบหน้าได้อย่างเป็นระบบ ซึ่งสามารถนำไปใช้เป็นเครื่องมือช่วยในการประเมินสภาพผิวเบื้องต้นได้อย่างมีประสิทธิภาพ

1.3.2 ผู้ใช้งานสามารถประเมินอาการสิวนเบื้องต้นของตนเองผ่านเว็บแอปพลิเคชัน และได้รับคำแนะนำในการดูแลรักษาสิวนด้วยตนเอง โดยเว็บแอปพลิเคชันจะให้แนวทางการดูแลผิวและการเลือกใช้ผลิตภัณฑ์ที่เหมาะสมตามระดับความรุนแรงของสิวนที่ตรวจพบ

1.3.3 การประยุกต์ใช้ระบบดังกล่าวสามารถช่วยลดความจำเป็นในการเข้าพบแพทย์ผิวหนังในกรณีที่เป็นการประเมินเบื้องต้น ส่งผลให้ช่วยลดภาระค่าใช้จ่ายและการเดินทางในการเข้ารับบริการทางการแพทย์ของผู้ใช้

1.4 ขอบเขตของการวิจัย

การวิจัยครั้งนี้เป็นการวิจัยเชิงทดลองแบบจริงจัง (True Experimental Research Design) โดยใช้กลุ่มอาสาสมัครจากมหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย จำนวน 524 คน ซึ่งมีการบันทึกภาพถ่ายใบหน้าในสามมุม ได้แก่ ใบหน้าด้านซ้าย ด้านขวา และหน้าตรง รวมทั้งสิ้น 1,572 ภาพ เพื่อนำมาใช้เป็นข้อมูลในการฝึกสอนโมเดลจำแนกระดับความรุนแรงของสิวน การพัฒนาโมเดลการเรียนรู้เชิงลึกสำหรับจำแนกระดับความรุนแรงของสิวนบนใบหน้า ตั้งแต่ระดับที่ 1 ถึงระดับที่ 3 โดยใช้ชุดข้อมูลภาพจากอาสาสมัครดังกล่าว โมเดลที่พัฒนาขึ้นได้รับการออกแบบให้สามารถนำไปประยุกต์ใช้ในรูปแบบเว็บแอปพลิเคชัน สำหรับเว็บแอปพลิเคชันที่สร้างขึ้นนี้ช่วยให้ผู้ใช้ประเมินระดับความรุนแรงของสิวนจากภาพถ่ายใบหน้าได้ด้วยตนเอง พร้อมรับคำแนะนำในการดูแลผิวและผลิตภัณฑ์ที่เหมาะสมตามระดับอาการ ทั้งยังสะท้อนศักยภาพของระบบอัตโนมัติในการสนับสนุนการดูแลผิวเบื้องต้น และลดความจำเป็นในการพบแพทย์ผิวหนังในกรณีที่ไม่เป็นสิวนรุนแรง

บทที่ 2

การทบทวนวรรณกรรม ผลงานวิจัยต่าง ๆ ที่เกี่ยวข้อง

2.1 ลักษณะของสิวและการเกิดสิว

สิวเป็นโรคที่มีลักษณะเฉพาะและพบในมนุษย์เมื่อนั้น อีกทั้งยังมีความเกี่ยวข้องกับต่อมไขมัน ซึ่งมีจำนวนและความหนาแน่นสูงบนหนังศีรษะ หน้าผาก และใบหน้า แม้จะเป็นปัญหาที่พบได้ทั่วไปในระดับสากลในวัยรุ่นที่มีอายุใกล้เคียงกัน ด้วยเหตุผลที่ได้กล่าวมาข้างต้นว่าทำไมต่อมไขมันที่มีปัญหาดังกล่าวจึงสอดคล้องต่อการเกิดสิวและเป็นปัญหาที่มีอยู่จริง แต่ก็ยังเป็นข้อถกเถียงกันอยู่โดยมีการตั้งสมมติฐานเกี่ยวกับทฤษฎีที่น่าสนใจบางประการ เช่น บทบาทในการบำรุงผิวพรรณ การทำงานของภูมิคุ้มกันหรือบางครั้งอาจเกิดได้จากฮอร์โมน (Hormone) แต่ในผิวหนังของวัยรุ่นก่อนเจริญพันธุ์หรือวัยเด็กซึ่งจะมีต่อมไขมันที่ส่วนใหญ่ไม่ทำงาน ถือว่าเป็นต่อมไขมันที่มีสุขภาพดีและไม่พบการอุดตันที่ก่อให้เกิดสิว (Shannon, 2019) สิวยังคงเป็นโรคผิวหนังที่ส่วนมากพบในวัยรุ่นจนถึงวัยผู้ใหญ่ (Goulden et al., 1999) แม้ว่าโดยทั่วไปสิวะจะถือว่าเป็นภาวะที่เกิดเฉพาะในวัยรุ่น ผู้ใหญ่และวัยรุ่นหนุ่มสาว ซึ่งมีอัตราการความชุกร้อยละ 85 แต่สิวะอาจจะยังคงอยู่ในทั้งชายและหญิงจนถึงอายุ 30 และ 40 ปี ซึ่งมีอัตราการความชุกร้อยละ 43 อันที่จริงร้อยละ 5 ของผู้ใหญ่ถึงอายุ 40 ปีขึ้นไปอาจจะยังคงประสบปัญหาสิวะอยู่ (Collier et al., 2008) สิวเป็นโรคที่เกิดจากการอักเสบขึ้นต้นที่เกี่ยวข้องกับหน่วยของรูขุมขนที่มีชื่อว่า Pilosebaceous ซึ่งการเกิดโรคมีหลายปัจจัย โดยเกี่ยวข้องกับปัจจัยสำคัญ 4 ประการที่มีกลไกสัมพันธ์กัน ดังนี้

1. การผลิตซีบัมที่เพิ่มขึ้นหรือมากเกินไป
2. การเพิ่มขึ้นของเคราตินในเซลล์ (Hyperkeratinization) ของรูขุมขนฟอลลิคูลาร์ (Follicular) บนชั้นของผิวหนัง
3. การอักเสบของรูขุมขน
4. สิวที่เกิดจากเชื้อ *Cutibacterium acnes* หรือเดิมชื่อ *Propionibacterium acnes* (Walton et al., 1988)

ซึ่งลักษณะทางคลินิกของสิวะสามารถอธิบายได้ดังต่อไปนี้

1. ไขมันส่วนเกิน (Seborrhea)
2. สิวที่ไม่อักเสบหรือสิวะอุดตันแบบเปิดและแบบปิด (Comedones)
3. สิวอักเสบ (Papules และ Pustules)

4. รอยแผลเป็นหลายระดับ โดยการกระจายของสิวสอดคล้องกับความหนาแน่นสูงสุดของรูขุมขนและการอักเสบของหน่วยรูขุมขน อันเป็นผลจากการผลิตซีบัมที่เพิ่มขึ้นที่ซึ่งมีสาเหตุการเกิดมาจากฮอร์โมนแอนโดรเจน แม้กระทั่งการเปลี่ยนแปลงของเคราตินในเซชัน การอักเสบ และการรวมตัวของแบคทีเรียในรูขุมขนบนใบหน้า คอ หน้าอก และหลัง โดย สาเหตุมาจากเชื้อแบคทีเรีย *C. acnes* (Williams et al., 2012)

สิบบนใบหน้าเป็นปัญหาผิวหนังที่พบบ่อย ซึ่งส่งผลกระทบต่อชีวิตประจำวันและความมั่นใจในตนเองของผู้คนทั่วโลก การจัดระดับความรุนแรงของสิวอย่างแม่นยำเป็นสิ่งสำคัญสำหรับการวางแผนและจัดการการรักษา วิธีการประเมินความรุนแรงของสิวแบบดั้งเดิม เช่น การประเมินโดยแพทย์ผิวหนังและการใช้มาตรฐานต่างๆ แม้จะเชื่อถือได้ แต่ก็มักมีความเป็นส่วนบุคคลและใช้เวลานาน ด้วย การเกิดขึ้นของปัญญาประดิษฐ์ (AI) และการเรียนรู้เชิงลึก (Deep Learning) ความสนใจในการพัฒนาระบบอัตโนมัติสำหรับการจัดระดับสิวและการแนะนำผลิตภัณฑ์รักษาเองก็เพิ่มขึ้น

2.2 *Cutibacterium acnes* และความผิดปกติของหน่วยรูขุมขน-ต่อมไขมัน (Pilosebaceous Unit) ต่อการเกิดสิ้ออักเสบ

สิวเป็นโรคผิวหนังอักเสบเรื้อรังของหน่วยรูขุมขนและต่อมไขมัน (pilosebaceous unit) ซึ่งพบเกือบทั่วร่างกายยกเว้นฝ่ามือและฝ่าเท้า โดยเฉพาะบริเวณใบหน้า หนังศีรษะและลำตัวช่วงบน ที่มีต่อมไขมันขนาดใหญ่และหนาแน่น ทำหน้าที่สร้างและหลั่งซีบัมแบบ holocrine ผ่านรูขุมขน ออกสู่ผิวหนัง (Williams et al., 2012) ภายในสภาวะแวดล้อมที่อุดมด้วยไขมันนี้พบ *C. acnes* ซึ่งเป็นแบคทีเรียรูปแท่งแกรมบวกที่ไม่เคลื่อนไหว พบมากในเด็กและวัยรุ่นที่เป็นสิว โดยจำนวนการสะสมของเชื้อ *C. acnes* สัมพันธ์กับปริมาณซีบัมที่สูงเป็นพิเศษในบริเวณที่มีต่อมไขมันหนาแน่น (McGinley et al., 1980; Cunliffe et al., 1970) ซึ่ง *C. acnes* สามารถผลิตพอร์ไฟริน เช่น coproporphyrin III ที่เรืองแสงภายใต้ Wood's light สังเคราะห์ phosphatidylinositol และมีโครงสร้าง peptidoglycan เฉพาะในผนังเซลล์ รวมทั้งผลิตเอนไซม์โปรตีเอส ไฮยาลูโรนิเดส และไลเปสหลายชนิด ซึ่งเอนไซม์ดังกล่าวร่วมกันกระตุ้นการอักเสบของเนื้อเยื่อและสร้างปฏิสัมพันธ์ที่ซับซ้อนกับระบบภูมิคุ้มกันของโฮสต์ ส่งเสริมให้รอยโรคที่ยังไม่อักเสบและสิวดุดตันพัฒนาเป็นสิ้ออักเสบในผู้ที่มีภูมิคุ้มกันต่อ *C. acnes* สูงขึ้น (Goldberg & Berlin, 2012; Webster et al., 1979) ดังนั้น ความผิดปกติของ Pilosebaceous unit ทั้งการอุดตันของท่อ การสะสมของไขมันหรือเคราติน และการอักเสบของรูขุมขน จึงเป็นกลไกสำคัญที่นำไปสู่การเกิดสิ้อ (Rawlings & Webster, 2007; Eisen et al., 1955)

2.3 การรักษาสิว

การจำแนกระดับความรุนแรงของสิวกับการแนะนำการรักษาเฉพาะบุคคลแสดงถึงความก้าวหน้าอย่างมีนัยสำคัญในการจัดการปัญหาสิวและวิธีการในปัจจุบันยังเกี่ยวข้องกับการรวมผลลัพธ์การจำแนกระดับความรุนแรงกับแนวทางของแพทย์ผิวหนังเพื่อแนะนำผลิตภัณฑ์ที่เหมาะสมหรือการดูแลผิว ในปัจจุบันมีการประยุกต์ใช้ Machine learning models ที่ฝึกด้วยข้อมูลผู้ป่วย รวมถึงผลลัพธ์การรักษา สามารถเพิ่มความเป็นส่วนตัวในการแนะนำเหล่านี้ได้

การศึกษาของ Lee et al. (2024) แสดงให้เห็นถึงความเป็นไปได้ของระบบเหล่านี้ โดยใช้ Decision Tree ในการตัดสินใจและอัลกอริทึมการแนะนำ เพื่อเสนอผลิตภัณฑ์ตามความรุนแรงของสิวและประเภทผิว อย่างไรก็ตาม การรวมการเรียนรู้เชิงลึกกับฐานข้อมูลการรักษาครบวงจรยังคงจำเป็นและต้องการการตรวจสอบเพิ่มเติม เพื่อพัฒนาต่อไปในอนาคต (Lee et al., 2024)

2.3.1 การรักษาสิวโดยไม่ใช้ยา (Nonpharmacologic therapy)

จากการที่สิวมักเป็นในช่วงอายุตั้งแต่วัยรุ่น และจะค่อยๆ ดีขึ้นได้ แม้ว่าการเป็นสิวเพียงเล็กน้อยอาจไม่จำเป็นต้องใช้ยา แต่ก็ยังคงมีความเข้าใจคลาดเคลื่อนหลายประการเกี่ยวกับการดูแลรักษาสิว เช่น การขัดหน้าด้วยผลิตภัณฑ์ขัดผิว (Scrubbing agent) หรือการล้างหน้าบ่อย ๆ ไม่ได้ช่วยให้ลดการเกิดสิวเนื่องจากการเกิดสิวยู่ในระดับที่ลึกคือการอักเสบในรูขุมขน (Follicle) และต่อมไขมัน (Sebaceous gland) และตัวอย่างที่ยกมาข้างต้นอาจส่งผลทำให้เกิดการระคายเคืองผิว การล้างหน้าด้วยสบู่หรือน้ำช่วยลดปริมาณไขมัน (Sebum) ตลอดจนแบคทีเรียบนผิวหนังได้ แต่ก็ยังคงมีผลเพียงเล็กน้อยกับรูขุมขน รวมทั้งการใช้ผลิตภัณฑ์ชำระล้างต่าง ๆ ควรระวังเกี่ยวกับการระคายเคืองและการเกิดผื่นแดงซึ่งจะกระตุ้นให้ผิวหนังสร้างไขมันมากขึ้นดังนั้นควรเลือกใช้ผลิตภัณฑ์ที่เหมาะสมอ่อนโยนและไม่ทำให้ผิวแห้ง เป็นหลัก (กุสาวดี เมลิ่งอนนท์, ม.ป.ป.; De Vries et al., 2018)

สารสำคัญที่มีการใช้ในผลิตภัณฑ์ดูแลผิว (Skincare active ingredient) ที่มาจากสารสกัดธรรมชาติช่วยปลอบประโลมผิวและลดการอักเสบของผิว การดูแลผิวโดยไม่ใช้ยามักอาศัยผลิตภัณฑ์บำรุงผิวที่มีสารออกฤทธิ์เหมาะสม โดยสารจากธรรมชาติที่ช่วยปลอบประโลมและลดการอักเสบได้แก่ แปะกัวย วานหางจระเข้ ชาเขียว อลันโทอิน ไลโคซาโคนจากรากชะเอม และไบบับก ซึ่งมีคุณสมบัติต้านการอักเสบ ต้านอนุมูลอิสระ เสริมความชุ่มชื้น และช่วยฟื้นฟูเกราะป้องกันผิว สารเหล่านี้มักถูกผสมรวมกันในมอยส์เจอร์ไรเซอร์ ครีม เจล หรือเซรัม เพื่อเสริมฤทธิ์ซึ่งกันและกันและเหมาะสมกับผิวแพ้ง่ายหรือผิวเป็นสิวง่าย

นอกจากนี้ สารออกฤทธิ์เฉพาะสำหรับการดูแลผิว เช่น ซิงค์ PCA และนิโคตินาไมด์ (วิตามิน B3) ช่วยควบคุมความมัน ลดการอักเสบ ต้านจุลชีพ และเสริมเกราะป้องกันผิว มักใช้ร่วมกันเพื่อเพิ่ม

ประสิทธิภาพ ขณะที่กรดไฮดรอกซีต่าง ๆ ได้แก่ AHA, BHA, PHA และ LHA มีบทบาทในการผลัดเซลล์ผิว โดยเลือกใช้ตามสภาพผิวและความทนของผิว แนวโน้มการดูแลผิวในปัจจุบันจึงมุ่งเน้นผลิตภัณฑ์อ่อนโยนจากธรรมชาติและสูตรหลายฟังก์ชัน เพื่อดูแลปัญหาผิวควบคู่กับการรักษาสมดุลและสุขภาพผิวในระยะยาว (Draelos et al., 2006; Brandt et al., 2011; Draelos, 2006; Fluhr et al., 2003; Wang & Saedi, 2019; Kubo & Matsumoto, 2020; Layton & Eady, 2011) ส่วนผสมจากธรรมชาติและพืช มีความต้องการเพิ่มขึ้นสำหรับผลิตภัณฑ์ดูแลผิวจากธรรมชาติและพืช ผู้บริโภคชื่นชอบสารสกัดจากพืชเนื่องจากการรับรู้ถึงความปลอดภัยและประสิทธิภาพของพวกเขา ผลิตภัณฑ์หลายฟังก์ชัน ผลิตภัณฑ์ที่รวมส่วนผสมออกฤทธิ์หลายชนิดเพื่อจัดการกับปัญหาผิวหลายประการพร้อมกันนั้นได้รับความนิยม ตัวอย่างเช่น มอยส์เจอไรเซอร์ที่มีว่านหางจระเข้และชาเขียว สามารถให้ความชุ่มชื้น บรรเทา และให้การปกป้องต้านอนุมูลอิสระ

2.3.2 การใช้ยารักษาสิว (Pharmacologic therapy)

การใช้ยารักษาสิวมุ่งเป้าหมายสำคัญ คือป้องกันการเกิดสิว กำจัดสิวที่เกิดขึ้นลดการผลิตไขมันจากต่อมไขมัน เร่งให้การอักเสบหายเร็วขึ้นและรักษาแผลเป็นให้ดีขึ้นโดยการรักษาสิวด้วยการใช้ยา ในที่นี้จะให้รายละเอียดของการรักษาสิวด้วยการใช้ยาทาและยารับประทาน (พลูศรี เขตโสภณ, 2549). ซึ่งเป็นที่คุ้นกันโดยทั่วไป

1. การใช้ยาทาหรือการรักษาเฉพาะที่ แบ่งได้ดังนี้

- 1) ยาที่ออกฤทธิ์ละลายขุย (Keratolytics) ได้แก่ 5-10% Salicylic acid lotion, 3-40% Sulphur lotion, 3% Resorcinol cream or lotion
- 2) ยาที่ออกฤทธิ์ละลายหัวสิว (Comedolytics) ได้แก่ 0.025-0.1% Tretinoic acid, Adapalene
- 3) ยาต้านแบคทีเรีย เช่น 2.5-10% Benzoyl peroxide, Tetracycline, Erythromycin หรือ clindamycin ในรูปของ Lotion และ Azelaic acid 15-20% cream (กุสาวดี เมลืองนนท์, ม.ป.ป.; Eichenfield et al., 2013.; Purath & Coyner, 2017)

2. การรับประทานยารักษาสิว (ควรอยู่ภายใต้การดูแลของแพทย์ผู้เชี่ยวชาญด้านผิวหนัง)

การรักษาโดยรับประทานได้แก่การใช้ยาปฏิชีวนะชนิดรับประทานได้แก่ยาปฏิชีวนะในกลุ่ม Tetracycline, Doxycycline, และ Macrolide ยาปฏิชีวนะนั้นมีที่ใช้ในสิวะระดับความรุนแรง-ปานกลาง ซึ่งมีตุ่มหนอง Papular/ Pustular หรือตุ่มแดงใหญ่ลักษณะ Nodule เพื่อลดปริมาณของเชื้อ *C. acnes* ยาปฏิชีวนะในกลุ่มของ Macrolides ที่มีการใช้เพื่อรักษาสิวดได้แก่ Erythromycin, Azithromycin, Clindamycin ส่วน Cotrimoxazole มีการนำมาใช้ในรายที่ไม่ตอบสนองต่อการรักษาด้วย Tetracycline หรือ Erythromycin แล้วหรือเรียกอีกอย่างว่า เชื้อดื้อยา

ยารับประทานอีกชนิดที่มีการใช้กันแพร่หลายคือ Oral retinoid เช่น Isotretinoin ใช้ในรายที่เป็นสิ่ว ระดับรุนแรงประกอบด้วยตุ่มแดงใหญ่หรือตุ่มหนองขนาดใหญ่ เป็น Treatment of choice ใน Severe nodulocystic acne หรือในรายที่ใช้ยารักษาสิ่วทั่วไปไม่ได้ผล

มีการใช้ฮอร์โมนเพศที่มีฤทธิ์ Antiandrogen ในการรักษาสิ่วในเพศหญิง ได้แก่ Cyproterone acetate รวมทั้งการใช้ Spironolactone เนื่องจากมีฤทธิ์ Antiandrogen (กุลสาวดี เมลียงนนท์, ม.ป.ป.; Feldman et al., 2004; Oge et al., 2019; Purath & Coyner, 2017)

3. การใช้ยาฉีดยา

ส่วนยาฉีดยาจะเป็นการรักษาสิ่วที่มีความรุนแรงมากเช่นถุงหนองและอยู่ภายใต้การดูแลของแพทย์ผู้เชี่ยวชาญด้านผิวหนัง (กุลสาวดี เมลียงนนท์, ม.ป.ป.; Zaenglein et al., 2016)

2.4 การจำแนกระดับความรุนแรงของสิ่ว

การจำแนกระดับความรุนแรงของสิ่วอาศัยเกณฑ์หลักจากลักษณะทางคลินิกของรอยโรคบนผิวหนัง โดยพิจารณาจาก ชนิด จำนวน การกระจายตัว และระดับการอักเสบของสิ่ว เป็นสำคัญ ระบบที่ใช้กันทั่วไป เช่น GAGS และ IGA (Wang et al., 2019) มีเกณฑ์ร่วมกันดังนี้

1. ชนิดของรอยโรค (Type of lesion) พิจารณาว่าเป็นสิ่วไม่อักเสบ (สิ่วอุดตันหัวเปิด-หัวปิด) หรือสิ่วอักเสบ (papule, pustule, nodule, cyst) โดยชนิดที่มีการอักเสบรุนแรงจะถูกจัดอยู่ในระดับที่สูงกว่า

2. จำนวนรอยโรค (Number of lesions) นับจำนวนสิ่วในบริเวณที่ประเมิน ยิ่งจำนวนมาก ความรุนแรงยิ่งสูง

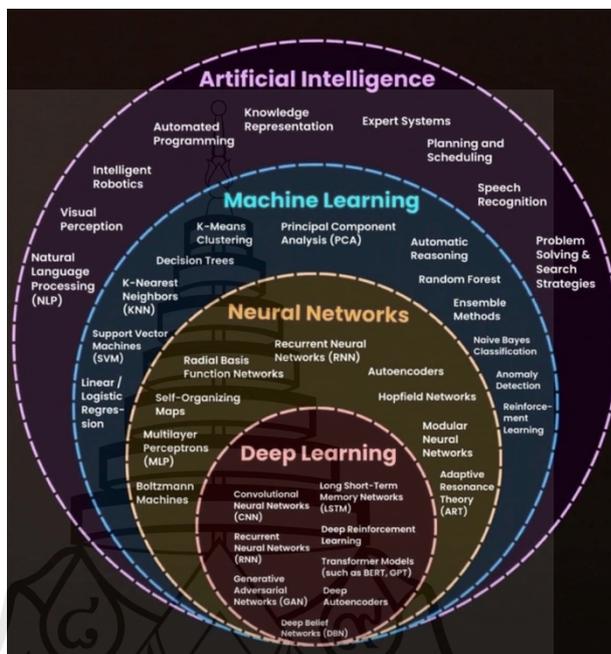
3. ความรุนแรงของการอักเสบ (Severity of inflammation) ประเมินจากขนาด ความแดง อาการบวม เจ็บ และการเกิดก้อนลึกใต้ผิวหนัง

4. ตำแหน่งและการกระจายตัว (Anatomical distribution) พิจารณาบริเวณที่เกิดสิ่ว เช่น ใบหน้า หน้าอก หลัง ซึ่งบางระบบให้น้ำหนักคะแนนต่างกันตามตำแหน่ง

5. ภาพรวมทางคลินิก (Global assessment) เป็นการประเมินภาพรวมของสภาพผิวและสิ่วทั้งหมด เพื่อจัดระดับตั้งแต่เล็กน้อย ปานกลาง ไปจนถึงรุนแรง

เกณฑ์เหล่านี้เป็นพื้นฐานในการจัดระดับความรุนแรงของสิ่ว เพื่อใช้ในการวางแผนการรักษา การติดตามผล และการเปรียบเทียบผลการรักษาทางคลินิกอย่างเป็นระบบ

2.5 การอธิบายภาพรวมและองค์ประกอบในส่วนต่าง ๆ ของปัญญาประดิษฐ์ (Artificial Intelligence หรือ AI)



ที่มา Khan (2024)

ภาพที่ 2.1 การอธิบายองค์ประกอบสำหรับปัญญาประดิษฐ์

2.5.1 ปัญญาประดิษฐ์ (Artificial Intelligence หรือ AI)

ปัญญาประดิษฐ์ คือ การจำลองกระบวนการทางปัญญาของมนุษย์โดยเปรียบเทียบ AI หรือสมองกล โดยเฉพาะระบบคอมพิวเตอร์ กระบวนการเหล่านี้รวมถึงการเรียนรู้ (การได้มาซึ่งข้อมูลและกฎเกณฑ์ในการใช้ข้อมูล) การให้เหตุผล (การใช้กฎเกณฑ์เพื่อให้ได้ข้อสรุปที่ใกล้เคียงหรือแน่นอน) และการแก้ไขตัวเอง คำว่า AI มักถูกใช้กับระบบที่แสดงลักษณะของปัญญามนุษย์ที่คล้ายคลึงกับมนุษย์ เช่น การเข้าใจภาษา การจดจำรูปแบบ การแก้ปัญหา และการเรียนรู้จากประสบการณ์ (Russell & Norvig, 2020) ปัญญาประดิษฐ์ เป็นอีกหนึ่งสาขาของวิทยาการคอมพิวเตอร์ที่มุ่งเน้นการพัฒนา Machine learning ให้สามารถทำงานและคิดใกล้เคียงกับมนุษย์ให้ได้มากที่สุด ซึ่งปัญญาประดิษฐ์ประกอบด้วยหลาย ๆ ด้านหลัก ได้แก่ การประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) การรับรู้ทางสายตา (Visual Perception) หุ่นยนต์ที่มีปัญญา (Intelligent Robotics) โปรแกรมอัตโนมัติ (Automated Programming) การแสดงความรู้ (Knowledge Representation) ระบบผู้เชี่ยวชาญ (Expert Systems) การวางแผนและตารางเวลา (Planning and Scheduling) การรับรู้เสียง (Speech Recognition)

2.5.2 การเรียนรู้ของเครื่อง (Machine learning)

การเรียนรู้ของเครื่อง (Machine learning หรือ ML) เป็นศาสตร์และศิลป์ในการสร้างอัลกอริทึมเพื่อให้คอมพิวเตอร์เรียนรู้จากข้อมูลโดยไม่ต้องตั้งโปรแกรมไว้อย่างชัดเจน ซึ่งโมเดลการเรียนรู้ของเครื่องจะถูกใช้เป็นหลักในการทำนาย (Prediction) และจำแนกประเภท (Classification) การเรียนรู้ของเครื่องซึ่งมีการเรียนรู้เชิงลึก (Deep learning) เป็นชุดย่อยอย่างมีนัยสำคัญที่อธิบายว่าอัลกอริทึม (algorithm) เป็นการศึกษาของเครื่องและแบบจำลองข้อมูลที่สามารถทำงานได้โดยใช้คอมพิวเตอร์โดยไม่ต้องตั้งโปรแกรมไว้อย่างชัดเจนเพื่อทำงานเหล่านั้นให้สำเร็จ โดย ML จะอาศัยการตรวจจับรูปแบบข้อมูลและสร้างการอนุมานเกี่ยวกับข้อมูลแทน ซึ่งประเภทหลัก ๆ มีอยู่ด้วยกัน 4 ประเภทที่เป็นตัวกำหนดให้กับ ML ซึ่งประเภทเหล่านี้ คือ การตรวจจับ (Detection) การจำแนก (Classification) การรับรู้ (Recognition) การทำนาย (Prediction) (Norris, 2020) Machine learning มีหลายวิธีด้วยกันในการเรียนรู้จากข้อมูล โดยสามารถจัดหมวดหมู่อัลกอริทึมตามรูปแบบการเรียนรู้ต่าง ๆ ได้ ซึ่งทั้งนี้ขึ้นอยู่กับผลลัพธ์ที่คาดหวังและประเภทของการป้อนข้อมูลที่ระบุรูปแบบที่เลือกใช้นั้นขึ้นอยู่กับประเภทของข้อมูลที่มีอยู่และผลลัพธ์ที่คาดหวัง รูปแบบของ Machine Learning สามารถแบ่งออกเป็นหลายประเภทตามลักษณะและวิธีการที่ใช้ในการเรียนรู้ข้อมูลรวมถึงการสร้างอัลกอริทึม ซึ่งสามารถแบ่งออกเป็น 4 ประเภทหลัก ดังนี้ การเรียนรู้แบบมีผู้สอน (Supervised) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised) การเรียนรู้ด้วยตนเอง (Self-supervised) การเรียนรู้แบบลองผิดลองถูก (Reinforcement) เป็นต้น

การเรียนรู้ของเครื่อง (Machine Learning) เป็นกระบวนการที่ใช้ในการทำให้คอมพิวเตอร์เรียนรู้จากข้อมูลและประสบการณ์ที่ผ่านมา ซึ่งเป็นกระบวนการที่อาศัยการวิเคราะห์และการเรียนรู้จากข้อมูลเพื่อให้ AI สามารถปรับตัวและทำนายผลลัพธ์ได้โดยอัตโนมัติ นี่เป็นส่วนหนึ่งของสมองของ AI ที่สามารถทำได้ โดยมีเทคนิคหลากหลาย เช่น Linear/Logistic Regression, Support Vector Machines (SVM), K-Nearest Neighbours (KNN), Decision Trees, K-Mean Clustering, Principal Component Analysis (PCA), Automatic Reasoning, Random Forest, Ensemble Methods, Naive Bayes, และ Anomaly Detection

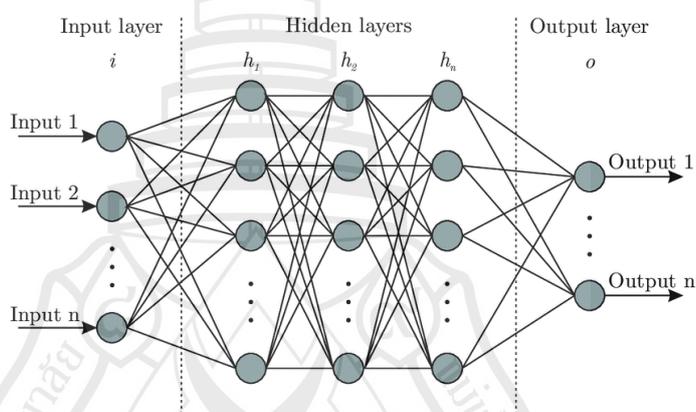
เทคนิคเหล่านี้เป็นเครื่องมือที่มีประโยชน์ในการวิเคราะห์ข้อมูลและการทำนายที่หลากหลายและใช้งานกันอย่างแพร่หลายในวงการวิทยาศาสตร์ข้อมูลและปัญญาประดิษฐ์ในปัจจุบัน การเรียนรู้เหล่านี้ทำให้ระบบ AI สามารถปรับปรุงและพัฒนาการทำงานของตนเองได้โดยไม่ต้องมีการโปรแกรมมิ่งโดยตรง และเป็นพื้นฐานสำคัญในการพัฒนา AI ไปในอนาคต

2.5.3 โครงข่ายประสาทเทียม (Neural Networks)

โครงข่ายประสาทเทียม (Neural Networks) เป็นแบบจำลองทางคณิตศาสตร์ที่ได้รับแรงบันดาลใจจากการทำงานของระบบประสาทมนุษย์ และถูกนำมาใช้อย่างแพร่หลายในงานด้านการ

เรียนรู้ของเครื่อง (Machine Learning) และปัญญาประดิษฐ์ (Artificial Intelligence) โดยเฉพาะงานด้านการจำแนกและการทำนายข้อมูล โดยมีลักษณะหลากหลายประเภท ได้แก่ Boltzmann Machines, Multilayer Perceptrons (MLP), Self-Organizing Maps (SOM), Radial Basis Function Networks (RBFN), Recurrent Neural Networks (RNN), Autoencoders, Hopfield Networks, Adaptive Resonance Theory (ART) ดังแสดงในภาพที่ 2.1

โครงสร้างพื้นฐานของโครงข่ายประสาทเทียมประกอบด้วยหน่วยประมวลผลพื้นฐานที่เรียกว่า เซลล์ประสาทเทียม (Artificial Neuron หรือ Perceptron) ซึ่งทำหน้าที่รับอินพุต คำนวณผลรวมถ่วงน้ำหนักพร้อมกับค่าอคติ (bias) และส่งผ่านฟังก์ชันกระตุ้น (activation function) เพื่อให้ได้ผลลัพธ์



ที่มา King Mongkut's Institute of Technology Ladkrabang (n.d.)

ภาพที่ 2.2 โครงสร้างพื้นฐานของโครงข่ายประสาทเทียมแบบ Multi-layer

เมื่อมีการเชื่อมต่อ Perceptron หลายหน่วยเข้าด้วยกัน จะเกิดเป็น โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Neural Network) ซึ่งโดยทั่วไปประกอบด้วย 3 ส่วนหลัก ดังภาพที่ 2.2 ได้แก่

1. ชั้นอินพุต (Input Layer)
2. ชั้นซ่อน (Hidden Layers)
3. ชั้นเอาต์พุต (Output Layer)

การทำงานของโครงข่ายประสาทเทียมแบบหลายชั้นอาศัยกระบวนการ Feedforward ในการส่งข้อมูลจากชั้นอินพุตไปยังชั้นเอาต์พุต และใช้กระบวนการ Backpropagation ในการปรับค่าน้ำหนักและค่าอคติของโครงข่าย เพื่อลดค่าความผิดพลาดระหว่างผลลัพธ์ที่ทำนายกับค่าจริง โดยอาศัยวิธี Gradient Descent

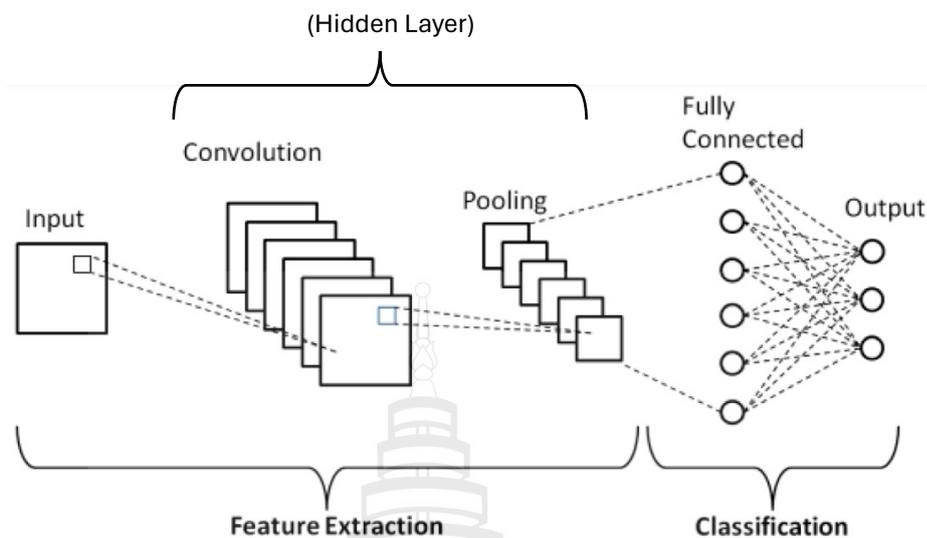
โครงข่ายประสาทเทียมแบบหลายชั้นถือเป็นพื้นฐานสำคัญของเทคนิคการเรียนรู้เชิงลึก (Deep Learning) และเป็นรากฐานของ Convolutional Neural Networks (CNN) ซึ่งเป็นโครงสร้างที่เหมาะสมอย่างยิ่งสำหรับงานวิเคราะห์และจำแนกภาพ เช่น การจำแนกระดับความรุนแรงของสีจากภาพถ่ายผิวหนัง

2.5.4 การเรียนรู้เชิงลึก (Deep learning)

การเรียนรู้เชิงลึก (Deep Learning) เป็นแขนงหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Deep Neural Networks) เพื่อเรียนรู้รูปแบบและคุณลักษณะที่มีความซับซ้อนจากข้อมูลจำนวนมาก โดยเฉพาะข้อมูลเชิงภาพ เสียง และข้อความ (Goodfellow et al., 2016) ความลึกของโครงข่ายหมายถึงจำนวนชั้นของเลเยอร์ที่ข้อมูลต้องผ่าน ตั้งแต่ชั้นอินพุตจนถึงชั้นเอาต์พุต ซึ่งช่วยให้โมเดลสามารถเรียนรู้คุณลักษณะในหลายระดับ ตั้งแต่คุณลักษณะพื้นฐานไปจนถึงคุณลักษณะเชิงนามธรรม

ในงานด้านการจำแนกภาพ การเรียนรู้เชิงลึกมักใช้การเรียนรู้แบบมีผู้สอน (Supervised Learning) โดยอาศัยข้อมูลภาพที่มีการกำหนดป้ายกำกับ (label) เพื่อฝึกสอนโมเดลให้สามารถเชื่อมโยงคุณลักษณะของภาพกับผลลัพธ์ที่ต้องการได้อย่างถูกต้อง (Norris, 2020; Sheel, 2020) นี้คือตัวอย่างบางประการหลัก ๆ ที่เกี่ยวข้องกับการเรียนรู้เชิงลึก ดังแสดงในภาพที่ 2.1 ได้แก่ Convolutional Neural Networks: CNN, Generative Adversarial Networks – GAN, Long Short-Term Memory Networks – LSTM, Deep Reinforcement Learning, Transformer Models, Deep Autoencoders, Deep Belief Networks – DBN (Raghu & Schmidt, 2020)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) เป็นสถาปัตยกรรมของการเรียนรู้เชิงลึกที่ได้รับการออกแบบมาเพื่อประมวลผลข้อมูลเชิงภาพโดยเฉพาะ โดยสามารถเรียนรู้คุณลักษณะเชิงพื้นที่ของภาพได้อย่างมีประสิทธิภาพ เช่น ขอบ สี พื้นผิว และรูปทรง (LeCun et al., 1998) ด้วยความสามารถดังกล่าว CNN จึงถูกนำมาใช้อย่างแพร่หลายในงานด้านการจำแนกและวิเคราะห์ภาพ โครงสร้างพื้นฐานของ CNN สามารถแบ่งออกเป็น 2 ส่วนหลัก ได้แก่ ส่วนการสกัดคุณลักษณะ (Feature Extraction) และส่วนการจำแนกประเภท (Classification) (Chayatummagoon & Chongstitvatana, 2021) ดังแสดงในภาพที่ 2.3



ที่มา Rhee (2018)

ภาพที่ 2.3 แสดงรายละเอียดองค์ประกอบของ Convolutional neural networks

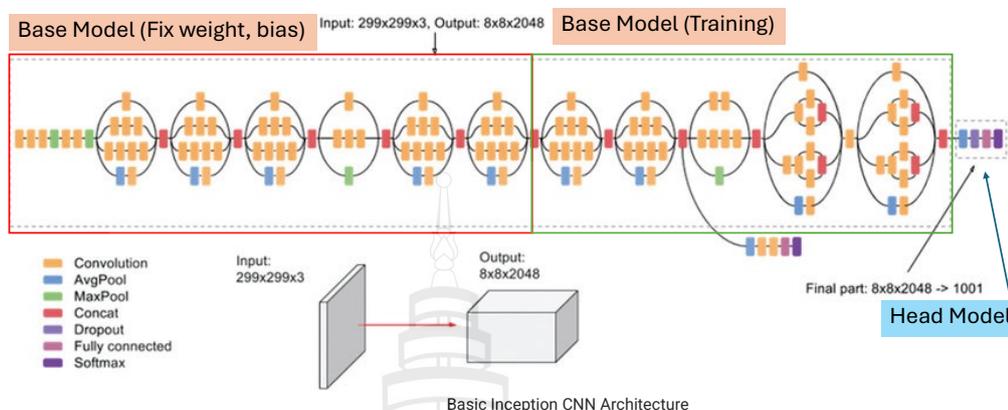
ส่วนการสกัดคุณลักษณะ (Feature Extraction) ส่วนการสกัดคุณลักษณะมีหน้าที่เรียนรู้ลักษณะสำคัญจากภาพอินพุต โดยประกอบด้วยเลเยอร์หลัก ได้แก่

1. ชั้นคอนโวลูชัน (Convolutional Layer) ทำหน้าที่สกัดคุณลักษณะจากภาพอินพุต โดยใช้ฟิลเตอร์หรือเคอร์เนล (Kernel) ซึ่งสามารถเรียนรู้ค่าได้จากข้อมูลฝึกสอน (LeCun et al., 1998; Uchida et al., 2018)
2. ฟังก์ชันการกระตุ้น (Activation Function) ทำหน้าที่เพิ่มความไม่เป็นเชิงเส้นให้กับโมเดล เพื่อให้สามารถเรียนรู้รูปแบบที่มีความซับซ้อนได้มากขึ้น (Nair & Hinton, 2010; Wang et al., 2020)
3. ชั้นพูลลิ่ง (Pooling Layer) ทำหน้าที่ลดขนาดเชิงพื้นที่ของข้อมูล โดยยังคงรักษาคุณลักษณะที่สำคัญไว้ ช่วยลดภาระในการคำนวณและลดปัญหาการเกิด overfitting (Scherer et al., 2010; Gholamalinezhad & Khosravi, 2020)

ส่วนการจำแนกประเภท (Classification) หลังจากการสกัดคุณลักษณะ ข้อมูลจะถูกส่งไปยังส่วนการจำแนกประเภท ซึ่งประกอบด้วยชั้นเชื่อมต่ออย่างสมบูรณ์ (Fully Connected Layer) และชั้นเอาต์พุต (Output Layer) เพื่อให้ได้ผลลัพธ์การจำแนกตามที่กำหนดไว้ (Chollet, 2017)

งานวิจัยนี้ประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ในการวิเคราะห์และจำแนกภาพ โดยข้อมูลภาพจะถูกใช้เป็นข้อมูลนำเข้า (input) ของโมเดล และดำเนินการฝึกสอนแบบมีผู้สอน (Supervised Learning) เพื่อให้โมเดลสามารถจำแนกระดับความรุนแรงของสีจากภาพถ่าย

ผิวหนังได้อย่างมีประสิทธิภาพ รายละเอียดของโครงสร้างโมเดลและกระบวนการฝึกสอนจะนำเสนอในบทถัดไป



ที่มา Praseetha et al. (2019)

ภาพที่ 2.4 ตัวอย่างโครงสร้างการทำ Model Fine-Tuning

2.6 การเรียนรู้แบบถ่ายโอน (Transfer Learning)

การเรียนรู้แบบถ่ายโอน (Transfer Learning) เป็นเทคนิคหนึ่งของการเรียนรู้ของเครื่องที่ได้รับ ความนิยมอย่างแพร่หลายในงานด้านคอมพิวเตอร์วิทัศน์ (Computer Vision) โดยเป็นแนวทางที่นำ ความรู้จากโมเดลที่ผ่านการฝึกสอนมาแล้วบนชุดข้อมูลขนาดใหญ่มาประยุกต์ใช้กับงานใหม่ที่มี ลักษณะใกล้เคียงกัน (Pan & Yang, 2010; Goodfellow et al., 2016) เทคนิคนี้ช่วยลดระยะเวลา ในการฝึกโมเดล ลดความต้องการทรัพยากรในการประมวลผล และเพิ่มประสิทธิภาพของโมเดลใน กรณีที่ชุดข้อมูลมีขนาดจำกัด โดยทั่วไป Transfer Learning มักใช้โมเดลที่ผ่านการฝึกสอนจากชุด ข้อมูลขนาดใหญ่ เช่น ImageNet เป็นโมเดลตั้งต้น ซึ่งโมเดลเหล่านี้สามารถเรียนรู้คุณลักษณะทั่วไป ของภาพ เช่น ขอบ รูปร่าง และพื้นผิว ซึ่งสามารถนำไปปรับใช้กับงานจำแนกภาพในโดเมนเฉพาะได้ อย่างมีประสิทธิภาพ (Tan et al., 2018; Weiss et al., 2016) ดังแสดงในภาพที่ 2.4 ได้แก่

1. การใช้โมเดลเพื่อสกัดคุณลักษณะ (Feature Extraction) เป็นการใช้คุณลักษณะที่ โมเดลที่ผ่านการฝึกมาแล้วได้เรียนรู้ในเลเยอร์ก่อนหน้า โดยคงค่าน้ำหนักของโมเดลเดิมไว้ และ ปรับเปลี่ยนเฉพาะเลเยอร์สำหรับการจำแนกประเภทให้เหมาะสมกับงานใหม่
2. การปรับแต่งโมเดล (Fine-Tuning) เป็นการปรับค่าน้ำหนักของบางเลเยอร์ในโมเดลที่ ผ่านการฝึกมาแล้ว เพื่อให้สามารถเรียนรู้ลักษณะเฉพาะของข้อมูลในงานใหม่ได้ดียิ่งขึ้น โดยแนวทางนี้ เหมาะสำหรับกรณีที่ข้อมูลมีความแตกต่างจากชุดข้อมูลต้นทางหรือมีความซับซ้อนสูง

งานวิจัยนี้ประยุกต์ใช้เทคนิค Transfer Learning ร่วมกับโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เพื่อการจำแนกภาพ โดยเลือกใช้โมเดลที่ผ่านการฝึกสอนมาแล้วเป็นโมเดลตั้งต้น และปรับโครงสร้างส่วนการจำแนกประเภทให้เหมาะสมกับชุดข้อมูลภาพถ่ายผิวหนัง การใช้ Transfer Learning ช่วยให้โมเดลสามารถเรียนรู้ได้อย่างมีประสิทธิภาพแม้ในกรณีที่จำนวนข้อมูลฝึกสอนมีจำกัด และช่วยลดเวลาในการฝึกโมเดลเมื่อเปรียบเทียบกับวิธีการฝึกโมเดลตั้งแต่เริ่มต้น

2.7 โครงสร้างของโมเดลที่ใช้สำหรับ Transfer Learning

2.7.1 GoogLeNet

GoogLeNet เป็นโครงข่ายประสาทเทียมแบบ Convolutional Neural Network (CNN) ที่พัฒนาโดย Google และได้รับรางวัลชนะเลิศจากการแข่งขัน ILSVRC ปี ค.ศ. 2014 โดยมีจุดเด่นอยู่ที่สถาปัตยกรรม Inception ซึ่งสามารถประมวลผลคุณลักษณะของภาพในหลายสเกลพร้อมกันผ่านฟิลเตอร์หลายขนาดภายในเลเยอร์เดียว ทำให้โครงข่ายสามารถสกัดคุณลักษณะที่มีความหลากหลายได้อย่างมีประสิทธิภาพ โครงสร้างของ GoogLeNet มีความลึกประมาณ 22 เลเยอร์ และประกอบด้วย Inception modules หลายชุด โดยใช้ Global Average Pooling เพื่อลดจำนวนพารามิเตอร์และลดปัญหา Overfitting นอกจากนี้ยังมีการเพิ่ม Auxiliary Classifiers ในชั้นกลางของโครงข่ายเพื่อช่วยแก้ปัญหาการสูญหายของ Gradient ในโครงข่ายที่มีความลึกสูง ส่งผลให้การฝึกโมเดลมีความเสถียรและมีประสิทธิภาพมากขึ้น (Szegedy et al., 2015)

2.7.2 Residual Block ใน ResNet

Residual Block เป็นองค์ประกอบหลักของสถาปัตยกรรม Residual Network (ResNet) ซึ่งถูกออกแบบมาเพื่อแก้ปัญหาการสูญหายของ Gradient ในโครงข่ายประสาทเทียมที่มีความลึกสูง โดยอาศัยแนวคิดของ Residual Learning ผ่านการเชื่อมต่อแบบทางลัด (Skip Connection) หลักการทำงานของ Residual Block คือการนำอินพุตเดิมมารวมกับผลลัพธ์ที่ผ่านเลเยอร์ Convolutional ก่อนส่งผ่านฟังก์ชันกระตุ้น ซึ่งช่วยให้ข้อมูลและ Gradient สามารถส่งผ่านไปยังเลเยอร์ลึกได้อย่างมีประสิทธิภาพ ส่งผลให้การฝึกโมเดลมีเสถียรภาพและสามารถสร้างโครงข่ายที่มีความลึกมากขึ้นได้

2.7.3 ResNet-18

ResNet-18 เป็นโครงข่ายประสาทเทียมเชิงลึกที่ประกอบด้วย 18 เลเยอร์ และใช้ Residual Blocks เป็นโครงสร้างหลัก โมเดลนี้มีความเหมาะสมสำหรับงานที่ต้องการความสมดุลระหว่างประสิทธิภาพและภาระการคำนวณ โดยสามารถเรียนรู้คุณลักษณะเชิงลึกได้โดยไม่ประสบปัญหา

Gradient Vanishing ด้วยจำนวนเลเยอร์ที่ไม่ลึกมาก ResNet-18 จึงมีความรวดเร็วในการฝึกและใช้ทรัพยากรการคำนวณน้อยกว่า ResNet รุ่นที่ลึกกว่า ทำให้เหมาะสมสำหรับการนำไปประยุกต์ใช้ในงานจำแนกภาพที่มีความซับซ้อนระดับต่ำถึงปานกลาง

2.7.4 ResNet-50

ResNet-50 เป็นโครงข่ายประสาทเทียมที่มีความลึกสูงขึ้น โดยประกอบด้วย 50 เลเยอร์ และใช้ Bottleneck Residual Blocks ซึ่งช่วยลดจำนวนพารามิเตอร์ในขณะที่ยังคงความสามารถในการเรียนรู้คุณลักษณะเชิงลึกได้อย่างมีประสิทธิภาพ โครงสร้างที่ลึกของ ResNet-50 ทำให้โมเดลสามารถสกัดลักษณะของภาพที่มีความซับซ้อนได้ดีกว่า ResNet-18 อย่างไรก็ตาม จะต้องแลกกับภาระการคำนวณที่สูงขึ้น โมเดลนี้จึงเหมาะสำหรับงานที่ต้องการความแม่นยำสูงและมีทรัพยากรการประมวลผลเพียงพอ

2.7.5 การเปรียบเทียบ ResNet-18 และ ResNet-50

เมื่อเปรียบเทียบโครงสร้างของ ResNet ทั้งสองรุ่น พบว่า ResNet-18 มีจำนวนเลเยอร์น้อยกว่าและมีความซับซ้อนต่ำกว่า จึงเหมาะสำหรับงานที่ต้องการความรวดเร็วและใช้ทรัพยากรการคำนวณต่ำ ในขณะที่ ResNet-50 มีโครงสร้างที่ลึกกว่าและใช้ Bottleneck Design ซึ่งช่วยเพิ่มความสามารถในการเรียนรู้คุณลักษณะเชิงลึกของภาพได้ดีกว่า แต่ต้องใช้พลังการคำนวณสูงกว่า (He et al., 2016)

2.8 ไฮเปอร์พารามิเตอร์ (Hyperparameters)

ไฮเปอร์พารามิเตอร์ คือ ค่าพารามิเตอร์ที่ผู้พัฒนา กำหนดไว้ล่วงหน้า ก่อนเริ่มกระบวนการฝึกโมเดล และ ไม่ถูกเรียนรู้จากข้อมูลโดยตรง แต่มีบทบาทสำคัญในการควบคุมโครงสร้าง การทำงาน และพฤติกรรมของอัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) Hyperparameters ใช้กำหนดว่าโมเดลจะเรียนรู้อย่างไรและมากน้อยเพียงใด เช่น อัตราในการเรียนรู้ (learning rate) ความซับซ้อนของโมเดล หรือ จำนวนรอบการฝึก (epoch) จำนวนชั้นของโครงข่ายประสาทเทียม และค่า regularization ต่าง ๆ ซึ่งการเลือกค่า Hyperparameters ที่เหมาะสมจะส่งผลโดยตรงต่อประสิทธิภาพ และความแม่นยำ

Transfer learning เป็นเทคนิคที่นำโมเดลที่ถูกฝึกฝนมาแล้วในงานหนึ่งมาใช้ในงานอื่น โดยไม่ต้องฝึกโมเดลตั้งแต่เริ่มต้นใหม่ทั้งหมด การตั้งค่าไฮเปอร์พารามิเตอร์สำหรับ Transfer learning มีความสำคัญเพื่อให้โมเดลสามารถปรับตัวกับงานใหม่ได้อย่างมีประสิทธิภาพ ต่อไปนี้เป็นไฮเปอร์พารามิเตอร์สำคัญที่ควรพิจารณาในการทำ Transfer learning สำหรับโครงข่ายประสาทเทียม

Convolutional Neural Networks มีไฮเปอร์พารามิเตอร์มากมายให้ระบุ (MATLAB Documentation: Transfer Learning using MATLAB, n.d.) ที่สำคัญที่สุดมีดังต่อไปนี้

2.8.1 กลยุทธ์การปรับแต่ง (Fine-Tuning Strategy)

การปรับแต่งเกี่ยวข้องกับการตัดสินใจว่าจะฝึกเฉพาะชั้นที่เชื่อมต่อย่างเต็มที่เท่านั้นหรือจะปรับแต่งชั้นคอนโวลูชันด้วย การตัดสินใจนี้ขึ้นอยู่กับความคล้ายคลึงกันระหว่างงานเดิมและงานใหม่ หากงานใหม่มีความเกี่ยวข้องกัน การปรับแต่งชั้นมากขึ้นอาจเป็นประโยชน์ หากงานใหม่ไม่มีความเกี่ยวข้องกัน อาจจะไม่ฝึกเฉพาะชั้นสุดท้าย

2.8.2 การเพิ่มข้อมูล (Data Augmentation)

การเพิ่มข้อมูล คือ การเพิ่มความหลากหลายของข้อมูลการฝึกโดยใช้การเปลี่ยนแปลงแบบสุ่ม เช่น การหมุน การพลิก หรือการซูม เทคนิคนี้มีประโยชน์อย่างยิ่งในการทำ Transfer learning เพื่อป้องกันการเกิด Overfitting โดยเฉพาะอย่างยิ่งเมื่อชุดข้อมูลใหม่มีขนาดเล็ก

2.8.3 เทคนิคการปรับแบบทั่วไป (Regularization Techniques)

เป็นเทคนิคการปรับแบบทั่วไปเช่น การดรอปเอาต์ (dropout) การย่อหน้าหนัก (weight decay) หรือการปรับ L2 สามารถช่วยป้องกันโมเดลจากการฟิตเกินในงานใหม่ได้ ทั้งนี้การใช้เทคนิคการปรับควรถูกปรับตามขนาดและความซับซ้อนของชุดข้อมูลใหม่

2.8.4 ฟังก์ชันการสูญเสีย (Loss Function)

การเลือกฟังก์ชันการสูญเสียขึ้นอยู่กับลักษณะของงานใหม่ เช่น classification, regression สำหรับ Transfer learning สิ่งที่สำคัญ คือ ต้องเลือกฟังก์ชันการสูญเสียที่สอดคล้องกับเป้าหมายของงานใหม่ บางครั้งอาจออกแบบฟังก์ชันการสูญเสียแบบกำหนดเองเพื่อให้เหมาะกับข้อกำหนดเฉพาะของงานใหม่มากขึ้น

2.8.5 Learning Rate (อัตราการเรียนรู้)

อัตราการเรียนรู้เป็นพารามิเตอร์ที่ควบคุมปริมาณการปรับปรุงของน้ำหนักโมเดลเมื่อเทียบกับความชันของการสูญเสีย (Loss gradient) หากอัตราการเรียนรู้สูง น้ำหนักจะถูกปรับปรุงมากขึ้น แต่หากอัตราการเรียนรู้ต่ำ น้ำหนักจะถูกปรับปรุงน้อยลง

2.8.6 Batch Size (ขนาดชุดข้อมูล)

ขนาดชุดข้อมูล คือ จำนวนตัวอย่างการฝึกที่ใช้ในหนึ่งครั้งการทำงาน การใช้ขนาดชุดข้อมูลใหญ่จะนำไปสู่การประมาณความชันที่มีความเสถียรมากขึ้น แต่ต้องการหน่วยความจำมากกว่า ขนาดชุดข้อมูลที่เล็กกว่าอาจนำไปสู่การปรับปรุงที่มีความแปรปรวนสูงกว่า แต่สามารถช่วยในการสร้างแบบจำลองที่ดีขึ้น โดยการคำนวณ Batch Size เพื่อส่งข้อมูลให้อัลกอริทึมใช้ในการเรียนรู้ชุดข้อมูลคำนวณในหนึ่งครั้ง เพื่อให้ครบใน 1 Epoch เช่น ถ้า Dataset มี 2000 โดยใช้ 500 Batch size คือ

นำ 500 ไปหาร 2000 มันจะถูกแบ่งออกเป็น 4 Iteration และก็จะมีการเรียนรู้จนเสร็จสิ้นใน 1 Epoch

2.8.7 Iteration (รอบการปรับปรุงหรือการวนซ้ำ)

การอ่านค่าซ้ำของชุดข้อมูล หรือการวนซ้ำของ 1 ชุดข้อมูล หรือรอบการปรับปรุง หมายถึง การปรับปรุงพารามิเตอร์ของโมเดลหนึ่งครั้ง ในแต่ละรอบการปรับปรุง ชุดข้อมูลหนึ่งชุดจะถูกส่งผ่าน เครือข่ายและน้ำหนักจะถูกปรับปรุงตามนั้น

2.8.8 Number of Epochs (จำนวนรอบการฝึกฝน)

จำนวนรอบการฝึกอบรมที่โมเดลทำงานกับชุดข้อมูลทั้งหมด โดยชุดข้อมูลที่ถูกส่งไปยัง Neural network 1 ครั้ง ต่อการวนซ้ำของ 1 ชุดข้อมูล เช่น 1 Epoch คือ การวนซ้ำของการปรับรอบ Iteration ถ้าหากว่ามี 4 Iteration (รอบ) ข้อมูลต้องถูกเรียนรู้ 4 รอบถึงจะครบ 1 Epoch สรุปคือ 1 Epoch/4 Iteration

2.8.9 Optimizer (ตัวปรับปรุงหรือ Algorithm)

ตัวปรับปรุง (Optimizer) เป็นอัลกอริทึมที่ใช้ในการปรับค่าพารามิเตอร์ของเครือข่ายประสาทเทียมเพื่อลดค่าฟังก์ชันการสูญเสีย (Loss function) ให้ต่ำที่สุด โดยอาศัยการคำนวณค่า Gradient ของพารามิเตอร์แต่ละตัว ตัวปรับปรุงที่นิยมใช้ในการเรียนรู้เชิงลึก ได้แก่ Stochastic Gradient Descent (SGD), Stochastic Gradient Descent with Momentum (SGDM), Adam และ RMSprop การเลือกใช้ตัวปรับปรุงและการกำหนดค่าพารามิเตอร์ที่เหมาะสม เช่น อัตราการเรียนรู้ (Learning rate) ค่า Momentum หรือพารามิเตอร์เบต้า มีผลโดยตรงต่อความเร็วในการลู่เข้าและประสิทธิภาพของกระบวนการ Transfer Learning (Goodfellow et al., 2016; Bottou & Bousquet, 2011; Kingma & Ba, 2014)

ในการศึกษานี้ใช้โปรแกรม MATLAB สำหรับการพัฒนาแบบจำลอง ซึ่งรองรับตัวปรับปรุงที่ใช้ในงาน Transfer Learning ดังต่อไปนี้

Stochastic Gradient Descent (SGD) เป็นอัลกอริทึมพื้นฐานที่ทำการปรับค่าพารามิเตอร์ของโมเดลโดยอาศัยค่า Gradient ที่คำนวณจากข้อมูลฝึกในแต่ละรอบหรือแต่ละกลุ่มย่อยของข้อมูล (Mini-batch) โดยมีสมการการอัปเดตพารามิเตอร์ดังนี้

$$\theta = \theta - \eta \nabla_{\theta} J(\theta)$$

โดยที่ θ คือ พารามิเตอร์ของโมเดล η คือ อัตราการเรียนรู้ และ $\nabla_{\theta} J(\theta)$ คือ Gradient ของฟังก์ชันการสูญเสีย แม้ว่า SGD จะมีความเรียบง่ายและคำนวณได้รวดเร็ว แต่การลู่เข้าอาจไม่เสถียรในกรณีที่พื้นผิวของฟังก์ชันการสูญเสียมีความซับซ้อน (Bottou, 2011; Ruder, 2016)

Stochastic Gradient Descent with Momentum (SGDM) เป็นการพัฒนาต่อยอดจาก SGD โดยเพิ่มแนวคิด Momentum เพื่อช่วยลดการสั่นของค่า Gradient และเร่งความเร็วในการลู่

เข้าสู่ค่าที่เหมาะสม โดยอาศัยการสะสมค่า Gradient จากรอบก่อนหน้า ทำให้โมเดลสามารถหลีกเลี่ยงการติดอยู่ใน Local minima ได้ดีขึ้น วิธีนี้ได้รับความนิยมอย่างแพร่หลายในงานด้าน Computer Vision และ Transfer Learning เนื่องจากมีความเสถียรและให้ผลลัพธ์ที่ดีในหลายกรณี (Goodfellow et al., 2016; Simonyan & Zisserman, 2014)

Adam (Adaptive Moment Estimation) เป็นอัลกอริทึมการเพิ่มประสิทธิภาพที่ผสมผสานข้อดีของ AdaGrad และ RMSprop เข้าด้วยกัน โดยใช้การประมาณค่าเฉลี่ยเคลื่อนที่ของ Gradient (First moment) และความแปรปรวนของ Gradient (Second moment) พร้อมทั้งมีการแก้ไขอคติของค่าเฉลี่ยดังกล่าว Adam มีความสามารถในการปรับอัตราการเรียนรู้แบบอัตโนมัติสำหรับพารามิเตอร์แต่ละตัว ทำให้เหมาะสมกับปัญหาที่มีข้อมูลจำนวนมากและโครงสร้างโมเดลที่ซับซ้อน (Kingma & Ba, 2017; Smith, 2017)

RMSprop (Root Mean Square Propagation) เป็นอัลกอริทึมที่ออกแบบมาเพื่อแก้ปัญหาการลดลงหรือเพิ่มขึ้นของค่าอัตราการเรียนรู้ที่ไม่เหมาะสม โดยใช้ค่าเฉลี่ยเคลื่อนที่ของกำลังสองของ Gradient เพื่อปรับอัตราการเรียนรู้แบบแปรผัน RMSprop ช่วยให้การเรียนรู้มีความเสถียรมากขึ้น โดยเฉพาะในกรณีที่ฟังก์ชันการสูญเสียมีความไม่เชิงเส้นสูง (Hinton et al., 2012; Ruder, 2017)

2.9 เทคนิค Grad-CAM (Gradient-weighted Class Activation Mapping)

เทคนิค Grad-CAM (Gradient-weighted Class Activation Mapping) เป็นวิธีการอธิบายการตัดสินใจของแบบจำลองโครงข่ายประสาทเทียมเชิงลึก โดยเฉพาะแบบจำลองประเภท Convolutional Neural Network (CNN) ซึ่งถูกพัฒนาขึ้นเพื่อเพิ่มความสามารถในการตีความผลลัพธ์ของแบบจำลองที่มักถูกมองว่าเป็น “กล่องดำ” (black box) เทคนิคนี้อาศัยการคำนวณค่า gradient ของคะแนนการทำนายคลาสเป้าหมายที่ไหลย้อนกลับไปยังชั้น convolution สุดท้ายของแบบจำลอง เพื่อนำมาถ่วงน้ำหนักกับแผนที่คุณลักษณะ (feature maps) และสร้างเป็นแผนที่การกระตุ้นของคลาส (class activation map) ในรูปแบบของแผนที่ความร้อน (heatmap) ซึ่งแสดงบริเวณของภาพที่แบบจำลองให้ความสำคัญในการตัดสินใจ (Selvaraju et al., 2017)

Grad-CAM มีจุดเด่น คือ สามารถนำไปประยุกต์ใช้กับสถาปัตยกรรมของ CNN ได้หลากหลายโดยไม่จำเป็นต้องปรับเปลี่ยนโครงสร้างของแบบจำลอง อีกทั้งยังให้ผลลัพธ์ในลักษณะเชิงภาพที่เข้าใจได้ง่าย ส่งผลให้ผู้วิจัยสามารถตรวจสอบได้ว่าแบบจำลองใช้ข้อมูลจากบริเวณที่มีความสอดคล้องกับหลักการทางโดเมนจริงหรือไม่ เช่น ในงานวิเคราะห์ภาพทางการแพทย์หรือภาพผิวหนัง

การใช้ Grad-CAM ช่วยยืนยันว่าแบบจำลองมุ่งเน้นไปยังบริเวณรอยโรคหรือความผิดปกติที่แท้จริง แทนที่จะอาศัยข้อมูลรบกวนจากพื้นหลังหรือสภาพแสงของภาพ (Samek et al., 2021)

ดังนั้น เทคนิค Grad-CAM จึงมีบทบาทสำคัญในการเพิ่มความโปร่งใสและความน่าเชื่อถือของแบบจำลองปัญญาประดิษฐ์ โดยเฉพาะในงานวิจัยที่เกี่ยวข้องกับการวิเคราะห์ภาพเพื่อการแพทย์ และชีวการแพทย์ ซึ่งผลการทำนายของแบบจำลองจำเป็นต้องสามารถอธิบายและตรวจสอบได้อย่างเป็นระบบ

2.10 การวิเคราะห์เชิงคาดการณ์ (Predictive Analytics)

การวิเคราะห์เชิงคาดการณ์เป็นคำที่ใช้เป็นหลักในเชิงสถิติและเทคนิคการวิเคราะห์ขั้นสูง คำนี้มาจาก Statistic of Machine Learning โดยใช้เทคนิคฐานข้อมูล และการเพิ่มประสิทธิภาพ โดยเทคนิคต่าง ๆ มีรากฐานมาจากสถิติคลาสสิก การทำเหมืองข้อมูล (Data Mining) การเรียนรู้ของเครื่อง (Machine Learning) และปัญญาประดิษฐ์ (Artificial Intelligence) ซึ่งทำนายในอนาคตโดยการวิเคราะห์ข้อมูลปัจจุบันและในอดีต อนาคต เหตุการณ์ และพฤติกรรมของตัวแปรสามารถทำนายได้โดยใช้เครื่องหมายแบบจำลองการวิเคราะห์เชิงคาดการณ์ (Kumar & Garg, 2018) วิธีการ Machine Learning กำลังได้รับความนิยมในสาขาการแพทย์เพื่อการวินิจฉัย การวิเคราะห์เชิงพยากรณ์ และการวิจัยทั่วไป โดยที่ข้อมูลมักจะไม่มีการจัดกระจายจึงต้องการการรวบรวม มีความจำเป็นสำหรับเครือข่ายการเรียนรู้ที่ไม่มีผู้ดูแลในด้านการแพทย์ Self-Organizing Feature Maps (SOFM) เป็นแอปพลิเคชันทั่วไปของเครือข่ายที่ไม่มีผู้ดูแลและอนุญาตให้ใช้ของข้อมูลที่ไม่มีป้ายกำกับในการฝึกอบรม (King et al., 2020) การใช้ Deep learning ในการวิเคราะห์เชิงพยากรณ์ด้านสุขภาพคือการใช้เครือข่ายประสาทเทียมขั้นสูงเพื่อวิเคราะห์ข้อมูลทางการแพทย์ที่ซับซ้อนและทำนายผลลัพธ์ด้านสุขภาพอย่างแม่นยำ วิธีการนี้ยังช่วยเพิ่มความสามารถในการทำนายโรค ผลลัพธ์ของผู้ป่วย การแพทย์เฉพาะบุคคล และการวินิจฉัยโรคในระยะแรก ซึ่งในที่สุดจะนำไปสู่การดูแลผู้ป่วยที่ดีขึ้นและการแทรกแซงทางการแพทย์ที่มีประสิทธิภาพมากขึ้น (Esteva et al., 2017; Miotto et al., 2018)

2.11 การทบทวนวรรณกรรมสำหรับการเรียนรู้เชิงลึกในการจัดระดับความรุนแรงของสิ่ว

งานวิจัยช่วงหลังได้ประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อประเมินและจัดระดับความรุนแรงของสิ่วจากภาพใบหน้า อย่างแพร่หลาย โดยเฉพาะโมเดลแบบ Convolutional Neural Network (CNN) ที่สามารถเรียนรู้คุณลักษณะของรอยโรคได้อัตโนมัติและให้ผลการจำแนกที่มีประสิทธิภาพ (Liu et al., 2018) นอกจากนี้ แนวทาง Transfer Learning ที่นำโมเดลที่ผ่านการฝึกมาก่อนมาปรับใช้กับข้อมูลสิ่วที่มีขนาดเล็ก ช่วยเพิ่มความแม่นยำและลดภาระการฝึกสอนโมเดลจากศูนย์ (Smith et al., 2022) อย่างไรก็ตาม “ชุดข้อมูล” เป็นปัจจัยสำคัญต่อความแข็งแรงของแบบจำลอง โดยฐานข้อมูลสาธารณะ เช่น ACNE04 แม้เอื้อต่อการเริ่มต้นวิจัย แต่ยังมีข้อจำกัดด้านความหลากหลาย คุณภาพของรูปภาพ และความสอดคล้องของการระบุความรุนแรง ขณะที่ชุดข้อมูลที่สร้างขึ้นเองและตรวจสอบโดยแพทย์ผิวหนังมักให้ผลลัพธ์ดีกว่า แต่ต้องใช้ทรัพยากรและเวลาในการรวบรวมสูง (Traini, 2025) มีงานที่ผสมระบบวิเคราะห์สิ่วกับการรักษา เช่น การใช้ ResNet50 และ YOLOv2 เพื่อวินิจฉัยสิ่วอัตโนมัติร่วมกับระบบบำบัด LED/IoT (H-IoT) และประเมินด้วย cross-validation ซึ่งสะท้อนศักยภาพการนำไปใช้จริง แต่ยังมีข้อจำกัดสำคัญคือ ความเข้มของแสงบนความแม่นยำของเครื่องตรวจจับสิ่วไม่ได้ถูกตรวจสอบในการศึกษา รวมถึงข้อจำกัดของชุดข้อมูลทำให้เกิดความแปรปรวนและความคลาดเคลื่อนในชุดทดสอบ โดยในอนาคตควรใช้ภาพใบหน้ามาตรฐานที่หลากหลายทั้งชนิดและระดับของสิ่ว รวมถึงพัฒนาโมเดลให้จำแนกสิ่วได้ละเอียดและเชื่อมโยงกับการรักษาอัตโนมัติ นอกจากนี้ ควรปรับปรุงประสิทธิภาพด้วยโมเดลเชิงผสม การปรับค่าไฮเปอร์พารามิเตอร์ และการประยุกต์ใช้กับแพลตฟอร์มสุขภาพที่เชื่อมต่อกับ IoT เพื่อเพิ่มขีดความสามารถของระบบในอนาคต (Phan et al., 2021) นอกจากนี้ ยังมีการพัฒนาแอปบนมือถือเพื่อประเมินความรุนแรงของสิ่วจากภาพถ่าย โดยมุ่งให้ผลใกล้เคียงแพทย์ผิวหนังและใช้ติดตามการรักษา/พยากรณ์ระยะเวลาฟื้นตัวได้ และมีจำนวนข้อมูลที่น้อยสำหรับการฝึกสอน ทำให้ความน่าเชื่อถือและความสามารถในการ generalization ของโมเดลยังเป็นข้อกังวล (Malgina & Kurochkina, 2021; Zhao et al., 2019)

ในเชิงการประเมินตามแนวทางการรักษา งานวิจัยหนึ่งพัฒนาโมเดลเพื่อจัดระดับสิ่วตามแนวปฏิบัติของจีนและรายงานความสอดคล้องกับแพทย์ผิวหนังในระดับสูง โดยเปรียบเทียบสถาปัตยกรรม เช่น VGGNet และ ResNet แต่ยังมีข้อจำกัดด้านต้นทุนการคำนวณของ VGG และความสามารถของ ResNet ในการแยกความแตกต่างของลักษณะละเอียดบางประเภท (Yang et al., 2021) ยิ่งไปกว่านั้น งานด้านการจำแนกรอยโรคผิวหนังจากภาพใบหน้าได้แสดงให้เห็นว่าโครงข่ายเชิงลึกที่ผ่านการฝึกล่วงหน้า เช่น DenseNet201 สามารถให้ความแม่นยำสูงในการจำแนกหลายโรค รวมทั้งสิ่ว แต่ต้อง

แตกต่างเวลาและต้นทุนการประมวลผลที่สูงกว่าโมเดลอื่น (Goceri, 2021) สุดท้าย มีแนวทางที่เน้นการตรวจจับตำแหน่งรอยโรคและการตีความได้ของโมเดล โดยใช้โมเดลตรวจจับวัตถุ (object detection) เพื่อช่วยนับจำนวนรอยโรคและประเมินความรุนแรง พร้อมนำไปให้บริการผ่านแพลตฟอร์มใช้งานจริง ทำให้มีศักยภาพต่อการติดตามอาการแม่ไม่ได้ไปโรงพยาบาลและช่วยแพทย์ในการประเมินผลการรักษา (Wen et al., 2022) โดยช่องว่างงานวิจัยจากการทบทวน คือ งานส่วนใหญ่ยังเผชิญข้อจำกัดเรื่อง ขนาดและคุณภาพของชุดข้อมูล รวมถึงความสอดคล้องของฉลากความสามารถของโมเดลเมื่อนำไปใช้กับข้อมูลจริง ความสมมูลระหว่างความแม่นยำกับต้นทุนที่ใช้ในการประมวลผล การนำเสนอระบบที่ใช้งานได้จริงควบคู่ความน่าเชื่อถือและการตีความผล ซึ่งเป็นประเด็นสำคัญที่งานวิจัยนี้ต้องพัฒนาต่อ

ความท้าทายและทิศทางในอนาคตสำหรับการพัฒนาโมเดลการเรียนรู้เชิงลึกที่แข็งแกร่งสำหรับการจัดระดับสีผิวเผชิญกับความท้าทายหลายประการ การทำให้ชุดข้อมูลมีความหลากหลายเพื่อครอบคลุมประเภทผิวและสภาวะที่แตกต่างกัน การปรับปรุงคุณภาพการระบุ และการจัดการกับข้อพิจารณาด้านจริยธรรมที่เกี่ยวข้องกับความเป็นส่วนตัวของผู้ป่วยเป็นสิ่งสำคัญ การวิจัยในอนาคตควรสำรวจวิธีการที่หลากหลาย รวมถึงการผสมผสานข้อมูลเพิ่มเติม เช่น ประวัติผู้ป่วยและปัจจัยสิ่งแวดล้อม เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของระบบ (Kim et al., 2019)

การประยุกต์ใช้การเรียนรู้เชิงลึกในการจัดระดับความรุนแรงของสิ่วบนใบหน้าและการแนะนำผลิตภัณฑ์รักษาเองเป็นสาขาที่มีศักยภาพสูงแม้จะมีความท้าทาย แม้ว่าจะมีความก้าวหน้าอย่างมีนัยสำคัญ แต่การวิจัยอย่างต่อเนื่องเป็นสิ่งจำเป็นเพื่อแก้ไขข้อจำกัดที่มีอยู่และตระหนักถึงศักยภาพของเทคโนโลยีเหล่านี้ในทางการแพทย์และผู้บริโภคอย่างเต็มที่ โดยการใช้การเรียนรู้เชิงลึกเราสามารถก้าวไปสู่การแก้ปัญหาที่แม่นยำ เป็นส่วนตัว และปรับขนาดได้สำหรับการจัดการสิ่ว (Jeong et al., 2023)

บทที่ 3

ระเบียบวิธีวิจัย

โครงการวิจัยการพัฒนาระบบจำแนกระดับความรุนแรงของสิวบนใบหน้าและคำแนะนำผลิตภัณฑ์สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก การวิจัยครั้งนี้เป็นการวิจัยเชิงทดลองที่แท้จริง (True Experimental Research Design) มีวัตถุประสงค์เพื่อพัฒนาโมเดลจำแนกระดับความรุนแรงของสิวบนใบหน้าโดยใช้เทคนิคการเรียนรู้เชิงลึก และแสดงให้เห็นถึงความเป็นไปได้ในการประยุกต์ใช้โมเดลดังกล่าวในรูปแบบเว็บแอปพลิเคชันสำหรับการใช้งานจริงในอนาคต การวิจัยนี้ใช้ภาพถ่ายจากอาสาสมัครในมหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย รวมจำนวนภาพถ่ายจากใบหน้าด้านซ้าย ใบหน้าด้านขวาและหน้าตรง ทั้งหมดเป็น 1,572 ภาพ โดยในจำนวนนี้ได้จากอาสาสมัครจำนวน 524 คน ใช้สำหรับการฝึกสอนโมเดล เพื่อให้สามารถจำแนกระดับความรุนแรงของสิวได้ตั้งแต่ระดับที่ 1 ถึงระดับที่ 3 นอกจากนี้ ผู้วิจัยได้แสดงให้เห็นถึงความเป็นไปได้ในการประยุกต์ใช้โมเดลดังกล่าวในรูปแบบเว็บแอปพลิเคชัน สำหรับประเมินระดับความรุนแรงของสิวและแนะนำผลิตภัณฑ์ดูแลรักษาที่เหมาะสมกับแต่ละระดับ โครงการวิจัยนี้มีแนวทางและขั้นตอนการดำเนินการศึกษาดังต่อไปนี้

3.1 รูปแบบการศึกษาวิจัย

การศึกษาวิจัยนี้เป็นการวิจัยเชิงทดลองที่แท้จริง (True Experimental Research Design) เพื่อพัฒนาโมเดลจำแนกระดับความรุนแรงของสิวบนใบหน้าโดยใช้เทคนิคการเรียนรู้เชิงลึก และแสดงให้เห็นถึงความเป็นไปได้ในการประยุกต์ใช้โมเดลดังกล่าวในรูปแบบเว็บแอปพลิเคชันสำหรับการใช้งานจริงในอนาคต การดำเนินการในลักษณะนี้ทำให้การวิจัยมีความครบถ้วนทั้งด้านการพัฒนาเทคโนโลยี การทดสอบเชิงทดลอง และการนำไปประยุกต์ใช้ในรูปแบบการประมวลผลอัตโนมัติ ลักษณะของการวิจัยประกอบด้วยดำเนินการตามขั้นตอน ดังนี้

1. การเก็บรวบรวมข้อมูลภาพใบหน้าทั้งหมด 3 ด้าน ได้แก่ ใบหน้าด้านซ้าย ใบหน้าด้านขวาและหน้าตรง จากอาสาสมัครในมหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย
2. การประเมินระดับความรุนแรงของสิวจากรูปภาพที่เก็บรวบรวมในอาสาสมัครโดยแพทย์ผู้เชี่ยวชาญด้านผิวหนัง ตามเกณฑ์การจำแนกของ Investigator's Global Assessment Scale (IGA)

3. การเตรียมข้อมูล (Data preprocessing) เช่น การแบ่งกลุ่มข้อมูล (Data splitting) การเพิ่มข้อมูล (Data augmentation)

4. การสร้างและพัฒนาแบบจำลองการเรียนรู้เชิงลึก (Model building and training) โดยใช้เทคนิคการเรียนรู้แบบถ่ายโอน (Transfer learning) และการปรับ Hyperparameters ของโมเดลโดย การเปรียบเทียบ Learning algorithm การปรับ Batch size การปรับ Learning rate การปรับ solver การปรับสมดุลข้อมูล (Resampling) และเปรียบเทียบกับ 5-Fold Cross Validation

5. การประเมินประสิทธิภาพของแบบจำลอง (Model evaluation)

6. การออกแบบเว็บแอปพลิเคชัน (Design and creation web Application) สำหรับจำแนกระดับความรุนแรงของสิวและออกแบบการให้คำแนะนำผลิตภัณฑ์รักษาสิวที่เหมาะสมตามผลการประมวลผลของแบบจำลอง

3.2 พื้นที่การศึกษา

มหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย

3.3 ระยะเวลาที่ใช้ในการศึกษา

1. ระยะเวลาใช้ในการเก็บข้อมูลและยื่นขอจริยธรรมวิจัยในมนุษย์ประมาณ 1 ปี เริ่มวันที่ 1 สิงหาคม พ.ศ. 2565 ถึง วันที่ 31 กรกฎาคม พ.ศ. 2566

2. ระยะเวลาดำเนินการวิจัยและประมวลผลประมาณ 2 ปี เริ่มวันที่ 1 สิงหาคม พ.ศ. 2566 ถึง วันที่ 30 กันยายน พ.ศ. 2568)

3.4 ประชากรและกลุ่มตัวอย่าง

3.4.1 ประชากรที่ใช้ในการศึกษา

ประชากรที่ศึกษา คือ กลุ่มประชากรนักศึกษามหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย อายุ 18 ปีขึ้นไป มีจำนวนทั้งหมด 524 คน

3.4.2 กลุ่มตัวอย่าง

กลุ่มตัวอย่างที่ใช้ในการศึกษาครั้งนี้ คือ นักศึกษาในมหาวิทยาลัยแม่ฟ้าหลวง จังหวัด เชียงราย โดยมีการกำหนดลักษณะของกลุ่มตัวอย่างดังนี้

3.4.2.1 เกณฑ์การคัดเลือกอาสาสมัครเข้าร่วมโครงการวิจัย (Inclusion criteria)

1. เป็นนักศึกษามหาวิทยาลัยแม่ฟ้าหลวง
2. อายุตั้งแต่ 18 ปีขึ้นไป
3. เป็นผู้ที่มีความสุขร่างกายแข็งแรง
4. มีความสนใจการที่จะวิเคราะห์ระดับความรุนแรงของสิวบนใบหน้า

3.4.2.2 เกณฑ์การคัดเลือกอาสาสมัครออกจากโครงการวิจัย (Exclusion criteria)

1. ผู้ที่เป็นโรคกลัวการถ่ายภาพ (Camera phobia)
2. ผู้ที่ไม่สามารถถ่ายภาพใบหน้าได้

3.4.2.3 เกณฑ์การถอนตัวและการขอยุติการวิจัย (Withdrawal criteria)

1. ผู้ที่ไม่ต้องการให้ใช้ภาพถ่ายใบหน้าตนเองในงานวิจัยนี้
2. ผู้ที่มีความกังวลต่อข้อมูลของตนเองจะถูกเปิดเผยต่อสาธารณะ
3. หากอาสาสมัครต้องการถอนตัวออกจากโครงการวิจัยผู้วิจัยจะไม่นำภาพถ่ายของอาสาสมัครมาใช้ในการงานวิจัยและจะลบภาพถ่ายนั้นทันทีที่อาสาสมัครแจ้งถอนตัวต่อผู้วิจัย

3.4.2.4 เกณฑ์การยุติการวิจัยก่อนกำหนดของโครงการวิจัย (Early termination of study criteria)

ผู้วิจัย อาจารย์ที่ปรึกษาโครงการวิจัยหรือผู้บริหารสำนักวิชาเล็งเห็นว่าการทำการวิจัยนี้ ไม่เกิดประโยชน์ต่ออาสาสมัคร

3.4.2.5 การคำนวณกลุ่มตัวอย่าง

การคำนวณขนาดตัวอย่างของกลุ่มจำนวนภาพถ่ายใบหน้าที่ใช้ในการสอน Algorithm ใช้สูตรของเครซี่และมอร์แกน (Krejcie & Morgan, 1970)

$$n = \frac{z^2 p(1-p)}{e^2 + \frac{z^2 p(1-p)}{N}}$$

n = ขนาดของกลุ่มตัวอย่างที่จะศึกษา

N = ขนาดของประชากรทั้งหมด (จำนวนนักศึกษา ณ วันที่ 1 สิงหาคม พ.ศ. 2565 ทั้งหมด 15,416 คน)

p = สัดส่วนของลักษณะที่สนใจในประชากรกรณีที่ไม่ทราบค่าสัดส่วนประชากร
ซึ่งกำหนดให้ $p = 0.5$

Z = ค่า Z ที่ระดับความเชื่อมั่น

โดยใช้ระดับความเชื่อมั่น 95% หรือระดับนัยสำคัญ 0.05 มีค่า $Z = 1.96$

e = ระดับความคาดเคลื่อนของการสุ่มตัวอย่างที่ยอมให้เกิดขึ้นได้ 0.05

$$n = \frac{1.96^2 \times 0.5(1-0.5)}{0.05^2 + \frac{1.96^2 \times 0.5(1-0.5)}{15,416}}$$

$$n = \frac{3.8416 \times 0.25}{0.0025 + \frac{0.9604}{15,416}}$$

$$n = \frac{0.9604}{0.0025 + 0.0000623}$$

$$n = \frac{0.9604}{0.0025623}$$

$$n = 374.82 \approx 375$$

จากการคำนวณกลุ่มอาสาสมัครโดยใช้สูตรคอแคเรน ผลการคำนวณได้กลุ่มอาสาสมัคร 375 คน และเพื่อป้องกันการถอนตัว (Drop-out) ของกลุ่มอาสาสมัคร ผู้วิจัยจึงกำหนดตัวอย่างเพิ่มขึ้นอีกร้อยละ 10 ดังนั้น การศึกษาครั้งนี้ใช้อาสาสมัครทั้งหมด 413 คน

$$\begin{aligned} \% \text{ Drop-out} &= \frac{375 \times 10}{100} \\ &= 37.5 \\ &\approx 38 \end{aligned}$$

$$\begin{aligned} \text{ดังนั้น } \% \text{ Drop-out} + n &= 38 + 375 \\ &= 413 \end{aligned}$$

3.5 เครื่องมือที่ใช้ในการศึกษา

3.5.1 เครื่องมือที่ใช้ในการเก็บข้อมูล

เอกสารที่ใช้ในการเก็บรวบรวมข้อมูลต่าง ๆ โดยรายละเอียดของเอกสารได้แสดงไว้ในภาคผนวกแล้ว มีดังต่อไปนี้

3.5.1.1 เอกสารข้อมูลและขอความยินยอมเข้าร่วมโครง ฉบับเก็บรวบรวมข้อมูลในการสอนอัลกอริทึม

3.5.1.2 เอกสารประชาสัมพันธ์รับอาสาสมัครเข้าร่วมโครงการวิจัย

3.5.1.3 แบบฟอร์มกรอกข้อมูล (Google form) สำหรับเก็บข้อมูลภาพถ่ายโดยอาสาสมัครเป็นผู้อัปโหลดเอง

3.5.1.4 แบบฟอร์มกรอกข้อมูล (Google form) สำหรับการจำแนกระดับความรุนแรงของสีจากภาพถ่ายและส่งต่อแบบฟอร์มให้แพทย์ผู้เชี่ยวชาญด้านผิวหนังในการช่วยจำแนกระดับความรุนแรงของสีจากภาพถ่าย โดยใช้เกณฑ์ในการจำแนกระดับความรุนแรงของสี โดยรายละเอียดของเอกสารที่กล่าวมาข้างต้นได้แสดงไว้ในภาคผนวกแล้ว

3.5.2 เครื่องมือที่ใช้ในการสร้างและพัฒนาโมเดล

ผู้วิจัยได้ใช้เครื่องมือที่ใช้สำหรับการสร้างและพัฒนาโมเดลในการศึกษาครั้งนี้ ประกอบด้วย Apple M1 chip with 8-core CPU, 7-core GPU หน่วยความจำ RAM 8 GB และพื้นที่จัดเก็บข้อมูล SSD 256 GB

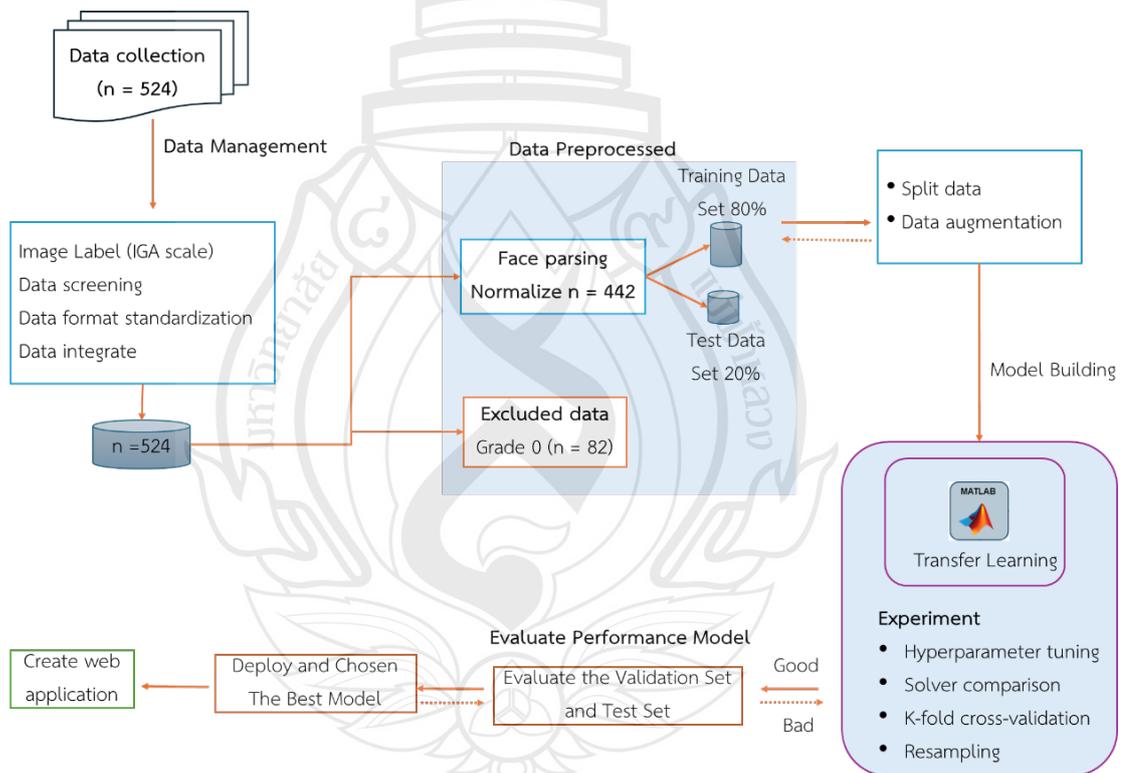
MATLAB – R2024a, 64-bit (maci64) เป็นโปรแกรมหลักที่ถูกใช้เป็นเครื่องมือในการสร้างและฝึกสอนแบบจำลองการเรียนรู้เชิงลึก (Deep Learning Model) เนื่องจากเป็นสภาพแวดล้อมที่รองรับการพัฒนาอัลกอริทึมเชิงคำนวณอย่างครบวงจร โปรแกรม MATLAB มีเครื่องมือเสริม (Toolbox) ที่สำคัญ เช่น Deep Learning Toolbox การปรับแต่งโครงข่ายประสาทเทียม (Network Modification) การฝึกสอนแบบจำลอง (Training) ไปจนถึง การประเมินผลลัพธ์ (Evaluation) ได้อย่างมีประสิทธิภาพ ทั้งนี้ เวอร์ชัน R2024a (maci64) ถูกเลือกใช้เพื่อให้เหมาะสมกับระบบปฏิบัติการ macOS แบบ 64-bit ซึ่งมีประสิทธิภาพในการประมวลผลกราฟิกสูงและรองรับการทำงานกับโมเดลขนาดใหญ่ได้อย่างราบรื่น

Google Colab เป็นแพลตฟอร์มบนคลาวด์ (Cloud-Based Platform) ที่ใช้ร่วมกับภาษา Python สำหรับการเตรียมและจัดการข้อมูล โดยรองรับไลบรารีทางด้านประมวลผลภาพและข้อมูล เช่น NumPy, Pandas และ OpenCV พร้อมความสามารถในการใช้ GPU (Graphics Processing Unit)

Deep learning model ที่ใช้ในการพัฒนาโมเดลในการศึกษาครั้งนี้ประกอบไปด้วย ResNet18, ResNet50, GoogLeNet และ InceptionV3

3.6 ขั้นตอนการดำเนินการวิจัย

สำหรับขั้นตอนการวิจัย การดำเนินงานและการเก็บรวบรวมข้อมูลในการวิจัยครั้งนี้ ประกอบด้วย ขั้นตอนการเก็บรวบรวมข้อมูล การจัดการข้อมูล ขั้นตอนการเตรียมข้อมูล ขั้นตอนการทดลอง การทดสอบประสิทธิภาพของแบบจำลอง การประมวลผลและการให้คำแนะนำผ่านระบบเว็บ แอปพลิเคชัน ดังแสดงในภาพที่ 3.1 ซึ่งมีรายละเอียดดังนี้



ภาพที่ 3.1 ขั้นตอนการดำเนินการศึกษา



ภาพที่ 3.2 ตัวอย่างการถ่ายภาพทั้ง 3 ด้านของใบหน้า

ตารางที่ 3.1 อธิบายรายละเอียดเกณฑ์ในการจำแนกระดับความรุนแรงของสิวจาก Investigator's Global Assessment Scale (IGA) (Wang et al., 2019; Huynh et al., 2022)

Grade	Description	Treatment	Class label
0	ผิวใส/ไม่มีสิว ไม่มีการอักเสบ ไม่พบรอยโรค	-	(Excluded)
1	พบเพียงรอยโรคที่ไม่อักเสบเล็กน้อยและมีรอยโรคอักเสบขนาดเล็กไม่เกินหนึ่งตำแหน่ง (Non-inflammation)	Topical product monotherapy: Retinoid (0.01-0.1%), Benzoyl peroxide (2.5-10%), Azelaic acid (20%)	1
2	ระดับความรุนแรงเล็กน้อย (Mild severity): มีความรุนแรงมากกว่าระดับที่ 1 พบรอยโรคที่ไม่อักเสบบางส่วน และมีรอยโรคอักเสบจำนวนเล็กน้อย (เป็นตุ่มนูนหรือตุ่มหนองเท่านั้น โดยไม่พบรอยโรคชนิดก้อนลึกหรือตุ่มนูนใต้ผิวหนัง)	Topical product combination therapy: Benzoyl peroxide (2.5-10%) + Clindamycin (1%) or Erythromycin (1-4%), Benzoyl peroxide (2.5%) + Adapalene (0.1%).	2
3	ระดับความรุนแรงปานกลาง (Moderate severity): มีความรุนแรงมากกว่าระดับที่ 2 พบได้หลายรอยโรคที่ไม่อักเสบ และอาจมีรอยโรคอักเสบบางส่วน แต่ไม่มีรอยโรคชนิดก้อนลึกหรือตุ่มนูนใต้ผิวหนังเกินหนึ่งตำแหน่ง	Topical product with an oral antibiotic or isotretinoin. Additional, topical combined oral contraceptive or oral	3
4	ระดับความรุนแรงมาก (Severe): มีความรุนแรงมากกว่าระดับที่ 3 พบได้หลายรอยโรคที่ไม่อักเสบ และอาจมีรอยโรคอักเสบหลายตำแหน่ง แต่ไม่พบรอยโรคชนิดก้อนลึกหรือตุ่มนูนใต้ผิวหนังเกินสองสามตำแหน่ง	spironolactone (female).	

ที่มา Wang et al. (2019) and Huynh et al. (2022)

หมายเหตุ Grade 0 = ผิวใส/ไม่มีสิว, Grade 1 = รอยโรคที่ไม่อักเสบ, Grade 2 = สิวระดับเล็กน้อย, Grade 3 = สิวระดับปานกลาง และ Grade 4 = สิวระดับรุนแรง

3.6.1 การเก็บรวบรวมข้อมูล (Data collection)

ข้อมูลที่เก็บรวบรวมจากอาสาสมัคร มีการเก็บข้อมูลในรูปแบบภาพถ่ายใบหน้าจากผู้ที่มีและไม่มีปัญหาสิว โดยมีวิธีการเก็บข้อมูลภาพถ่าย 2 แบบ ประกอบด้วย ผู้วิจัยเป็นผู้ถ่ายภาพเองโดยตรงด้วยสมาร์ทโฟน และอาสาสมัครเป็นผู้ถ่ายภาพเองโดยจะเก็บข้อมูลผ่านการอัปโหลดรูปภาพผ่าน Google from การกำหนดระยะห่างการถ่ายภาพประมาณ 20 เซนติเมตร ภายใต้แสงสว่างที่เพียงพอ ดังแสดงในภาพที่ 3.2 ข้อมูลภาพมีขนาดประมาณ $1,538 \times 2,051$ พิกเซล ซึ่งข้อมูลภาพถ่ายจะต้องเก็บ 3 ด้านของใบหน้าในอาสาสมัครแต่ละท่าน ได้แก่ ใบหน้าด้านซ้าย ใบหน้าด้านขวาและหน้าตรง จำนวนภาพถ่ายที่ได้ทั้งหมด คือ 1,572 ภาพ จากจำนวนรวมของอาสาสมัครทั้งหมดเป็น 524 คน ถูกจำแนกออกเป็นกลุ่มข้อมูลทั้งหมด 5 กลุ่ม ดังตารางที่ 3.2

3.6.2 ขั้นตอนการจัดการข้อมูล

การจัดการข้อมูล (Data management) ประกอบด้วย

1. จำนวนภาพถ่ายที่ได้ทั้งหมด 1,572 ภาพ ถูกจำแนกโดยแพทย์ผู้เชี่ยวชาญด้านผิวหนังด้วย IGA Scale ออกเป็นกลุ่มข้อมูลทั้งหมด 5 กลุ่ม ดังตารางที่ 3.1 และคัดมาใช้เฉพาะหน้าตรงเป็นจำนวนทั้งหมด 524 ภาพ ดังตารางที่ 3.2 ทั้งนี้แพทย์ผู้เชี่ยวชาญด้านผิวหนังเป็นผู้กรอกข้อมูลผ่าน Google form ในการจำแนกระดับความรุนแรงจากภาพถ่าย

ตารางที่ 3.2 ข้อมูลคลาสแต่ละระดับความรุนแรงของสิว โดยใช้ IGA Scale ในการจำแนก

ระดับความรุนแรง	จำนวนข้อมูล
0	80
1	106
2	141
3	124
4	73
รวมทั้งหมด	524

หมายเหตุ 0 = ผิวใส/ไม่มีสิว, 1 = รอยโรคที่ไม่อักเสบ, 2 = สิวระดับเล็กน้อย, 3 = สิวระดับปานกลาง และ 4 = สิวระดับรุนแรง

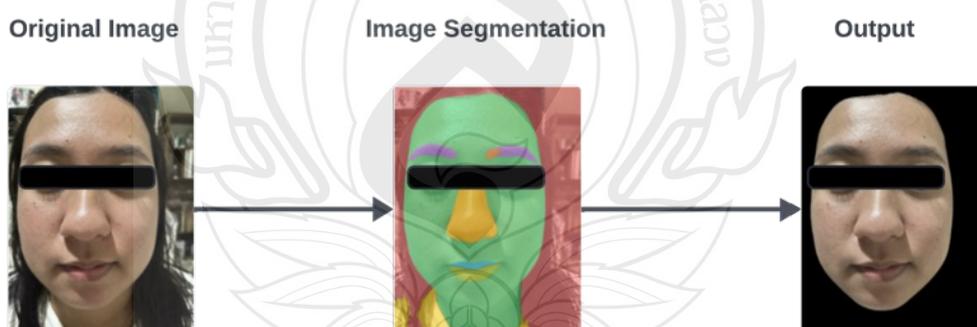
2. การคัดกรอง (Data screening) โดยคัดเลือกรูปภาพออก เกณฑ์คัดออก คือภาพที่ไม่ชัดเจนหรือไม่เห็นทั้งใบหน้า เช่น ภาพที่มีผมหน้าม้าปกปิดบริเวณหน้าผาก และรูปภาพ 2 ด้านของใบหน้า ได้แก่ ใบหน้าด้านซ้าย และใบหน้าด้านขวาก็ถูกคัดออกเช่นกัน เพื่อลดปัจจัยก่อกวนให้

แบบจำลองสามารถเรียนรู้จากภาพที่แสดงลักษณะของใบหน้าได้อย่างสมบูรณ์และมีมาตรฐานเดียวกัน

3. การปรับมาตรฐานรูปแบบข้อมูล (Data format standardization) โดยแปลงไฟล์ของข้อมูลบนรูปภาพจาก PNG และ HEIC เป็น JPG เพื่อให้เป็นรูปแบบเดียวกันและง่ายต่อการสร้างฐานข้อมูลในการใช้งานกับการเรียนรู้ของโมเดล

4. การคัดเลือกและจัดการข้อมูล (Data integration) เป็นการจัดการข้อมูลไฟล์ระดับความรุนแรงของสิว โดยไม่นำข้อมูลจากระดับความรุนแรงใน Grade 0 = 0_Clear (n=82) เข้ามาสอนอัลกอริทึม เนื่องจากไม่ปรากฏรอยโรค และไม่จำเป็นต้องได้รับคำแนะนำในการรักษา

ในขณะเดียวกันข้อมูลรูปภาพในระดับความรุนแรง Grade 3 = 3_Moderate และ Grade 4 = 4_Severe ก็ถูกรวมเข้าด้วยกัน เพื่อลดความซับซ้อนของโมเดล เนื่องจากลักษณะอาการของสิวในระดับ Grade 3 และ Grade 4 มีความใกล้เคียงกัน โดยทั้งสองระดับมีสิวกักเสบและสิวไม่อักเสบปรากฏร่วมกัน แตกต่างกันเพียงจำนวนและความรุนแรงของตุ่มนูน (Nodular lesions) ดังนั้น การรวมข้อมูลของทั้งสองระดับจึงไม่ทำให้สูญเสียความหมายทางคลินิก ขณะเดียวกันการดูแลรักษาและการให้คำแนะนำก็ไม่แตกต่างกัน ซึ่งจะเหลือระดับความรุนแรงของสิว คือ ระดับความรุนแรง 1 (1_None) ระดับความรุนแรง 2 (2_Mild) และระดับความรุนแรง 3 (3_Severe) จะถูกนำไปใช้ในการสอนโมเดล (จากการจัดการข้อมูลที่ได้กล่าวมาข้างต้น ทำให้เหลือภาพถ่ายใบหน้าที่สามารถนำเข้าสู่ขั้นตอนถัดไป จาก 524 ภาพ เหลือ 442 ภาพ ดังแสดงในภาพที่ 3.1)



ภาพที่ 3.3 Image Segmentation by Face Parsing

3.6.3 การเตรียมข้อมูล (Data preprocessing)

1. การแยกส่วนของภาพใบหน้าด้วยวิธี (Face Parsing) เป็นเทคนิคการประมวลผลภาพแยกส่วนต่าง ๆ ของภาพใบหน้าด้วย Face Parsing Model ของ Jonathan Dinu (Jonathan, 2023) โดยใช้เทคนิคการประมวลผลภาพแบบเชิงลึก (Deep Learning-based Image Segmentation) ด้วยโมเดล Semantic Segmentation เพื่อจำแนกองค์ประกอบของใบหน้าออกเป็นส่วนต่าง ๆ เช่น

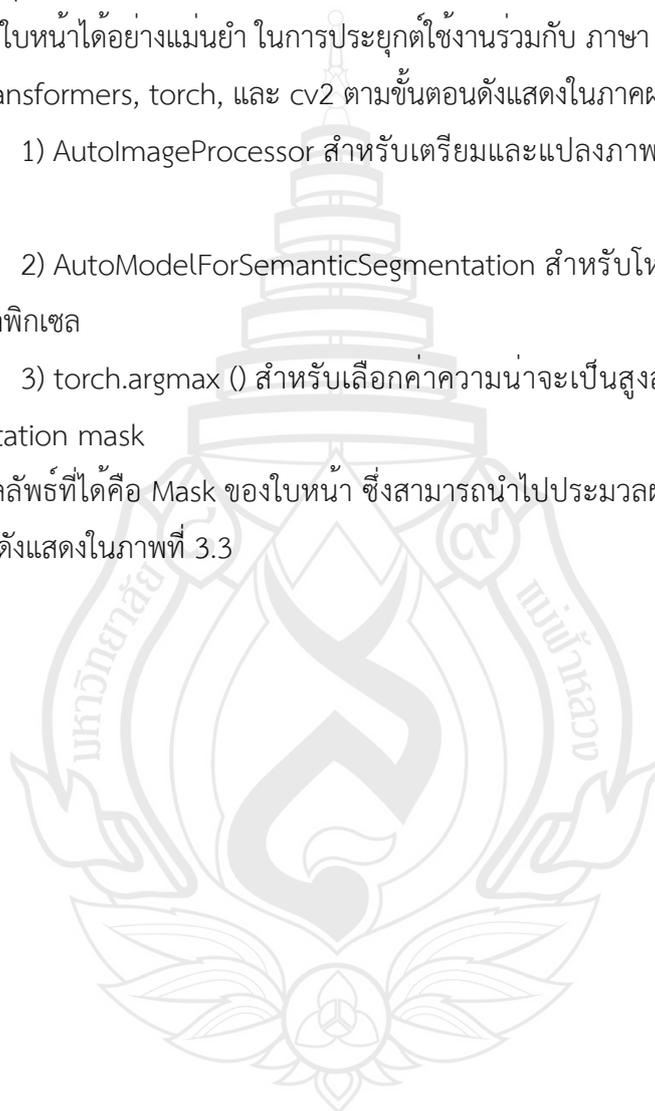
พื้นหลัง (background) ผิวหนัง (skin) ดวงตา (eyes) จมูก (nose) ปาก (mouth) เส้นผม (hair) และเสื้อผ้า (clothes) โมเดลนี้ถูกพัฒนาและเผยแพร่ผ่านแพลตฟอร์ม Hugging Face ภายใต้ชื่อ “jonathandinu/face-parsing” (<https://huggingface.co/jonathandinu/face-parsing>) โดยใช้สถาปัตยกรรมเครือข่ายประสาทเทียมเชิงลึกแบบ U-Net ที่ผ่านการฝึกด้วยชุดข้อมูล CelebAMask-HQ ซึ่งมีการระบุขอบเขต (Annotation) ของส่วนประกอบใบหน้าอย่างละเอียด ทำให้สามารถแยกพิกเซลของภาพใบหน้าได้อย่างแม่นยำ ในการประยุกต์ใช้งานร่วมกับ ภาษา Python จะเรียกใช้โมเดลผ่านไลบรารี transformers, torch, และ cv2 ตามขั้นตอนดังแสดงในภาคผนวก ฟังก์ชันหลักที่ใช้ คือ

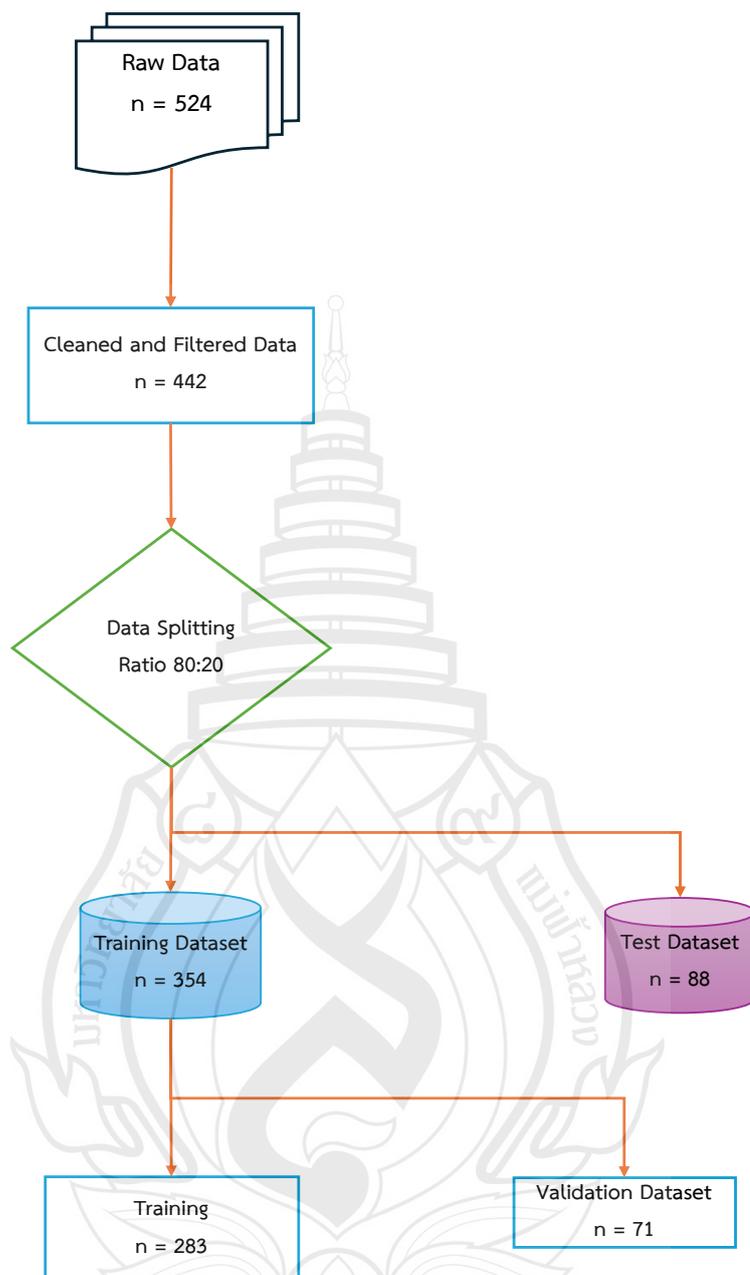
1) AutoImageProcessor สำหรับเตรียมและแปลงภาพให้อยู่ในรูปแบบที่โมเดลรองรับ

2) AutoModelForSemanticSegmentation สำหรับโหลดโมเดล Face Parsing และประมวลผลพิกเซล

3) torch.argmax () สำหรับเลือกค่าความน่าจะเป็นสูงสุดของแต่ละพิกเซล เพื่อสร้าง segmentation mask

ผลลัพธ์ที่ได้คือ Mask ของใบหน้า ซึ่งสามารถนำไปประมวลผลต่อ เพื่อให้เหลือเฉพาะบริเวณผิวหนัง ดังแสดงในภาพที่ 3.3





ภาพที่ 3.4 การแบ่งชุดข้อมูล (Data splitting)

2. ก่อนการแบ่งชุดข้อมูล ได้มีการสุ่มเรียงลำดับข้อมูลภาพใหม่โดยใช้ฟังก์ชัน `imds = shuffle(imds)`; ซึ่งการเรียกใช้ฟังก์ชันเป็นเครื่องมือสำหรับจัดการข้อมูลรูปภาพด้วย `matlab.io.datastore.ImageDatastore` (MathWorks, 2024) เพื่อป้องกันอคติที่อาจเกิดจากลำดับของข้อมูล (Data order bias) ซึ่งอาจส่งผลให้แบบจำลองการเรียนรู้เชิงลึก จดจำลำดับของภาพมากกว่าคุณลักษณะที่แท้จริง การสุ่มลำดับข้อมูล (Shuffling) จึงมีความสำคัญในการกระจายตัวของข้อมูลให้

เป็นอิสระและสมดุลระหว่างแต่ละคลาส ก่อนที่จะนำไปสู่ขั้นตอนการแบ่งชุดข้อมูล หลังจากทำการสุ่มลำดับข้อมูลแล้ว จึงทำการแบ่งชุดข้อมูล (Data Splitting) ออกเป็น 2 ส่วน คือ

- 1) ชุดข้อมูลสำหรับฝึกสอนแบบจำลอง (Training Dataset)
- 2) ชุดข้อมูลสำหรับทดสอบประสิทธิภาพของแบบจำลอง (Testing Dataset) โดยใช้สัดส่วนการแบ่งชุดข้อมูล 80:20 ซึ่งได้ผลลัพธ์เป็น ชุดข้อมูลฝึกสอนจำนวน 354 ภาพ และ ชุดข้อมูลทดสอบจำนวน 88 ภาพ ตามขั้นตอนที่แสดงในภาพที่ 3.4

3. การปรับค่าข้อมูลให้อยู่ในช่วงเดียวกัน (Normalize) ค่า pixel ให้อยู่ในช่วงเดียวกัน ทำให้การเรียนรู้ของโครงข่ายประสาทเทียมแบบ Convolutional Neural Network มีเสถียรภาพมากขึ้น ทำการปรับค่าข้อมูลให้อยู่ในช่วงเดียวกัน ด้วยการใช้ฟังก์ชัน `inputSize = net.Layers(1).InputSize`

4. การเพิ่มข้อมูล (Data Augmentation) ในการทดลองนี้ได้ใช้เทคนิคการเพิ่มข้อมูลแบบสุ่ม (Random Transformation) เฉพาะชุดฝึกสอน (Training) เท่านั้นและไม่ทำในชุดการตรวจสอบ (Validation) โดยกำหนดพารามิเตอร์การเปลี่ยนแปลงของภาพดังแสดงในตารางที่ 3.3

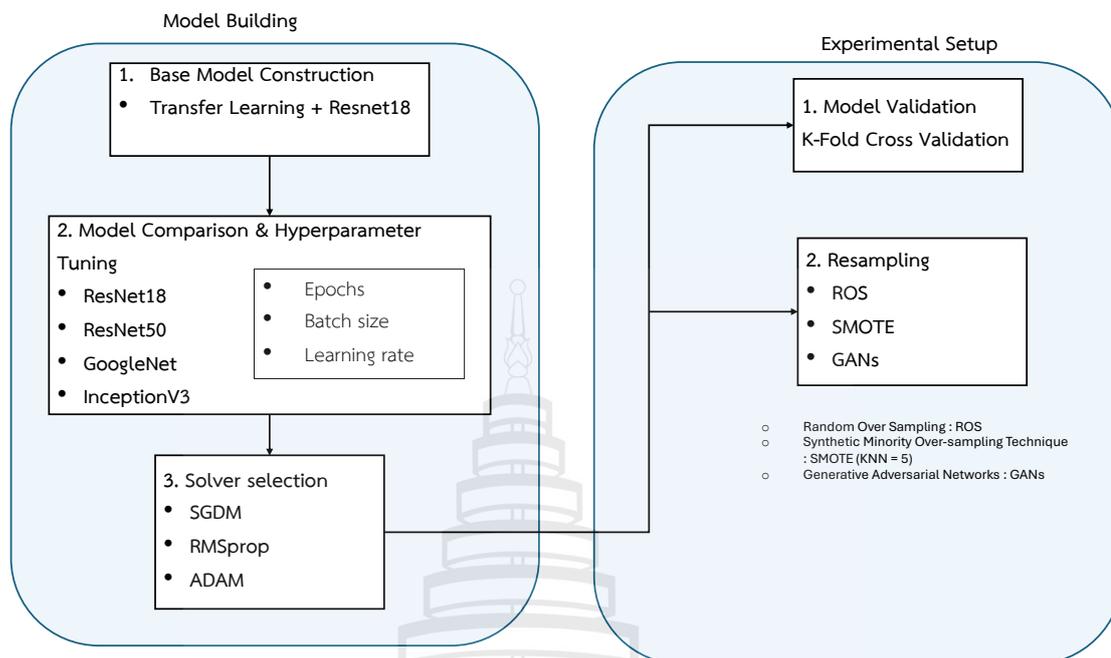
ตารางที่ 3.3 Augmentation Settings

Transformation	Values	
	Minimum	Maximum
Random rotation	-30	30
Random X-axis translation	-20	20
Random Y-axis translation	-20	20
Random X-axis scaling	0.8	1.2
Random Y-axis scaling	0.8	1.2
Random horizontal flipping		True

3.6.4 ขั้นตอนการทดลอง (Experimental Procedure)

เพื่อให้การดำเนินการวิจัยมีความเป็นระบบและสามารถอธิบายกระบวนการได้อย่างชัดเจน ผู้วิจัยได้แบ่งขั้นตอนการทดลองออกเป็น 2 ส่วน ดังแสดงในภาพที่ 3.5 ได้แก่

1. การสร้างแบบจำลอง (Model Building)
 2. การตั้งค่าการทดลอง (Experimental Setup)
- โดยรายละเอียดของขั้นตอนการทดลองทั้ง 2 ส่วน มีดังนี้



ภาพที่ 3.5 ขั้นตอนการทดลอง (Experimental Procedure Diagram)

3.6.4.1 การสร้างแบบจำลอง (Model Building)

การสร้างแบบจำลองพื้นฐาน (Base Model Construction) เป็นการสร้างแบบจำลองการเรียนรู้เชิงลึกเพื่อจำแนกระดับความรุนแรงของสี เริ่มต้นจากการสร้างแบบจำลองพื้นฐานโดยใช้เทคนิค การเรียนรู้แบบถ่ายโอน (Transfer Learning) ซึ่งเป็นการนำแบบจำลองสำเร็จรูป (Pre-trained model) ที่ผ่านการฝึกด้วยชุดข้อมูลขนาดใหญ่ เช่น ImageNet มาปรับให้เหมาะสมกับข้อมูลของงานวิจัยนี้ ในงานวิจัยนี้ผู้วิจัยได้เลือกใช้ ResNet18 เป็นแบบจำลองเริ่มต้น (Base Model) เนื่องจากมีความลึกในระดับปานกลางและมีจำนวนพารามิเตอร์ไม่มาก ส่งผลให้กระบวนการฝึกสอน (Training) มีความรวดเร็วและใช้ทรัพยากรคอมพิวเตอร์น้อย โดยกำหนดค่าพารามิเตอร์เริ่มต้นในการฝึกแบบจำลองดังนี้

1) Learning rate = 0.001

2) Batch size = 128

3) Epochs = 30

ค่าดังกล่าวอ้างอิงจากค่าเริ่มต้น (Defaults) ของโปรแกรม MATLAB (MathWorks, 2024) เพื่อใช้ในการฝึกสอนและประเมินประสิทธิภาพของแบบจำลอง

1. การเปรียบเทียบสถาปัตยกรรมของแบบจำลอง (Model Comparison) เพื่อประเมินประสิทธิภาพของแบบจำลองในแต่ละสถาปัตยกรรม ผู้วิจัยได้เปรียบเทียบโครงข่ายประสาทเทียมเชิงลึก (CNN) หลายรูปแบบภายใต้เงื่อนไขเดียวกัน โดยใช้ชุดข้อมูลและพารามิเตอร์การฝึกเหมือนกันทุกประการ แบบจำลองที่ใช้ในการเปรียบเทียบประกอบด้วย

- 1) ResNet18
- 2) ResNet50
- 3) GoogLeNet
- 4) InceptionV3

จากนั้นประเมินผลลัพธ์ด้วยค่าความแม่นยำ (Accuracy) และค่าความสูญเสีย (Loss) ด้วยการใช้ฟังก์ชันการหยุดการทำงานก่อนกำหนด (Early Stopping) และเลือกโมเดลที่ให้ประสิทธิภาพสูงสุดในการจำแนกระดับความรุนแรงของสี

2. การปรับแต่งค่าพารามิเตอร์ของแบบจำลอง (Hyperparameter Tuning) หลังจากได้แบบจำลองพื้นฐานแล้ว ผู้วิจัยได้ทำการปรับแต่งค่าพารามิเตอร์ (Hyperparameter) เพื่อหาค่าที่เหมาะสมที่สุดสำหรับการฝึกแบบจำลอง โดยทำการทดสอบค่าพารามิเตอร์ดังนี้

- 1) Epochs: 50, 100, 150, 200, 250, 300
- 2) Batch size: 16, 32, 64, 128
- 3) Learning rate: 0.1, 0.01, 0.001, 0.0001

จากนั้นทำการฝึกและบันทึกผลลัพธ์ของแต่ละชุดพารามิเตอร์ เพื่อนำค่าที่ให้ประสิทธิภาพดีที่สุดไปใช้ในการทดลองขั้นต่อไป

3. การเปรียบเทียบอัลกอริทึมการเรียนรู้ (Solver Comparison) ผู้วิจัยได้เปรียบเทียบอัลกอริทึมการเรียนรู้ (Optimizer) เพื่อหาวิธีการที่ช่วยให้แบบจำลองเรียนรู้ได้อย่างรวดเร็วและมีประสิทธิภาพสูงสุด อัลกอริทึมที่ใช้ในการทดลองประกอบด้วย

- 1) Stochastic Gradient Descent with Momentum (SGDM)
- 2) Adaptive Moment Estimation (ADAM)
- 3) Root Mean Square Propagation (RMSprop)

แบบจำลองแต่ละแบบได้รับการฝึกภายใต้ค่าพารามิเตอร์ที่เหมาะสมที่สุดจากการทดลองก่อนหน้าและบันทึกผลลัพธ์เพื่อเปรียบเทียบค่าความแม่นยำและค่าความสูญเสีย

3.6.4.2 การตั้งค่าการทดลอง (Experimental Setup)

1. การตรวจสอบความถูกต้องของแบบจำลองด้วยเทคนิค K-Fold Cross Validation ในการทดลองนี้ได้ใช้เทคนิค 5-Fold Cross Validation ซึ่งเป็นกระบวนการแบ่งชุดข้อมูลฝึก (Training Set) ออกเป็น 5 ส่วนเท่า ๆ กัน โดยในแต่ละรอบของการประเมินจะใช้ข้อมูล 1

ส่วนเป็นชุดตรวจสอบ (Validation Set) และใช้ข้อมูลอีก 4 ส่วนที่เหลือเป็นชุดฝึก (Training Set) เมื่อทำครบทั้ง 5 รอบ ข้อมูลทั้งหมดจะถูกใช้ทั้งในการฝึกและในการตรวจสอบอย่างเท่าเทียม การกำหนดค่า $K = 5$ ถือเป็นจำนวนที่เหมาะสมกับขนาดของชุดข้อมูลในงานวิจัยนี้ ช่วยลดความเอนเอียง (Bias) และเพิ่มความน่าเชื่อถือของผลการประเมินแบบจำลองได้อย่างมีประสิทธิภาพ

2. การปรับสมดุลข้อมูล (Resampling Technique) ข้อมูลที่ใช้ในการเรียนรู้ของแบบจำลองมีจำนวนภาพในแต่ละระดับความรุนแรงไม่เท่ากัน ซึ่งอาจก่อให้เกิด ปัญหาข้อมูลไม่สมดุล (Imbalanced Data) เพื่อแก้ปัญหาดังกล่าว ผู้วิจัยได้ใช้เทคนิคการปรับสมดุลข้อมูลด้วย 155, 300, 500 ภาพต่อระดับความรุนแรง โดยประกอบด้วย 3 วิธี ดังนี้

1) Random Oversampling (ROS) ทำการสุ่มทำซ้ำข้อมูลของระดับความรุนแรงที่มีจำนวนน้อยให้เพิ่มขึ้นจนเท่ากับระดับความรุนแรงที่มีจำนวนมากและไม่มีการเปลี่ยนแปลงลักษณะของข้อมูลเดิม

2) Synthetic Minority Over-sampling Technique (SMOTE) เป็นวิธีการสร้างข้อมูลใหม่ในคลาสที่มีจำนวนน้อยโดยใช้ การสังเคราะห์ข้อมูลเทียม (Synthetic Data Generation) โดย SMOTE จะสร้างตัวอย่างใหม่จากการคำนวณค่าเฉลี่ยเชิงเส้นระหว่างข้อมูลจริงของระดับความรุนแรงเดียวกัน ทำให้ได้ข้อมูลที่ใกล้เคียงกับของจริงแต่ไม่ซ้ำกับข้อมูลเดิม การสร้างตัวอย่างข้อมูลสังเคราะห์โดยใช้วิธี k-nearest neighbors (K-NN) โดยกำหนดค่า $k = 5$ ซึ่งเป็นค่าที่นิยมใช้ในงานวิจัย (Chawla et al., 2002) เพื่อสร้างชุดข้อมูลใหม่ ทั้งนี้เพื่อประเมินระดับความคล้ายคลึงของข้อมูลที่ได้เมื่อเทียบกับผลจากเทคนิค ROS โดยจำนวนภาพที่ถูกสร้างต่อระดับความรุนแรงเช่นเดียวกับเทคนิค ROS

3) Generative Adversarial Networks (GANs) เป็นเทคนิคการสร้างข้อมูลใหม่ โดยใช้โครงข่ายประสาทเทียมสองส่วน ได้แก่ Generator และ Discriminator ในส่วนของ Generator มีหน้าที่สร้างภาพเทียมให้มีลักษณะใกล้เคียงกับข้อมูลจริง ส่วนของ Discriminator มีหน้าที่จำแนกภาพจริงกับภาพเทียม ทั้งสองส่วนจะเรียนรู้แข่งขันกัน (Adversarial Training) จนสามารถสร้างภาพที่มีความสมจริงสูง โดยจำนวนภาพที่ถูกสร้างต่อระดับความรุนแรงเช่นเดียวกับเทคนิค ROS ในการทดลองนี้ ใช้ค่าพารามิเตอร์ของแบบจำลอง GANs ตามงานวิจัยของ Radford (Radford et al., 2015) เพื่อให้กระบวนการเรียนรู้ของเครือข่ายมีความเสถียรและสามารถสร้างภาพสังเคราะห์ที่มีความสมจริงได้ โดยกำหนด

ก. Learning rate = 0.0002

ข. Gradient decay = 0.5

ค. Squared gradient decay = 0.999

3.6.5 การทดสอบประสิทธิภาพของแบบจำลอง (Model evaluation)

เพื่อช่วยในการตัดสินใจการเลือกแบบจำลองเพื่อนำไปใช้กับการทำนายผลลัพธ์สำหรับข้อมูลชุดใหม่ในอนาคต โดยการทำ Confusion matrix

ตารางที่ 3.4 แสดง Confusion Matrix แบบ Binary Classification

		ผลลัพธ์ที่ได้จริง (Actual values)	
		Positive	Negative
ผลลัพธ์ที่ทำนายได้ (Predicted value)	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

True Positive (TP) คือ จำนวนผลลัพธ์ที่ทำนายถูกว่าเป็นผลบวก

True Negative (TN) คือ จำนวนผลลัพธ์ที่ทำนายถูกว่าเป็นผลลบ

False positive (FP) คือ จำนวนผลลัพธ์ที่ทำนายผิดว่าเป็นผลบวก

False negative (FN) คือ จำนวนผลลัพธ์ที่ทำนายผิดว่าเป็นผลลบ

จากตารางที่ 3.4 นำค่าที่ได้จาก Confusion matrix (Bhavna et al., 2021) มาคำนวณเพื่อวัดประสิทธิภาพของแบบจำลอง ดังนี้

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}}$$

$$F_1\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}}$$

1. ค่าความถูกต้อง (Accuracy) เป็นค่าที่ใช้วัดประสิทธิภาพของโมเดลการจัดประเภท (Classification) โดยบอกถึงสัดส่วนของการทำนายที่ถูกต้องทั้งหมดเมื่อเทียบกับจำนวนตัวอย่างทั้งหมดในชุดข้อมูลทดสอบ ค่าความถูกต้องสามารถคำนวณได้ ค่าความถูกต้องมีค่าระหว่าง 0 ถึง 1 หรือ 0% ถึง 100% โดยค่าที่ใกล้ 1 หรือ 100% แสดงว่าโมเดลมีความถูกต้องสูงในการทำนาย

แต่อย่างไรก็ตาม ค่าความถูกต้องอาจไม่เพียงพอในการประเมินประสิทธิภาพของโมเดลในกรณีที่ข้อมูลมีการกระจายตัวไม่สมดุล (imbalanced data) เช่น ในกรณีที่มีตัวอย่างในกลุ่มหนึ่งมากกว่ากลุ่มอื่นอย่างมาก โมเดลอาจทำการทำนายที่มีค่าความถูกต้องสูงโดยไม่สนใจตัวอย่างในกลุ่มที่มีจำนวนน้อย ดังนั้นในกรณีเหล่านี้ ควรพิจารณาค่าอื่น ๆ เช่น Precision, Recall, F1 Score และ Specificity

2. F1-Score เป็นค่าที่ใช้ในการประเมินประสิทธิภาพของโมเดลในงานการจัดประเภท (Classification tasks) โดยเฉพาะอย่างยิ่งในกรณีที่ข้อมูลมีการกระจายตัวไม่สมดุล (Imbalanced data) ค่า F1-Score เป็นค่าเฉลี่ยของ Precision และ Recall ซึ่งค่า F1-Score มีค่าระหว่าง 0 ถึง 1 ซึ่งค่า 1 แสดงว่าโมเดลมีประสิทธิภาพสูงสุดในการจัดประเภท และค่า 0 แสดงว่าโมเดลมีประสิทธิภาพต่ำสุด ค่า F1-Score มีความสำคัญมากในกรณีที่ต้องการความสมดุลระหว่าง Precision และ Recall และไม่ต้องทำให้ค่าหนึ่งสูงเกินไปในขณะที่อีกค่าหนึ่งต่ำเกินไป

3. ค่าความไว (Recall หรือ Sensitivity) คือ อัตราส่วนของผลลัพธ์ที่ทำนายถูกกว่าเป็นผลบวกต่อผลลัพธ์ที่วัดได้จริงที่เป็นผลบวกทั้งหมด ซึ่งมักจะถูกนำมาวัดผลของเครื่องมือที่ใช้ในการตรวจคัดกรองผู้ที่เป็นสิ่ว เนื่องจากหากเครื่องมือนั้นมีค่าความไวที่สูงแสดงว่าเครื่องมือนั้นมีโอกาสวัดสภาวะที่สนใจได้ดี

4. ค่าทำนายผลบวกหรือค่าพยากรณ์ผลบวก (Precision) คือ ค่าความน่าจะเป็นที่ผู้ที่เป็นสิ่วจะอยู่ในระดับความรุนแรงระดับใดหรือเป็นภาวะผลบวก เมื่อวัดผลลัพธ์ที่ทำนายได้เป็นผลบวก ซึ่งค่าทำนายผลบวก มักจะสอดคล้องกับค่าความจำเพาะในทิศทางเดียวกัน

5. ค่าความจำเพาะ (Specificity หรือ True negative rate) คือ อัตราส่วนของผลลัพธ์ที่ทำนายถูกกว่าเป็นผลลบต่อผลลัพธ์ที่วัดได้จริงที่เป็นผลลบทั้งหมด ซึ่งมักจะถูกนำไปใช้ประโยชน์ในการยืนยันผล การวินิจฉัย เนื่องจากหากเครื่องมือมีความจำเพาะสูงแสดงว่าเครื่องมือสามารถยืนยันการตรวจได้ดี

6. การวัดประสิทธิภาพของแบบจำลองที่นิยมใช้และมีประสิทธิภาพสูงในการวัดผล จากกราฟ Area Under the ROC curve (AUC curve) คือกราฟความสัมพันธ์ระหว่างแกน X คือ false positive rate (1-specificity) กับแกน Y คือ true positive rate (sensitivity) โดยจุดบนกราฟที่เกิดขึ้น หมายถึง จุดตัด ที่เป็นไปได้ระหว่างความสัมพันธ์ ของทั้งสองแกนดังกล่าว แบบจำลองควรมีทั้งค่าความไวและความจำเพาะที่สูง ดังนั้นจุดตัดที่ดีที่สุดจึงหมายถึง จุดตัดที่ให้ค่าความไวหรือค่าผลบวกจริง เท่ากับ 1 และให้ค่าผลบวกลวง เท่ากับ 0 ซึ่งเป็น ตำแหน่งที่ทำให้กราฟชิดมุมบนซ้ายมากที่สุดนั่นเอง

3.6.6 การอธิบายการตัดสินใจของแบบจำลองด้วยเทคนิค Grad-CAM

ในการศึกษานี้ ผู้วิจัยได้นำเทคนิค Grad-CAM (Gradient-weighted Class Activation Mapping) มาใช้เพื่ออธิบายการตัดสินใจของแบบจำลอง Convolutional Neural Network ที่ผ่านการฝึกสอนและคัดเลือกแล้ว โดย Grad-CAM เป็นเทคนิคที่ใช้ค่า gradient ของคะแนนการทำนายคลาสเป้าหมายย้อนกลับไปยังชั้น convolution สุดท้ายของแบบจำลอง เพื่อนำมาคำนวณเป็นแผนที่การกระตุ้นของคลาส (class activation map) ซึ่งแสดงบริเวณของภาพที่มีอิทธิพลต่อการตัดสินใจของแบบจำลอง (Selvaraju et al., 2017)

การวิเคราะห์ Grad-CAM จะทำถัดจากการประเมินประสิทธิภาพของโมเดลดังแสดงในภาคผนวก ฅ ซึ่งมีวัตถุประสงค์เพื่อเพิ่มความโปร่งใสของกระบวนการเรียนรู้ของแบบจำลอง และตรวจสอบว่าแบบจำลองให้ความสำคัญกับบริเวณที่มีความหมายเชิงกายภาพจริงของผิวหนังใบหน้า โดยจะดำเนินการเฉพาะกับข้อมูลภาพในชุดทดสอบ (Testing Dataset) โดยเลือกตัวอย่างภาพในแต่ละระดับความรุนแรงของสิว ได้แก่ ระดับความรุนแรงที่ 1 ระดับความรุนแรงที่ 2 และระดับความรุนแรงที่ 3 เพื่อประเมินรูปแบบการให้ความสำคัญของแบบจำลองในบริบทของระดับความรุนแรงที่ต่างกัน ผลลัพธ์ของ Grad-CAM ถูกแสดงในรูปแบบแผนที่ความร้อน (heatmap) และนำมาซ้อนทับกับภาพต้นฉบับ เพื่อให้สามารถมองเห็นตำแหน่งเชิงพื้นที่ ตามที่แบบจำลองใช้ในการตัดสินใจได้อย่างชัดเจน

3.6.7 การคัดเลือกแบบจำลองไปใช้งาน (Model deployment)

การเลือกนำแบบจำลองที่มีประสิทธิภาพสูงสุดจากการฝึกสอนและผ่านการปรับแต่งค่าพารามิเตอร์ไปใช้ในการจำแนกระดับความรุนแรงของสิวจากภาพใบหน้าที่ไม่เคยอยู่ในชุดข้อมูลฝึกมาก่อน มีวัตถุประสงค์เพื่อแสดงให้เห็นถึงการประยุกต์ใช้โมเดลดังกล่าวในรูปแบบเว็บแอปพลิเคชันพร้อมแสดงคำแนะนำผลิตภัณฑ์และแนวทางการดูแลรักษาที่เหมาะสมกับระดับความรุนแรงที่ตรวจพบ เช่น ผลิตภัณฑ์ทำความสะอาด ผลิตภัณฑ์บำรุงผิว และยารักษาสิวในระดับที่เหมาะสม ทั้งนี้ เพื่อให้ผู้ใช้สามารถนำข้อมูลไปใช้ประกอบการดูแลตนเองได้อย่างถูกต้องและปลอดภัย

ในส่วนของการให้คำแนะนำผลิตภัณฑ์และแนวทางการดูแลรักษา ผู้วิจัยได้รวบรวมข้อมูลจากเอกสารและแนวทางการรักษามาตรฐาน โดยอ้างอิงจาก สถาบันแห่งชาติเพื่อความเป็นเลิศด้านสุขภาพและการแพทย์ (National Institute for Health and Care Excellence: NICE) สมาคมแพทย์ผิวหนังแห่งประเทศไทย (Dermatological Society of Thailand: DST) สถาบันแพทย์ผิวหนังแห่งประเทศไทยสหรัฐอเมริกา (The American Academy of Dermatology: AAD) และ สภาโรคผิวหนังแห่งยุโรป (European Dermatology Forum: EDF) เพื่อใช้เป็นข้อมูลอ้างอิงในการแนะนำผลิตภัณฑ์ที่เหมาะสมกับระดับความรุนแรงของสิวแต่ละระดับ

3.7 จริยธรรมสำหรับการวิจัย

การศึกษาและวิจัยในครั้งนี้ได้รับการอนุมัติให้ทำการศึกษาวิจัยในมนุษย์โดยผ่านการพิจารณาจากคณะกรรมการจริยธรรมวิจัยในมนุษย์ มหาวิทยาลัยแม่ฟ้าหลวง ว่าสอดคล้องกับแนวทางจริยธรรมสากล ได้แก่ ปฏิญญาเฮลซิงกิ (Declaration of Helsinki) รายงานเบลมอนต์ (Belmont report) แนวทางจริยธรรมสากลสำหรับการวิจัยในมนุษย์ของสภาองค์การสากลด้านวิทยาศาสตร์การแพทย์ (CIOMS) และแนวทางการปฏิบัติการวิจัยที่ดี (ICH GCP) หมายเลขรับรองการวิจัย COA: 52/2025 รหัสโครงการวิจัย EC 22190 – 18 วันที่รับรองด้านจริยธรรมโครงการวิจัย 21 เมษายน 2566 วันสิ้นสุดการรับรอง 01 เมษายน 2569 สำหรับกระบวนการเก็บข้อมูลจากกลุ่มตัวอย่างหรืออาสาสมัคร ผู้วิจัยได้ชี้แจงรายละเอียดการวิจัย วัตถุประสงค์ ขั้นตอนการเก็บข้อมูล การนำข้อมูลไปใช้ในการวัดผลและประเมินผลต่าง ๆ ในการศึกษาวิจัยครั้งนี้หากผู้ร่วมวิจัยหรืออาสาสมัครมีความรู้สึกไม่ปลอดภัยต่อการเก็บรักษาข้อมูลที่ใช้ในการศึกษาวิจัย ผู้ร่วมวิจัยหรืออาสาสมัครสามารถแจ้งต่อผู้วิจัยให้ลบหรือกำจัดข้อมูลที่เกี่ยวข้องกับอาสาสมัครได้ทุกเมื่อและผู้วิจัยได้มีการแจ้งต่ออาสาสมัครก่อนเก็บข้อมูลทุกครั้งว่า “ข้อมูลที่จะใช้สำหรับการศึกษาวิจัยในครั้งนี้จะถูกเก็บเป็นความลับและจะรายงานผลการศึกษาวิจัยแบบภาพรวมเท่านั้น ซึ่งไม่สามารถระบุถึงตัวตนของผู้หนึ่งผู้ใดได้ ข้อมูลที่เก็บรวบรวมในครั้งนี้จะถูกใช้เฉพาะในงานวิจัยนี้เท่านั้น”

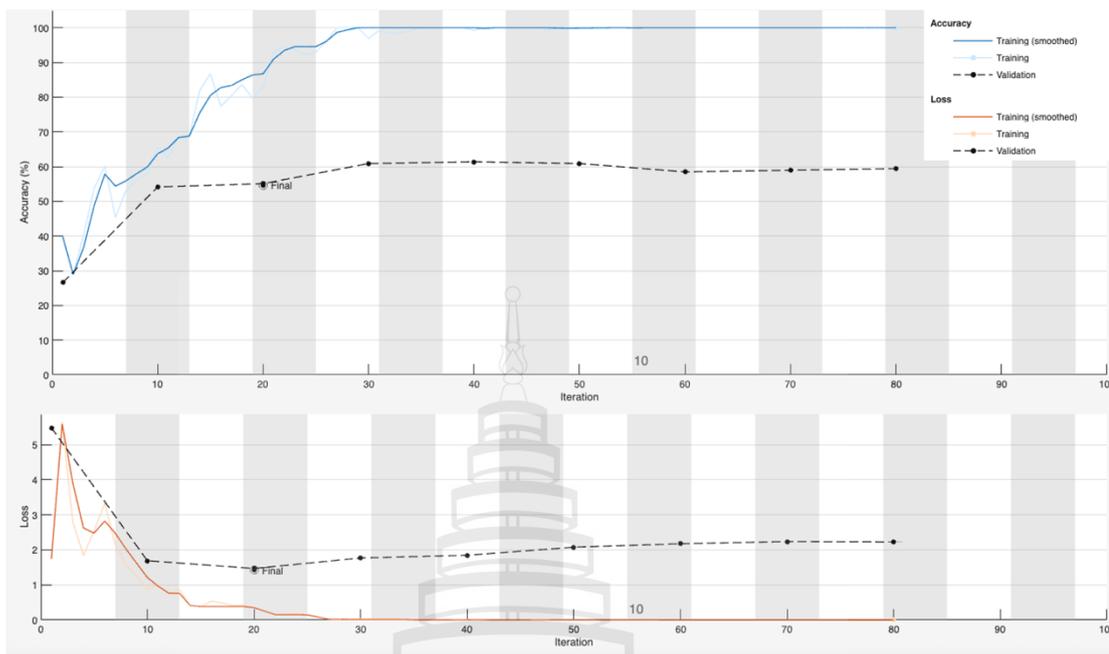
บทที่ 4

ผลการศึกษาวิจัยและอภิปรายผล

การศึกษาคั้งนี้มุ่งเน้นการพัฒนาแบบจำลองโครงข่ายประสาทเทียมเชิงลึก เพื่อจำแนกระดับความรุนแรงของสิ่วบนใบหน้า โดยบทนี้นำเสนอภาพรวมผลการทดลองจากกระบวนการหลักทั้งหมด พบว่า การทำ Preprocessed data เช่น การแยกส่วนภาพใบหน้าด้วยวิธี Face Parsing การปรับขนาดภาพ การ Normalize ค่า pixel การสุ่มเรียงลำดับข้อมูล และการเพิ่มข้อมูลด้วย Data Augmentation ช่วยเพิ่มความถูกต้องจาก 28.08% เป็น 37.50% และลดปัญหาภาวะโมเดลจำข้อมูลมากเกินไป (Overfitting) การปรับค่าพารามิเตอร์ Batch Size และ Learning Rate พบว่าค่าที่เหมาะสมคือ Batch Size = 128 และ Learning Rate = 0.001 ซึ่งส่งผลให้ ResNet50 มีค่า Test Accuracy = 52.27% และมี Precision, Recall, F1-score และ Specificity สูงขึ้น แสดงถึงความเสถียรของการเรียนรู้ การตรวจสอบความเสถียรด้วย 5-Fold Cross Validation พบค่าเฉลี่ย Validation Accuracy เท่ากับ 50.99% และค่าเบี่ยงเบนมาตรฐาน 6.09% แสดงถึงความสม่ำเสมอของโมเดล อีกทั้งการปรับสมดุลข้อมูลด้วยเทคนิค GANs ให้ผลดีกว่า Base model, ROS และ SMOTE (Test Accuracy = 51.13%, Precision = 0.57, Recall = 0.50, F1-score = 0.49 และ Specificity = 0.75) เทคนิค GANs สะท้อนให้เห็นถึงความสามารถในการเพิ่มประสิทธิภาพการจำแนกระดับความรุนแรงของสิ่วในงานวิจัยนี้

4.1 การเปรียบเทียบประสิทธิภาพของแบบจำลองระหว่างข้อมูลดิบ (Raw Data) และข้อมูลที่ผ่านการเตรียมข้อมูล (Preprocessed Data)

การเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกระดับความรุนแรงของสิ่วระหว่างข้อมูลภาพใบหน้าจากชุดข้อมูลดิบ และข้อมูลหลังผ่านกระบวนการเตรียมข้อมูล ด้วย ResNet18 เป็นแบบจำลองเริ่มต้น (Baseline) โดยกำหนดค่าพารามิเตอร์เริ่มต้นในการฝึกแบบจำลอง ดังนี้ Learning rate = 0.001, Batch size = 128, Epochs = 30



ภาพที่ 4.1 แสดงกราฟผลการฝึกของแบบจำลอง (Training Progress Graph)

จากกราฟในภาพที่ 4.1 แสดงผลการเปรียบเทียบความก้าวหน้าของการฝึกแบบจำลอง (Training Progress) กราฟด้านบนแสดงค่าของ Baseline โดยความถูกต้อง (Accuracy) และกราฟด้านล่างแสดงค่าความสูญเสีย (Loss) พบว่า เส้นสีน้ำเงินซึ่งแทนค่าความถูกต้องของชุดข้อมูลฝึก (Training Accuracy) มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องจนเกือบแตะระดับ 100% ภายในรอบที่ 30 สะท้อนว่าแบบจำลองสามารถเรียนรู้ข้อมูลฝึกได้อย่างเต็มที่ แต่เส้นประสีดำซึ่งแทนค่าความถูกต้องของชุดตรวจสอบ (Validation Accuracy) กลับคงที่อยู่ประมาณ 54.59% และไม่เพิ่มขึ้นตาม ส่งผลให้เกิดภาวะ Overfitting ส่วนกราฟค่าความสูญเสีย (Loss) พบว่า Training Loss ลดลงอย่างรวดเร็วในช่วงแรกและเข้าใกล้ศูนย์หลัง Iteration ที่ 20 ขณะที่ Validation Loss มีการแกว่งขึ้นลงและไม่ลดลงตาม Training Loss

ตารางที่ 4.1 การประเมินประสิทธิภาพของแบบจำลองจำแนกระดับความรุนแรงของสี

Technique	ValAcc (%)	TestAcc (%)	Class	Precision	Recall	F1	Specificity
Raw Data	54.59	28.08	1	0.21	0.28	0.24	0.68
			2	0.27	0.14	0.19	0.82
			3	0.32	0.36	0.34	0.33
			(AVG)	0.27	0.26	0.26	0.61
			Preprocessed data	40.85	37.50	1	0.25
			2	0.29	0.19	0.23	0.8
			3	0.52	0.48	0.5	0.65
			(AVG)	0.42	0.38	0.39	0.70

การเปรียบเทียบประสิทธิภาพระหว่างข้อมูลดิบและข้อมูลที่ผ่านการเตรียมข้อมูล ดังแสดงในตารางที่ 4.1 พบว่าข้อมูลดิบมีค่า Validation Accuracy สูงกว่า (54.59%) แต่ให้ค่า Test Accuracy ต่ำมาก (28.08%) ในขณะที่ข้อมูลที่ผ่านการเตรียมข้อมูลช่วยเพิ่ม Test Accuracy จาก 28.08% เป็น 37.50% และค่าเฉลี่ยของ F1-Score จาก 0.26 เป็น 0.39 รวมถึง Precision, Recall และ Specificity เพิ่มขึ้นจาก 0.27, 0.26 และ 0.61 เป็น 0.42, 0.38 และ 0.70 ตามลำดับ โดยตัวหนาในตารางแสดงถึงค่าที่สูง จากตารางสะท้อนว่าการเตรียมข้อมูล เช่น การแยกส่วนของใบหน้า (Face Parsing), การเพิ่มข้อมูล (Augmentation) และการปรับค่าสีของพิกเซลให้อยู่ในช่วงมาตรฐาน (Normalization) มีส่วนช่วยลดความซ้ำซ้อนของข้อมูล ลดสัญญาณรบกวน และเพิ่มความสามารถของแบบจำลองในการจำแนกสปีชีส์ได้ถูกต้องและครอบคลุมมากยิ่งขึ้น นอกจากนี้ ผลการประเมินรายคลาสพบว่าในข้อมูลที่ผ่านการเตรียมข้อมูล ระดับความรุนแรงที่ 3 (มีค่า Precision, Recall และ F1-score สูงที่สุด (0.52, 0.48 และ 0.50 ตามลำดับ) สะท้อนให้เห็นว่าแบบจำลองสามารถจดจำลักษณะสปีชีส์ที่รุนแรงได้ชัดเจนกว่าคลาสอื่น ขณะที่ระดับความรุนแรงของสปีชีส์ (Class 1-2) มีค่าความถูกต้องเพิ่มขึ้นหลังการปรับปรุงข้อมูล แสดงให้เห็นว่าขั้นตอนการเตรียมข้อมูลมีบทบาทสำคัญในการสร้างความสมดุลและเพิ่มประสิทธิภาพการเรียนรู้ของแบบจำลองโดยรวม

จากการทำ Preprocessed Data สามารถช่วยให้การจำแนกระดับความรุนแรงของสปีชีส์มีความเสถียรขึ้น โดยเฉพาะการตัดฉากหลังที่ช่วยให้โมเดลโฟกัสเฉพาะบริเวณผิวหนัง ลดสิ่งรบกวน เช่น เส้นผม เสื้อผ้า หรือพื้นหลัง ทำให้คุณลักษณะที่เรียนรู้มีความจำเพาะต่อสปีชีส์มากยิ่งขึ้น ซึ่งสอดคล้องกับ (Han et al., 2020) ที่ระบุว่า การใช้เทคนิค Face Region Segmentation สามารถลดผลของ Background clutter ได้อย่างมีประสิทธิภาพ และตรงกับ (Zhang et al., 2021)

นอกจากนี้ การ Normalize ค่า pixel ให้อยู่ในช่วงมาตรฐานเดียวกันช่วยให้การเรียนรู้ของโครงข่ายประสาทเทียมแบบ CNN มีความเสถียรมากขึ้น ซึ่งสอดคล้องกับแนวคิดของ Goodfellow et al. (2016) ที่ระบุว่า การปรับช่วงข้อมูลให้อยู่ในมาตรฐานเดียวกันสามารถลดความแปรปรวนของการอัปเดตน้ำหนัก (Weight Updates) และเพิ่มประสิทธิภาพในการฝึกแบบจำลอง การสุ่มลำดับข้อมูล (Shuffle) และการทำ Data Augmentation ยังช่วยลดการจดจำเฉพาะข้อมูลฝึก (Memorization) เพิ่มความหลากหลายของข้อมูล และเสริมความสามารถในการเรียนรู้แบบทั่วไป (Generalization) เพื่อลดความเสี่ยงของการเกิด Overfitting ทั้งนี้สอดคล้องกับรายงานของ Shorten and Khoshgoftaar (2019) ที่ชี้ว่าการใช้ Data Augmentation เป็นเทคนิคสำคัญในการเพิ่มประสิทธิภาพของ Deep Learning Model สำหรับงานจำแนกภาพทางการแพทย์

การทำ Preprocessed data ช่วยให้แบบจำลองสามารถเรียนรู้คุณลักษณะที่สำคัญของภาพผิวหนังได้ชัดเจนขึ้น ส่งผลให้ความสามารถในการจำแนกระดับความรุนแรงของสปีชีส์มีความถูกต้องและมีความเสถียรขึ้น ข้อมูลที่ผ่านการเตรียมดังกล่าวจึงถูกนำไปใช้ในการ ปรับแต่งค่าพารามิเตอร์ของ

แบบจำลอง (Hyperparameter Tuning) และ การเปรียบเทียบประสิทธิภาพของแบบจำลอง (Model Performance Comparison) ในขั้นตอนต่อไปของการวิจัย เพื่อให้ได้แบบจำลองที่มีความเหมาะสมและมีประสิทธิภาพในการจำแนกระดับความรุนแรงของสิวบนใบหน้า

4.2 การปรับแต่งพารามิเตอร์และการเปรียบเทียบประสิทธิภาพของแบบจำลอง (Model Optimization and Performance Comparison)

4.2.1 การเปรียบเทียบประสิทธิภาพของการปรับพารามิเตอร์และแบบจำลอง

ในการทดลองครั้งนี้ ผู้วิจัยได้ทำการปรับค่าพารามิเตอร์หลักของแบบจำลองโครงข่ายประสาทเทียมเชิงลึก เพื่อหาค่าที่เหมาะสมสำหรับการจำแนกระดับความรุนแรงของสิว โดยใช้ ResNet18, ResNet50, GoogLeNet และ Inception-V3 ด้วยการปรับพารามิเตอร์ ได้แก่ ขนาดชุดข้อมูลย่อย (Batch Size) และ อัตราการเรียนรู้ (Learning Rate) ซึ่งแต่ละค่ามีผลต่อประสิทธิภาพของการเรียนรู้ของแบบจำลองทั้งสิ้น

ตารางที่ 4.2 การปรับพารามิเตอร์ของแต่ละแบบจำลอง

Model	Hyperparameter		ValAcc	TestAcc
	Batch Size	Learning Rate		
ResNet18	16	0.1	0.43662	0.44318
		0.01	0.35211	0.32955
		0.001	0.40845	0.37500
		0.0001	0.43662	0.51136
	32	0.1	0.43662	0.44318
		0.01	0.43662	0.38636
		0.001	0.42254	0.45455
		0.0001	0.30986	0.32955
	64	0.1	0.46479	0.38636
		0.01	0.43662	0.44318
		0.001	0.40845	0.46591
		0.0001	0.45070	0.35227
128	0.1	0.38028	0.38636	
	0.01	0.23944	0.25000	
	0.001	0.46479	0.45455	
	0.0001	0.46479	0.37500	

ตารางที่ 4.2 (ต่อ)

Model	Hyperparameter		ValAcc	TestAcc
	Optimizers	Learning Rate		
ResNet50	16	0.1	0.39437	0.40909
		0.01	0.36620	0.35227
		0.001	0.40845	0.37500
		0.0001	0.42254	0.39773
	32	0.1	0.40845	0.43182
		0.01	0.45070	0.40909
		0.001	0.29577	0.39773
		0.0001	0.36620	0.51136
	64	0.1	0.40845	0.38636
		0.01	0.42254	0.39773
		0.001	0.46479	0.50000
		0.0001	0.45070	0.39773
GoogLeNet	16	0.1	0.40845	0.36364
		0.01	0.29677	0.29545
		0.001	0.40845	0.52273
		0.0001	0.38028	0.37500
	32	0.1	0.42254	0.43182
		0.01	0.45070	0.38636
		0.001	0.30986	0.30682
		0.0001	0.38028	0.34091
	64	0.1	0.29577	0.29545
		0.01	0.30986	0.25000
		0.001	0.45070	0.42045
		0.0001	0.43662	0.48864
128	64	0.1	0.42254	0.43182
		0.01	0.46479	0.40909
		0.001	0.39437	0.42045
		0.0001	0.42254	0.35227
	128	0.1	0.39437	0.28409
		0.01	0.43662	0.44318
		0.001	0.42254	0.47727
		0.0001	0.38028	0.36364

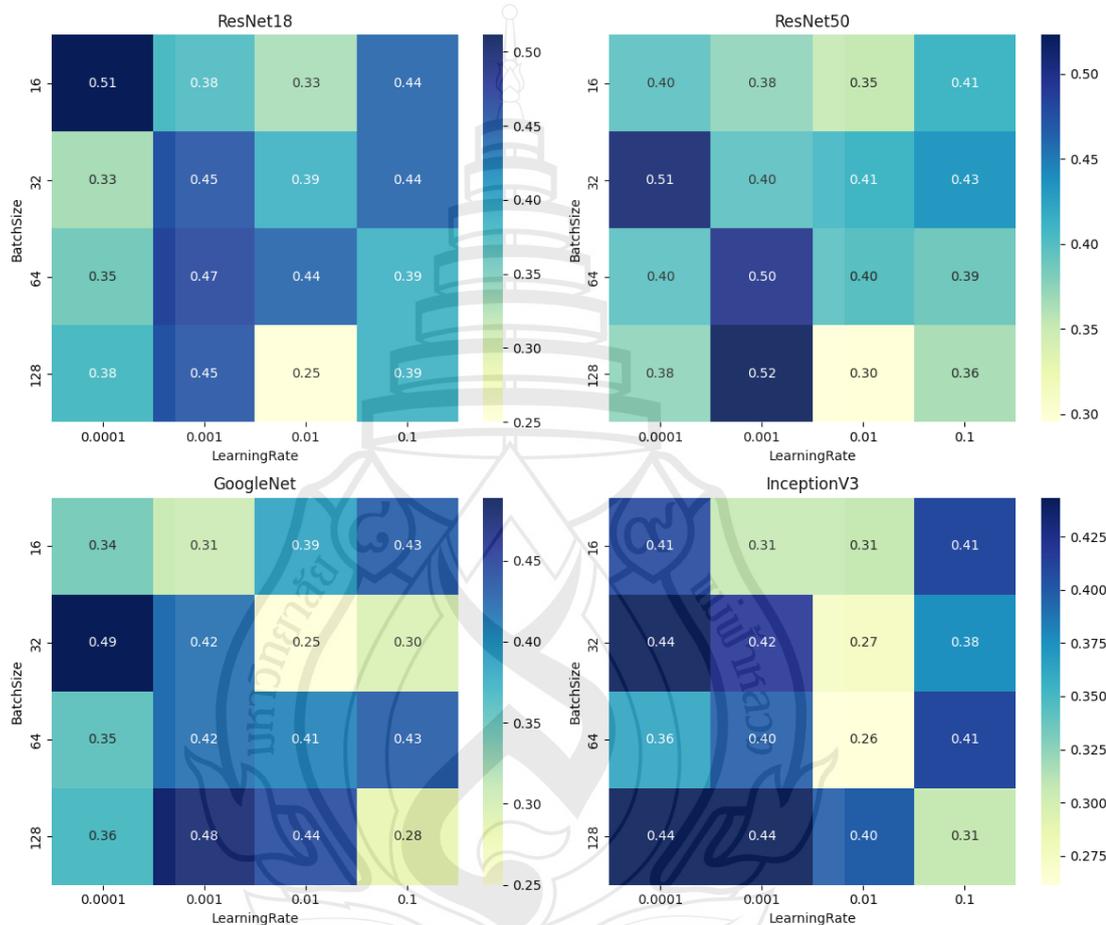
ตารางที่ 4.2 (ต่อ)

Model	Hyperparameter		ValAcc	TestAcc
	Optimizers	Learning Rate		
InceptionV3	16	0.1	0.43662	0.40909
		0.01	0.28169	0.30682
		0.001	0.28169	0.30682
	32	0.0001	0.47887	0.40909
		0.1	0.43662	0.37500
		0.01	0.28169	0.27273
	64	0.001	0.28169	0.42045
		0.0001	0.47887	0.44318
		0.1	0.42254	0.40909
		0.01	0.26761	0.26136
		0.001	0.40845	0.39773
		0.0001	0.28169	0.36364
128	0.1	0.32394	0.30682	
	0.01	0.40845	0.39773	
	0.001	0.43662	0.44318	
	0.0001	0.43662	0.44318	

หมายเหตุ ValAcc = Validation accuracy, TesAcc = Test accuracy

ผลการปรับพารามิเตอร์ของแบบจำลอง ResNet18, ResNet50, GoogLeNet และ Inception-V3 โดยพิจารณาค่าความถูกต้องบนชุดตรวจสอบ (Validation Accuracy) และชุดทดสอบ (Test Accuracy) เพื่อประเมินความสามารถของแต่ละแบบจำลองและหาค่าพารามิเตอร์ที่เหมาะสมสำหรับแต่ละโมเดล จากตารางที่ 4.2 การปรับพารามิเตอร์ของแต่ละแบบจำลอง พบว่า ResNet18 ให้ผล Batch Size = 128 และ Learning Rate = 0.0001 โดยได้ค่า Test Accuracy เท่ากับ 51.14% แสดงให้เห็นว่า เมื่อขนาดชุดข้อมูลย่อยใหญ่ขึ้นและอัตราการเรียนรู้ลดลง โมเดลสามารถปรับน้ำหนักได้อย่างละเอียดและมีเสถียรภาพ ส่วน ResNet50 พบว่า ค่าที่เหมาะสม คือ Batch Size = 128 และ Learning Rate = 0.001 ให้ค่า Test Accuracy สูงสุดเท่ากับ 52.27% แสดงให้เห็นถึงศักยภาพในการเรียนรู้ลักษณะเชิงลึกของภาพผิวหน้าได้อย่างมีประสิทธิภาพ ขณะที่ GoogLeNet ให้ค่า Test Accuracy สูงสุด 48.86% ที่ Batch Size = 32 และ Learning Rate = 0.0001 สะท้อนว่าโครงสร้างแบบ Inception Module มีความสามารถในการเรียนรู้เชิงลึกได้ดีในระดับหนึ่ง แต่ยังมีข้อจำกัดด้านการปรับสมดุลของข้อมูล คือ ข้อมูลในแต่ละระดับความรุนแรงไม่

เท่ากัน ส่วน Inception-V3 ให้ค่า Test Accuracy = 44.32% ที่ Batch Size = 128 และ Learning Rate = 0.001 แสดงถึงแนวโน้มการเรียนรู้ที่เสถียรขึ้นเมื่อเปรียบเทียบกับ Base model โดยภาพรวมของการเปรียบเทียบแบบจำลองในการปรับพารามิเตอร์ จะเห็นได้ว่าแบบจำลองกลุ่ม ResNet ให้ผลการเรียนรู้และการทดสอบอาจมีความเหมาะสมกว่าแบบจำลองอื่น โดยเฉพาะ ResNet50 ที่มีการถ่ายโอนน้ำหนักที่เหมาะสมสำหรับการจำแนกระดับความรุนแรงของสิวในงานวิจัยนี้



ภาพที่ 4.2 Heatmap แสดงค่า Test Accuracy สูงสุดของแบบจำลองในแต่ละค่าพารามิเตอร์

จากการปรับพารามิเตอร์ของแบบจำลอง ภาพที่ 4.2 พบว่า ResNet50 ให้ค่าความถูกต้องสูงที่สุดเท่ากับ 52% ที่ค่าพารามิเตอร์ Batch Size = 128 และ Learning Rate = 0.001 ซึ่งมีการทดสอบในช่วงค่าของ Batch Size และ Learning Rate โดยผลลัพธ์ถูกแสดงในรูปแบบ Heatmap เพื่อแสดงระดับค่าความถูกต้องที่แตกต่างกันด้วยโทนสีตั้งแต่ฟ้าอ่อนถึงน้ำเงินเข้ม จากภาพจะเห็นว่าสีที่เข้มกว่าแสดงถึงค่าความถูกต้องที่สูงกว่า ซึ่งช่วยให้สามารถสังเกตแนวโน้มการตอบสนองของแบบจำลองต่อการปรับพารามิเตอร์ได้และค่าที่ให้ประสิทธิภาพรองลงมา ได้แก่ ResNet18, GoogleNet, InceptionV3 ตามลำดับ

ResNet18 ให้ค่า Validation Accuracy คือ 46.48% และ Test Accuracy เท่ากับ 51.14% เมื่อใช้ Batch Size = 128 และ Learning Rate = 0.0001 ซึ่งเป็นอัตราการเรียนรู้ต่ำและชุดข้อมูลย่อยขนาดใหญ่ ผลลัพธ์ดังกล่าวแสดงว่าโมเดลสามารถเรียนรู้คุณลักษณะได้อย่างต่อเนื่องและลดการสั่นของค่า Gradient ทำให้การปรับน้ำหนัก (Weight Updates) มีเสถียรภาพมากขึ้น (He et al., 2016)

ResNet50 เป็นแบบจำลองที่ให้ผลที่ดีที่สุดในการทดลองนี้ โดยมีค่า Test Accuracy = 52.27% เมื่อใช้ Batch Size = 128 และ Learning Rate = 0.001 ซึ่งถือเป็นค่าที่สมดุลระหว่างความเร็วในการเรียนรู้และความเสถียรของการปรับน้ำหนัก โมเดลนี้มีโครงสร้างลึกกว่า ResNet18 และใช้เทคนิค “Residual Block” เพื่อป้องกันปัญหา Gradient Vanishing ทำให้สามารถเรียนรู้ลักษณะเชิงลึกของสปีดได้แม่นยำยิ่งขึ้น (He et al., 2016; Rawat & Wang, 2017)

GoogLeNet ผลการทดลองพบว่าได้ค่า Test Accuracy สูงสุดที่ 48.86% เมื่อใช้ Batch Size = 32 และ Learning Rate = 0.0001 โดยโครงสร้างแบบ Inception Module ที่รวมการกรองภาพหลายขนาดเข้าด้วยกัน ทำให้สามารถดึงคุณลักษณะหลากหลายระดับได้ดี อย่างไรก็ตามความสามารถในการจำแนกภาพสปีดในบางระดับรุนแรงยังไม่แม่นยำเท่ากับ ResNet50 ซึ่งมีการคงโครงสร้างเชิงลึกที่ต่อเนื่องกว่า (Szegedy et al., 2015)

Inception-V3 ให้ค่า Test Accuracy สูงสุด 44.32% ที่ Batch Size = 128 และ Learning Rate = 0.001 โดยโมเดลนี้ได้รับการปรับปรุงจาก GoogLeNet ให้มีการคำนวณที่มีประสิทธิภาพมากขึ้น เช่น การใช้ Factorized Convolution และ Batch Normalization เพื่อเพิ่มความเร็วในการเรียนรู้ (Szegedy et al., 2016) เมื่อเปรียบเทียบกับ ResNet50 แล้ว พบว่าความสามารถในการเรียนรู้รายละเอียดเชิงลึกของสปีดยังไม่ดีเท่ากัน ซึ่งอาจเกิดจากลักษณะของข้อมูลภาพที่มีความละเอียดจำกัดและไม่ซับซ้อนเพียงพอสำหรับโครงสร้าง Inception-V3 ที่ต้องการข้อมูลหลากหลายระดับ

จากผลการทดลองการปรับแต่งพารามิเตอร์และการเปรียบเทียบประสิทธิภาพของแบบจำลอง พบว่า ResNet50 เป็นแบบจำลองที่มีประสิทธิภาพสูง ซึ่งให้ทั้งค่าความถูกต้องและความเสถียรในการเรียนรู้สูงกว่าโมเดลอื่น โดยความเสถียรในการเรียนรู้พิจารณาจากแนวโน้มของค่า Validation Accuracy (ValAcc) และ Test Accuracy (TestAcc) ซึ่งมีความใกล้เคียงกันในหลายชุดของการปรับไฮเปอร์พารามิเตอร์ สะท้อนให้เห็นถึงความสามารถของแบบจำลองในการเรียนรู้และทั่วไปกับข้อมูลที่ไม่เคยเห็นได้อย่างสม่ำเสมอ นอกจากนี้ เมื่อมีการปรับค่า batch size และ learning rate พบว่าค่า TestAcc ของ ResNet50 มีการเปลี่ยนแปลงในช่วงที่จำกัดและไม่ผันผวนรุนแรงเท่าแบบจำลอง

ResNet50 แสดงให้เห็นถึงศักยภาพของโครงข่ายประสาทเทียมแบบ Residual Learning ในการจำแนกภาพที่มีความละเอียดเชิงลึกและความแตกต่างระดับเล็กน้อยของสิวบนใบหน้า ในขณะที่ GoogLeNet และ Inception-V3 มีความผันผวนที่รุนแรงกว่า และให้ผลลัพธ์ที่ดีในระดับปานกลาง

4.2.2 การเปรียบเทียบประสิทธิภาพของอัลกอริทึมการปรับค่าน้ำหนัก (Solver)

เพื่อประเมินและเปรียบเทียบประสิทธิภาพของอัลกอริทึมการปรับค่าน้ำหนัก (Solver) งานวิจัยนี้ได้ทำการเปรียบเทียบอัลกอริทึม SGDM, RMSprop และ Adam ในกระบวนการฝึกแบบจำลองสำหรับการจำแนกระดับความรุนแรงของสิว โดยเลือกใช้แบบจำลอง ResNet50 ซึ่งแสดงความเสถียรสูงจากผลการวิเคราะห์ในตารางที่ 4.2 ทั้งนี้ได้กำหนดค่าพารามิเตอร์ที่เหมาะสมจากการทดลอง ได้แก่ Batch Size เท่ากับ 128 และ Learning Rate เท่ากับ 0.001 เพื่อให้การเปรียบเทียบประสิทธิภาพของอัลกอริทึมการปรับค่าน้ำหนักเป็นไปอย่างเป็นธรรมและสะท้อนศักยภาพของแต่ละอัลกอริทึมได้อย่างชัดเจน

ตารางที่ 4.3 ผลการเปรียบเทียบประสิทธิภาพของอัลกอริทึมการปรับค่าน้ำหนัก ในการจำแนกระดับความรุนแรงของ

Optimizer	TestAcc (%)	Class	Precision	Recall	F1	Specificity
SGDM	0.41	1	0.35	0.43	0.39	0.72
		2	0.29	0.3	0.3	0.69
		3	0.6	0.51	0.55	0.73
		(AVG)	0.41	0.41	0.71	0.41
RMSprop	0.41	1	0.33	0.348	0.34	0.75
		2	0.4	0.346	0.37	0.79
		3	0.5	0.538	0.51	0.57
		(AVG)	0.41	0.41	0.70	0.41
Adam	0.52	1	0.4	0.43	0.41	0.76
		2	0.6	0.11	0.19	0.96
		3	0.56	0.84	0.68	0.48
		(AVG)	0.46	0.43	0.73	0.46

ผลการทดลองตารางที่ 4.3 พบว่า Adam เป็น Solver ที่ให้ผลลัพธ์โดยรวมดีกว่า SGDM และ RMSprop อย่างชัดเจน โดยมีค่า Test Accuracy ซึ่งสูงที่สุดเมื่อเทียบกับ optimizer อื่น 52.27%, Precision = 0.52, Recall = 0.46, F1-score = 0.43, และ Specificity = 0.73 แสดงให้เห็นว่า Adam สามารถช่วยให้แบบจำลองเรียนรู้รูปแบบข้อมูลได้มีประสิทธิภาพมากกว่า optimizer อื่น นอกจากนี้ ค่า F1-score ยังแสดงให้เห็นถึงสมดุลระหว่างความแม่นยำและความครอบคลุมในการจำแนกข้อมูลรูปภาพในแต่ละระดับความรุนแรง มากไปกว่านั้น ค่าความจำเพาะ (Specificity) ที่สูงยังสะท้อนว่าแบบจำลองสามารถจำแนกภาพที่ไม่เป็นสิวออกจากกลุ่มอื่นได้อย่างแม่นยำ

ผลการทดลองชี้ให้เห็นว่า Adam มีความได้เปรียบเนื่องจากกลไกการปรับ learning rate แบบอัตโนมัติร่วมกับ momentum ซึ่งสอดคล้องกับงานวิจัยก่อนหน้านี้ที่ระบุว่า Adam มีจุดเด่นในการผสมผสานแนวคิดของ momentum และ adaptive learning rate เข้าด้วยกัน ทำให้สามารถปรับค่าพารามิเตอร์ได้อย่างมีประสิทธิภาพและมีความเสถียรในการลู่เข้าสู่คำตอบที่เหมาะสม (Kingma & Ba, 2015) อย่างไรก็ตาม ความไม่สมดุลของค่า Recall ระหว่างแต่ละระดับความรุนแรง โดยเฉพาะระดับความรุนแรงที่ 2 สะท้อนว่าแบบจำลองอาจยังได้รับผลกระทบจากการกระจายตัวของข้อมูล (class imbalance) ซึ่งควรได้รับการปรับปรุงเพิ่มเติมในการทดลองถัดไป เช่น เพิ่มจำนวนข้อมูลตัวอย่างในบางระดับความรุนแรงหรือทุกระดับความรุนแรง

ในขณะที่ SGDM ให้ค่า Test Accuracy เพียง 43.18%, Precision = 0.41, Recall = 0.41, F1 = 0.41 และ Specificity = 0.71 แม้กระบวนการเรียนรู้มีความช้ากว่า Adam เนื่องจากการปรับอัตราการเรียนรู้ที่คงที่และไม่ยืดหยุ่นต่อการเปลี่ยนแปลงของข้อมูล ทำให้ผลลัพธ์โดยรวมต่ำกว่า (Bottou et al., 2018; Wilson et al., 2017)

ส่วน RMSprop แสดงให้เห็นว่า แบบจำลองสามารถเรียนรู้รูปแบบของข้อมูลในชุดตรวจสอบได้ดีในระหว่างการฝึก แต่เมื่อพิจารณาผลการทดสอบกับข้อมูลที่ไม่เคยเห็นมาก่อน พบว่าค่า Test Accuracy ไม่เพิ่มขึ้น คือ 43.18% ประกอบกับค่า Precision, Recall และ F1-score = 0.41 และค่า Specificity = 0.70 ซึ่งอยู่ในระดับใกล้เคียงกับ SGDM และต่ำกว่า Adam ผลลัพธ์ดังกล่าวสะท้อนให้เห็นถึง แนวโน้มของการเกิด overfitting ในกระบวนการฝึก คือ แบบจำลองสามารถปรับตัวให้เข้ากับข้อมูลฝึกและข้อมูลตรวจสอบได้ดี แต่ไม่สามารถทั่วไป (generalize) ได้อย่างมีประสิทธิภาพเมื่อทดสอบกับข้อมูลใหม่ ปรากฏการณ์นี้สอดคล้องกับงานวิจัยที่ระบุว่า adaptive learning rate methods เช่น RMSprop อาจมีความเสี่ยงต่อการเกิด overfitting หากไม่มีการควบคุมด้วยเทคนิค regularization หรือการปรับค่าพารามิเตอร์อย่างเหมาะสม (Goodfellow et al., 2016; Ruder, 2017)

เมื่อพิจารณาผลเปรียบเทียบในแต่ละระดับความรุนแรง พบว่าระดับความรุนแรงที่ 1 ผลการทดลองแสดงให้เห็นว่า Adam ให้ค่า Precision = 0.40 และ Recall = 0.43 ซึ่งสูงกว่า SGDM (0.35, 0.43) และ RMSprop (0.33, 0.35) เล็กน้อย แสดงให้เห็นถึง Adam มีความสามารถที่ใกล้เคียงกันในการจำแนกภาพสักระดับความรุนแรงที่ 1 โดยไม่สูญเสียความสมดุลระหว่าง Precision และ Recall มากนัก ซึ่งเป็นผลจากการปรับอัตราการเรียนรู้ที่ยืดหยุ่นต่อข้อมูลที่มีความคล้ายคลึงสูง ในลักษณะของสักระดับเริ่มต้น ระดับความรุนแรงที่ 2 ค่า Precision ของ Adam สูงสุดที่ 0.60 แต่มี Recall ต่ำเพียง 0.11 ส่งผลให้ค่า F1-score ต่ำสุดในคลาสนี้ (0.19) เมื่อเทียบกับ SGDM (0.30) และ RMSprop (0.37) ซึ่งอาจเกิดจากความไม่สมดุลของจำนวนภาพในคลาสหรือความคล้ายคลึงกับสักระดับรุนแรง ทำให้โมเดลมีแนวโน้มจำแนกผิดไปยังคลาส 3 แม้จะมั่นใจในการจำแนกบางภาพ

(Precision สูง) แต่ไม่สามารถครอบคลุมตัวอย่างทั้งหมดได้ดี (Recall ต่ำ) ขณะที่ใน ระดับความรุนแรงที่ 3 Adam ให้ค่า Precision = 0.56 และ Recall = 0.84 ซึ่งสูงกว่าในทุกระดับความรุนแรงของ Adam โดยมีค่า F1-score = 0.68 และ Specificity = 0.48 แสดงว่าโมเดลสามารถจดจำลักษณะสิวที่รุนแรงได้อย่างชัดเจนและตอบสนองต่อการทดสอบได้ดี เนื่องจากสิวระดับนี้มีความแตกต่างทางภาพที่เด่นชัด เช่น รอยแดง การอักเสบ และขนาดของตุ่มสิว ซึ่งเอื้อต่อการเรียนรู้ของโมเดลมากกว่าระดับอื่น

การที่ Adam ให้ประสิทธิภาพสูงกว่า Solver อื่น อาจสามารถอธิบายได้จากกลไกของอัลกอริทึม ซึ่งใช้การปรับอัตราการเรียนรู้ (Learning rate) ของแต่ละพารามิเตอร์แบบ Adaptive โดยอาศัยค่าเฉลี่ยเคลื่อนที่ (moving averages) ของกราเดียนต์และกำลังสองของกราเดียนต์ ช่วยให้การเรียนรู้มีความเสถียรและลู่เข้าสู่ค่าที่เหมาะสมได้รวดเร็วกว่า SGDM และ RMSprop มากไปกว่านั้น Adam ยังเหมาะสมกับงานที่มีข้อมูลภาพขนาดเล็กหรือไม่สมดุล เช่น ข้อมูลทางการแพทย์ ซึ่งต้องการการปรับพารามิเตอร์อย่างละเอียดในแต่ละชั้นของโครงข่ายประสาทเทียม (Kingma & Ba., 2017) การพัฒนาเพิ่มเติมของ Adam ยังช่วยลดปัญหา Overfitting และเพิ่มประสิทธิภาพในการเรียนรู้ในงานจำแนกภาพทางการแพทย์ ซึ่งมีลักษณะข้อมูลไม่สมดุลและความซับซ้อนสูง (Loshchilov & Hutter, 2019) แม้ RMSprop จะ เป็น Solver ที่มีความสามารถในการปรับอัตราการเรียนรู้แบบ adaptive เช่นกัน แต่การไม่มีส่วนของการแก้ไขอคติ (Bias-correction) ทำให้ค่าเฉลี่ยของกราเดียนต์ในช่วงต้นของการฝึกไม่เสถียร ส่งผลต่อความแม่นยำของชุดทดสอบ ในขณะที่ SGDM แม้จะเป็นวิธีการที่เสถียรและเป็นที่ยอมรับ แต่ต้องใช้เวลาลู่เข้านานและมีโอกาสติดอยู่ในค่าขั้วกลาง (Local minima) เมื่อข้อมูลมีความซับซ้อนสูง (Ruder et al., 2017)

จากผลการทดลองของ Resnet50 Batch Size เท่ากับ 128 และ Learning Rate เท่ากับ 0.001 ด้วยตัวปรับค่าพารามิเตอร์ (Solver) ที่ต่างกัน เพื่อประเมินผลลัพธ์ในชุดข้อมูลทดสอบ พบว่าแต่ละวิธีมีลักษณะการเรียนรู้และสมรรถนะที่แตกต่างกัน โดย Adam ให้ผลลัพธ์ที่เหมาะสมทั้งในด้านความถูกต้อง (Test Accuracy) และตัวชี้วัดสมรรถนะอื่น ๆ ได้แก่ Precision, Recall, F1-score และ Specificity สะท้อนถึงความสามารถของอัลกอริทึมในการปรับอัตราการเรียนรู้แบบปรับตัว (Adaptive Learning Rate) ทำให้แบบจำลองมีเสถียรภาพและรวดเร็วกว่า Solver อื่น

4.3 การประเมินแบบจำลองด้วย 5-Fold Cross Validation

การประเมินประสิทธิภาพของแบบจำลองในการจำแนกระดับความรุนแรงของสิวด้วยวิธี 5-Fold Cross Validation มีวัตถุประสงค์เพื่อประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลอง

ระหว่างการไว้วิธี 5-Fold Cross Validation และการประเมินจากชุดข้อมูลที่ใช้ในการทดลองก่อนหน้า รวมถึงเพื่อศึกษาความเสถียรและความน่าเชื่อถือของผลการทำนายของแบบจำลอง โดยในการทดลองนี้ได้นำแบบจำลองและค่าพารามิเตอร์ที่ให้ผลการเปรียบเทียบประสิทธิภาพที่ดีที่สุดจากการทดลองก่อนหน้า ได้แก่ ResNet50 ร่วมกับตัวปรับค่าน้ำหนัก Adam ที่ Learning Rate = 0.001, Batch Size = 128 มาใช้ในขั้นตอนการประเมินผล ข้อมูลชุดฝึก (Training Set) ถูกแบ่งออกเป็น 5 ส่วนเท่า ๆ กัน โดยในแต่ละรอบจะใช้ข้อมูล 1 ส่วนเป็นชุดตรวจสอบ (Validation Set) และอีก 4 ส่วนเป็นชุดฝึก (Training Set) ทำให้ข้อมูลทุกส่วนถูกนำมาใช้ทั้งในการฝึกและการตรวจสอบอย่างสมดุล การกำหนดค่า K=5 มีความเหมาะสมกับขนาดของชุดข้อมูล เนื่องจากสามารถช่วยลดอคติที่เกิดจากการแบ่งข้อมูลเพียงครั้งเดียว และเพิ่มความน่าเชื่อถือของผลการประเมินประสิทธิภาพของแบบจำลองได้อย่างมีประสิทธิภาพ

ตารางที่ 4.4 การประเมินประสิทธิภาพของแบบจำลองด้วยการตรวจสอบแบบ 5-Fold Cross Validation

Fold	Validation Accuracy (%)	Mean (ค่าเฉลี่ย)	Std Dev (ค่าเบี่ยงเบนมาตรฐาน)
1	53.52	50.99	6.09
2	60.56		
3	46.48		
4	47.89		
5	46.48		

ผลการทดลองตารางที่ 4.4 แสดงผลการประเมินประสิทธิภาพของแบบจำลองจำแนกระดับความรุนแรงของสิวด้วยวิธี 5-Fold Cross Validation โดยค่าความถูกต้องในการตรวจสอบ (Validation Accuracy) ของแต่ละรอบอยู่ในช่วง 46.48–60.56% ให้ค่าเฉลี่ยเท่ากับ 50.99% และมีค่าเบี่ยงเบนมาตรฐานเท่ากับ 6.09% ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่าแม้ค่าความถูกต้องของแต่ละ fold จะมีความแตกต่างกันบ้างตามลักษณะของชุดข้อมูลที่ถูกลับมาใช้เป็นชุดตรวจสอบ แต่โดยรวมแล้วแบบจำลองยังคงให้ผลการเรียนรู้ที่สม่ำเสมอและอยู่ในช่วงที่ยอมรับได้สำหรับงานจำแนกภาพที่มีความซับซ้อนและข้อมูลจำกัด ค่าเฉลี่ยของ Validation Accuracy ที่ประมาณร้อยละ 51 แสดงให้เห็นว่าแบบจำลองสามารถเรียนรู้รูปแบบของข้อมูลได้ในระดับหนึ่ง ขณะที่ค่าเบี่ยงเบนมาตรฐานที่ไม่สูงมาก (6.09%) บ่งชี้ถึงความเสถียรของการฝึกแบบจำลองในแต่ละรอบของการลับข้อมูล ซึ่งเป็นจุดประสงค์สำคัญของการใช้เทคนิค 5-Fold Cross Validation โดยเฉพาะในกรณีชุดข้อมูลมีขนาดไม่ใหญ่ การประเมินผลด้วยวิธีนี้ช่วยลดอคติจากการเลือกชุดข้อมูลตรวจสอบเพียงครั้งเดียว และทำให้ค่าประสิทธิภาพที่รายงานมีความน่าเชื่อถือมากขึ้น ผลการประเมินประสิทธิภาพของแบบจำลองด้วย

วิธี 5-Fold Cross Validation ดังที่ได้กล่าวมาแล้วข้างต้น ได้รายงานผลค่าความถูกต้องในการตรวจสอบ (Validation Accuracy) และค่าเบี่ยงเบนมาตรฐาน การรายงานผลในลักษณะค่าเฉลี่ยร่วมกับค่าเบี่ยงเบนมาตรฐานถือเป็นแนวปฏิบัติมาตรฐานในงานด้านการเรียนรู้ของเครื่อง (Machine learning) เนื่องจากช่วยแสดงทั้งสมรรถนะโดยรวมและความแปรปรวนของแบบจำลองจากการแบ่งข้อมูลที่แตกต่างกัน (Hastie et al., 2009; Raschka, 2018) นอกจากนี้ ในบริบทของการเรียนรู้เชิงลึก (Deep learning) ที่มีจำนวนข้อมูลจำกัด การใช้ cross validation ยังมีบทบาทสำคัญในการลดความเสี่ยงของการเกิด overfitting และช่วยให้ผลการประเมินมีความน่าเชื่อถือมากขึ้น (Goodfellow et al., 2016) ซึ่งสอดคล้องกับลักษณะของงานวิจัยด้านการจำแนกภาพทางการแพทย์ที่นิยมใช้ k-Fold Cross Validation เพื่อยืนยันความสามารถของแบบจำลองและความเสถียรของผลลัพธ์ที่รายงาน (Zou et al., 2019)

ตารางที่ 4.5 การเปรียบเทียบประสิทธิภาพของแบบจำลอง Preprocessed data with Adam กับ Preprocessed data with 5-fold cross validation

Technique	TestAcc (%)	Class	Precision	Recall	F1	Specificity
Preprocessed data with Adam	0.52	1	0.4	0.43	0.41	0.76
		2	0.6	0.11	0.19	0.96
		3	0.56	0.84	0.68	0.48
		(AVG)	0.46	0.43	0.73	0.46
Preprocessed data with 5-fold cross validation	51.14	1	0.39	0.39	0.39	0.78
		2	0.56	0.53	0.54	0.82
		3	0.55	0.56	0.55	0.63
		(AVG)	0.50	0.49	0.49	0.74

ผลการทดลองจากตารางที่ 4.5 แสดงการเปรียบเทียบประสิทธิภาพของแบบจำลองระหว่าง Preprocessed data with Adam กับ Preprocessed data with 5-fold cross validation โดยผลลัพธ์ชี้ให้เห็นว่าแนวทางการใช้ 5-Fold Cross Validation ให้ประสิทธิภาพเชิงสมดุลและความเสถียรของแบบจำลองดีกว่าอย่างชัดเจน เมื่อพิจารณาค่าเฉลี่ยของตัวชี้วัด พบว่าแบบจำลองที่ใช้ 5-Fold Cross Validation ให้ค่า Precision, Recall และ F1-score เฉลี่ยเท่ากับ 0.50, 0.49 และ 0.49 ตามลำดับ สูงกว่าแบบจำลองที่ใช้ Adam เพียงอย่างเดียวซึ่งให้ค่าเฉลี่ย Precision = 0.46, Recall = 0.43 และ F1-score = 0.46 ขณะที่ค่า Specificity เฉลี่ยเพิ่มขึ้นจาก 0.46 เป็น 0.74 สะท้อนถึงความสามารถที่ดีขึ้นในการจำแนกภาพที่ไม่เป็นสิวได้ถูกต้อง เมื่อพิจารณาผลการจำแนกในแต่ละระดับความรุนแรง พบว่าแบบจำลองที่ใช้ 5-Fold Cross Validation แสดงการเรียนรู้ที่สมดุล

มากขึ้นในทุกระดับความรุนแรง ระดับความรุนแรงที่ 1 มีค่า Precision และ Recall เท่ากันที่ 0.39 สะท้อนให้เห็นว่าแบบจำลองให้ผลการทำนายที่มีความสมดุล ไม่เอนเอียงไปทางความแม่นยำ (Precision) หรือความสามารถในการครอบคลุมตัวอย่างจริง (Recall) มากเกินไป ระดับความรุนแรงที่ 2 ให้ค่า Precision = 0.56, Recall = 0.53 และ F1-score = 0.54 ซึ่งเป็นค่าที่สูงและใกล้เคียงกันมากที่สุดในทุกระดับความรุนแรง บ่งชี้ว่าแบบจำลองสามารถเรียนรู้ลักษณะของสิวะระดับปานกลางได้อย่างชัดเจนและมีเสถียรภาพเพิ่มขึ้น ส่วนระดับความรุนแรงที่ 3 มีค่า Precision = 0.55 และ Recall = 0.56 แม้จะใกล้เคียงกับระดับความรุนแรงที่ 2 แต่มีค่า Specificity ต่ำกว่า (0.63) ซึ่งอาจเกิดจากความคล้ายคลึงของลักษณะทางภาพระหว่างสิวะรุนแรงกับระดับความรุนแรงอื่นบางส่วน ผลลัพธ์จากตารางที่ 4.5 แสดงให้เห็นว่าการใช้เทคนิค 5-Fold Cross Validation ร่วมกับการเตรียมข้อมูลช่วยให้แบบจำลองเรียนรู้ข้อมูลได้ครอบคลุมมากขึ้น สอดคล้องจากการแบ่งชุดข้อมูลเพียงครั้งเดียว และลดความเสี่ยงของการเกิด overfitting โดยเฉพาะในกรณีที่มีจำนวนข้อมูลมีจำกัด ส่งผลให้ผลการประเมินมีความเสถียรและสะท้อนสมรรถนะที่แท้จริงของแบบจำลองได้ดียิ่งขึ้น การเพิ่มขึ้นพร้อมกันของค่า Precision, Recall และ F1-score เฉลี่ย บ่งชี้ว่าแบบจำลองสามารถรักษาสมดุลระหว่างความแม่นยำและความสามารถในการครอบคลุมตัวอย่างได้ดีขึ้น โดยระดับความรุนแรงที่ 2 ให้ผลการจำแนกที่ดีที่สุด เนื่องจากลักษณะภาพมีความชัดเจน ขณะที่ระดับความรุนแรงที่ 3 แม้มีค่า Recall สูง แต่ค่า Specificity ที่ลดลงสะท้อนถึงความท้าทายในการแยกแยะจากคลาสนอื่น ซึ่งเป็นข้อจำกัดที่พบได้ทั่วไปในงานจำแนกภาพทางการแพทย์ ผลการทดลองยืนยันว่า 5-Fold Cross Validation เป็นวิธีประเมินที่เหมาะสม ช่วยเพิ่มความน่าเชื่อถือและความสามารถในการทั่วไปของแบบจำลอง สอดคล้องกับแนวคิดของ Ron Kohavi และงานวิจัยที่เกี่ยวข้อง (Kohavi, 1995; Tougui et al., 2021)

4.4 การปรับสมดุลข้อมูล (Resampling Technique)

ข้อมูลที่ใช้ในการเรียนรู้ของแบบจำลองในงานวิจัยนี้มีจำนวนตัวอย่างในแต่ละระดับความรุนแรงของสิวะไม่เท่ากัน ซึ่งก่อให้เกิดปัญหาความไม่สมดุลของข้อมูล (Imbalanced Data) โดยปัญหาดังกล่าวอาจส่งผลให้แบบจำลองมีอคติในการเรียนรู้ไปยังกลุ่มข้อมูลที่มีจำนวนมากกว่า และลดความสามารถในการจำแนกกลุ่มข้อมูลส่วนน้อยได้อย่างถูกต้อง ดังนั้น เพื่อบรรเทาผลกระทบจากความไม่สมดุลของข้อมูลเพื่อแก้ไขปัญหาดังกล่าว ผู้วิจัยจึงประยุกต์ใช้เทคนิคการปรับสมดุลข้อมูล (Resampling Techniques) จำนวน 3 วิธี ได้แก่

1. การสุ่มซ้ำข้อมูล (Random Oversampling: ROS)
2. เทคนิคการเพิ่มจำนวนข้อมูลส่วนน้อยแบบสังเคราะห์ SMOTE (Synthetic Minority Over-sampling Technique)

3. การสร้างภาพสังเคราะห์ด้วยเทคนิค GANs (Generative Adversarial Networks)

การเลือกใช้เทคนิคทั้งสามวิธีนี้มีวัตถุประสงค์เพื่อเปรียบเทียบผลกระทบของแนวทางการปรับสมดุลข้อมูลที่แตกต่างกันต่อประสิทธิภาพและความเสถียรของแบบจำลอง โดย ROS เป็นเทคนิคพื้นฐานที่ช่วยปรับสมดุลจำนวนข้อมูลโดยไม่เปลี่ยนแปลงลักษณะเชิงเนื้อหาของข้อมูล SMOTE เป็นเทคนิคที่สร้างข้อมูลสังเคราะห์ใหม่ในเชิงคุณลักษณะเพื่อเพิ่มความหลากหลายของข้อมูลส่วนน้อย ขณะที่ GANs เป็นเทคนิคเชิงลึกที่สามารถสร้างภาพสังเคราะห์ที่มีความสมจริงและมีโครงสร้างเชิงภาพที่ซับซ้อน ซึ่งเหมาะสมกับงานจำแนกภาพทางผิวหนัง นอกจากนี้ เพื่อศึกษาผลกระทบของอัตราการเพิ่มจำนวนข้อมูล (Resampling Rate) ต่อประสิทธิภาพของแบบจำลอง ผู้วิจัยได้กำหนดจำนวนข้อมูลในแต่ละระดับความรุนแรงของผิวหนังให้เหมือนกันที่ 155, 300 และ 500 ภาพต่อคลาส โดยจำนวน 155 ภาพต่อคลาสสะท้อนการปรับสมดุลขั้นต่ำจากข้อมูลจริง ขณะที่จำนวน 300 และ 500 ภาพต่อคลาสใช้เพื่อประเมินผลของการเพิ่มปริมาณข้อมูลในระดับที่สูงขึ้นต่อความสามารถในการเรียนรู้และการทั่วไปของแบบจำลอง ทั้งนี้ การกำหนดระดับจำนวนข้อมูลหลายค่า ช่วยให้สามารถวิเคราะห์แนวโน้มของประสิทธิภาพแบบจำลองเมื่อปริมาณข้อมูลเพิ่มขึ้นอย่างเป็นระบบ ในการทดลองทั้งหมด ใช้แบบจำลอง ResNet50 ร่วมกับตัวแก้ปัญหาค่า Adam (Solver: Adam) โดยกำหนดอัตราการเรียนรู้ (Learning Rate) เท่ากับ 0.001 และขนาดแบตช์ (Batch Size) เท่ากับ 128 เป็นพารามิเตอร์หลัก เพื่อควบคุมตัวแปรด้านโครงสร้างและกระบวนการฝึกให้คงที่ ทำให้สามารถเปรียบเทียบประสิทธิภาพของเทคนิคการปรับสมดุลข้อมูลแต่ละวิธีได้อย่างเป็นธรรมและเป็นระบบ

4.4.1 Random Oversampling (ROS)

การสุ่มซ้ำข้อมูล (ROS) โดยเพิ่มจำนวนภาพในแต่ละระดับความรุนแรงของผิวหนังให้เท่ากันที่จำนวนต่อระดับความรุนแรง คือ 155, 300 และ 500 ภาพ เพื่อศึกษาผลของการเพิ่มปริมาณข้อมูลต่อความสามารถของแบบจำลองในการเรียนรู้และจำแนกภาพ ผลลัพธ์แตกต่างกันตามจำนวนข้อมูลที่ใส่ซ้ำในแต่ละระดับความรุนแรง

ตารางที่ 4.6 การเปรียบเทียบค่าเฉลี่ยประสิทธิภาพของแบบจำลองภายใต้จำนวนข้อมูลที่ได้จากการสุ่มซ้ำ ROS

จำนวนข้อมูลหลัง ROS (ภาพต่อระดับความรุนแรง)	TestAcc (%)	Class	Precision	Recall	F1-score	Specificity
155	44.32	1	0.42	0.47	0.44	0.76
		2	0.23	0.11	0.15	0.83
		3	0.51	0.64	0.56	0.51
		AVG	0.39	0.41	0.38	0.70
300	43.18	1	0.2	0.13	0.15	0.81
		2	0.34	0.46	0.39	0.62
		3	0.6	0.58	0.59	0.69
		AVG	0.38	0.39	0.38	0.71
500	38.64	1	0.25	0.3	0.28	0.69
		2	0.26	0.23	0.24	0.72
		3	0.55	0.53	0.54	0.65
		AVG	0.35	0.35	0.35	0.69

จากตารางที่ 4.6 พบว่า การเพิ่มข้อมูลด้วยวิธี ROS สามารถช่วยปรับสมดุลของชุดข้อมูลในแต่ละระดับความรุนแรงต่าง ๆ ได้บางส่วน แต่ไม่ได้ทำให้ประสิทธิภาพของแบบจำลองเพิ่มขึ้นอย่างต่อเนื่อง โดยค่าความถูกต้องสูงสุด (Test Accuracy) อยู่ที่ 44.32% เมื่อใช้จำนวนข้อมูล 155 ภาพต่อระดับความรุนแรง ซึ่งให้ค่าเฉลี่ย Precision 0.39, Recall 0.41, F1-score 0.38, และ Specificity 0.70 สูงกว่าชุดข้อมูลที่มีการเพิ่มจำนวนที่มากกว่านี้ แสดงให้เห็นว่าการเพิ่มข้อมูลมากเกินไปอาจทำให้โมเดลได้รับตัวอย่างที่ซ้ำซ้อนจนสูญเสียความหลากหลายของข้อมูล ส่งผลให้ความสามารถในการเรียนรู้คุณลักษณะใหม่ลดลง

เมื่อพิจารณาผลรายคลาสพบว่า ในระดับข้อมูล 155 ภาพต่อคลาส โมเดลสามารถจำแนกระดับความรุนแรงที่ 3 ได้ดีที่สุด โดยมีค่า Precision = 0.51, Recall = 0.64 และ F1-score = 0.56 แสดงถึงความแม่นยำและการตอบสนองที่ดี ซึ่งช่วยให้โมเดลสามารถเรียนรู้คุณลักษณะได้ชัดเจนกว่าระดับความรุนแรงอื่น ขณะที่ระดับความรุนแรงที่ 1 มีค่า Precision = 0.42 และ Recall = 0.47 แสดงถึงการเรียนรู้ที่สมดุลในระดับปานกลาง ส่วน ระดับความรุนแรงที่ 2 ให้ค่า Precision และ Recall ต่ำที่สุด (0.23 และ 0.11) เนื่องจากภาพสักระดับนี้มีลักษณะคล้ายกัน ในระดับความรุนแรงที่ 1 และระดับความรุนแรงที่ 2 ทำให้เกิดการจำแนกผิดได้ง่าย ซึ่งสอดคล้องกับลักษณะของข้อมูลจริงที่ขอบเขตของสักระดับความรุนแรงที่ 2 มักไม่ชัดเจน เมื่อเพิ่มจำนวนข้อมูลเป็น 300 ภาพต่อระดับ

ความรุนแรง พบว่า Test Accuracy ลดลงเล็กน้อยเป็น 43.18% แม้ระดับความรุนแรงที่ 3 ยังคงให้ค่า F1-score สูงสุด (0.59) แต่ค่า Precision และ Recall ของระดับความรุนแรงที่ 1–2 ไม่เพิ่มขึ้น แสดงว่าการเพิ่มข้อมูลไม่ได้ช่วยปรับปรุงความสามารถของโมเดลในกลุ่มที่มีความใกล้เคียงทางลักษณะภาพมากนัก และมีแนวโน้มเกิด Overfitting ในขั้นตอนการฝึก ในกรณีที่เพิ่มข้อมูลสูงสุดเป็น 500 ภาพต่อระดับความรุนแรง พบว่าผลการจำแนกตกลงอย่างชัดเจน โดยมีค่าเฉลี่ย Precision, Recall และ F1-score เท่ากันที่ 0.35 และ Specificity 0.69 ซึ่งลดลงจากระดับก่อนหน้าอย่างต่อเนื่อง สาเหตุอาจมาจากการที่ข้อมูลถูกทำซ้ำมากเกินไปจนแบบจำลองเรียนรู้ลักษณะภาพเดิมซ้ำ ๆ ผลการทดลองนี้สอดคล้องกับแนวคิดของ (Buda et al., 2018) ที่ระบุว่า แม้เทคนิค Oversampling จะสามารถช่วยลดความไม่สมดุลของข้อมูล (Class Imbalance) ได้ แต่การเพิ่มจำนวนตัวอย่างซ้ำมากเกินไปจะก่อให้เกิดการเรียนรู้ซ้ำ (Redundant Learning) และความสามารถในการจำแนกของแบบจำลองในข้อมูลทดสอบจริงลดลง

การเพิ่มจำนวนข้อมูลด้วยเทคนิค ROS มีส่วนช่วยในการลดอคติของคลาส (Class Imbalance) และปรับสมดุลของข้อมูลระหว่างระดับความรุนแรงของสิวได้ในระดับหนึ่ง แต่ไม่สามารถเพิ่มประสิทธิภาพของแบบจำลองได้อย่างต่อเนื่อง ผลการทดลองชี้ชัดว่า การสุ่มซ้ำที่ 155 ภาพต่อระดับความรุนแรง ให้ผลลัพธ์โดยรวมดี ทั้งในแง่ความถูกต้อง ความสมดุลของค่า Precision-Recall และความสามารถของโมเดลในการจำแนกสิวแต่ละระดับได้อย่างมีประสิทธิภาพภายใต้การตั้งค่าพารามิเตอร์เดียวกัน จึงถือเป็นจำนวนข้อมูลที่เหมาะสมที่สุดสำหรับการฝึกแบบจำลอง ResNet50 ในงานวิจัยนี้

4.4.2 Synthetic Minority Over-sampling Technique (SMOTE)

เทคนิคการเพิ่มจำนวนข้อมูลส่วนน้อยแบบสังเคราะห์ (SMOTE) ซึ่งเป็นกระบวนการสร้างตัวอย่างข้อมูลใหม่โดยการคำนวณเชิงเส้นระหว่างตัวอย่างที่มีจำนวนน้อย เพื่อช่วยลดปัญหาความไม่สมดุลของข้อมูล (Class Imbalance) และเพิ่มความสามารถในการเรียนรู้ของแบบจำลองให้ครอบคลุมลักษณะข้อมูลมากยิ่งขึ้น โดยกำหนดค่า K-NN ($k = 5$)

ตารางที่ 4.7 ผลการเปรียบเทียบค่าเฉลี่ยประสิทธิภาพของแบบจำลองภายใต้จำนวนข้อมูลที่สร้างด้วยเทคนิค SMOTE

จำนวนข้อมูลหลัง SMOTE (ภาพต่อระดับรุนแรง)	TestAcc (%)	Class	Precision	Recall	F1-score	Specificity
155	37.5	1	0.33	0.1	0.16	0.92
		2	0.26	0.19	0.22	0.78
		3	0.38	0.61	0.46	0.22
		AVG	0.32	0.30	0.28	0.64

ตารางที่ 4.7 (ต่อ)

จำนวนข้อมูลหลัง SMOTE (ภาพต่อระดับความรุนแรง)	TestAcc (%)	Class	Precision	Recall	F1-score	Specificity
300	52.27	1	0.4	0.43	0.41	0.76
		2	0.6	0.23	0.33	0.93
		3	0.56	0.76	0.65	0.53
		AVG	0.52	0.47	0.46	0.74
500	42.05	1	0.2	0.1	0.1	0.84
		2	0.4	0.09	0.15	0.94
		3	0.39	0.7	0.5	0.15
		AVG	0.33	0.30	0.25	0.64

จากผลการทดลองที่แสดงในตาราง 4.7 พบว่าผลการเปรียบเทียบค่าเฉลี่ยประสิทธิภาพของแบบจำลองภายใต้จำนวนข้อมูลที่สร้างด้วยเทคนิค SMOTE โดยเพิ่มจำนวนภาพสังเคราะห์ในแต่ละระดับความรุนแรงของสิวให้เท่ากันดังที่ได้กล่าวไว้แล้วข้างต้น จากผลการทดลองพบว่า การใช้ SMOTE มีผลต่อประสิทธิภาพของแบบจำลองแตกต่างกันตามจำนวนข้อมูลที่สร้างขึ้น โดยจำนวนข้อมูลในระดับ 300 ภาพต่อระดับความรุนแรง ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า Test Accuracy = 52.27%, Precision เฉลี่ย 0.52, Recall 0.47, F1-score 0.46 และ Specificity 0.74 ซึ่งสะท้อนว่าแบบจำลองสามารถจำแนกระดับความรุนแรงของสิวได้แม่นยำและมีความสมดุลระหว่างความถูกต้อง (Precision) และอัตราการตรวจพบตัวอย่างสิวที่เป็นจริงของแบบจำลอง (Recall) ได้อย่างเหมาะสม การเพิ่มข้อมูลในระดับนี้ช่วยให้แบบจำลองสามารถเรียนรู้ลักษณะเฉพาะของสิวในแต่ละระดับความรุนแรงได้ชัดเจนยิ่งขึ้น โดยเฉพาะใน ระดับความรุนแรงที่ 3 ซึ่งให้ค่า Precision = 0.56, Recall = 0.76 และ F1-score = 0.65 สูงกว่าทุกระดับความรุนแรง แสดงถึงความสามารถของโมเดลในการแยกแยะลักษณะสิวที่มีการอักเสบและรอยแดงได้ดี ส่วนระดับความรุนแรงที่ 1 มีค่า Precision = 0.40, Recall = 0.43 และ F1-score = 0.41 ซึ่งอยู่ในระดับสมดุล ขณะที่ ระดับความรุนแรงที่ 2 มีค่า Precision = 0.60 และ Recall = 0.23 ซึ่งแม้จะมีความแม่นยำในการจำแนกบางตัวอย่าง แต่ยังคงมีความคลาดเคลื่อนสูงในการตรวจจับสิว เนื่องจากลักษณะภาพของสิวระดับนี้มีความใกล้เคียงกับระดับความรุนแรงที่ 1 และระดับความรุนแรงที่ 3 ทำให้แบบจำลองมีโอกาสจำแนกผิดพลาดได้บ่อยกว่าในทางกลับกัน เมื่อใช้จำนวนข้อมูลเพียง 155 ภาพต่อระดับความรุนแรง ผลการจำแนกมีความแม่นยำน้อยกว่า โดยมี Test Accuracy = 37.50% และค่าเฉลี่ย F1-score = 0.28 สะท้อนว่าแบบจำลองยังได้รับข้อมูลฝึกที่ไม่เพียงพอ ส่งผลให้การเรียนรู้คุณลักษณะสำคัญของสิวในแต่ละระดับไม่เพียงพอ ขณะที่การเพิ่มข้อมูลมากเกินไปในระดับ 500 ภาพต่อระดับความรุนแรง กลับทำให้ประสิทธิภาพโดยรวมลดลง โดยมี Test Accuracy = 42.05%, Precision = 0.33, Recall = 0.30, F1-score = 0.25, และ Specificity = 0.64 ซึ่งอาจเกิดจากการสร้างข้อมูลสังเคราะห์ซ้ำ ๆ จนขาด

ความหลากหลาย และทำให้โมเดลเกิดการเรียนรู้ลักษณะภาพที่ซ้ำซ้อนหรือไม่สมจริง ผลการทดลองนี้สอดคล้องกับแนวคิดของ (Chawla et al., 2002) ที่ระบุว่า SMOTE สามารถช่วยเพิ่มประสิทธิภาพของโมเดลได้โดยการสร้างตัวอย่างใหม่ในกลุ่มข้อมูลส่วนน้อยผ่านการสังเคราะห์ข้อมูล ทำให้แบบจำลองเรียนรู้ได้สมดุลมากขึ้น แต่หากเพิ่มจำนวนข้อมูลมากเกินไปจะเกิดความซ้ำซ้อนและลดความแม่นยำในการจำแนกข้อมูลจริง อีกทั้งยังสอดคล้องกับแนวคิดของ (He et al., 2016) ที่ชี้ว่าปริมาณข้อมูลสังเคราะห์ที่เหมาะสมเป็นปัจจัยสำคัญในการรักษาความสามารถในการจำแนกข้อมูลโดยทั่วไปของโมเดล

การใช้เทคนิค SMOTE ในระดับ 300 ภาพต่อระดับความรุนแรง ถือเป็นค่าที่เหมาะสมที่สุดในงานวิจัยนี้ เพราะสามารถสร้างสมดุลระหว่างความแม่นยำ ความครอบคลุม และความสามารถในการจำแนกข้อมูลใหม่ได้อย่างมีประสิทธิภาพภายใต้แบบจำลอง ResNet50 ที่ใช้พารามิเตอร์ Learning Rate = 0.001 และ Batch Size = 128

4.4.3 Generative Adversarial Networks (GANs)

ผลการประเมินแบบจำลองภายหลังการสร้างข้อมูลสังเคราะห์ด้วยเทคนิค GANs ซึ่งเป็นกระบวนการสร้างข้อมูลใหม่ที่มีลักษณะใกล้เคียงกับข้อมูลจริง โดยอาศัยการเรียนรู้ระหว่าง Generator และ Discriminator เพื่อเพิ่มความหลากหลายของข้อมูลและลดความไม่สมดุลระหว่างระดับความรุนแรงของข้อมูลสิวในแต่ละระดับความรุนแรง

ตารางที่ 4.8 การเปรียบเทียบค่าเฉลี่ยประสิทธิภาพของแบบจำลองภายใต้จำนวนข้อมูลที่สร้างด้วยเทคนิค GANs

จำนวนข้อมูล GANs (ภาพต่อระดับรุนแรง)	TestAcc (%)	Class	Precision	Recall	F1-score	Specificity
155	52.27	1	0.5	0.347	0.41	0.87
		2	0.33	0.115	0.17	0.9
		3	0.55	0.897	0.686	0.42
		AVG	0.46	0.45	0.42	0.73
300	38.64	1	0.54	0.3	0.39	0.91
		2	0.5	0.3	0.39	0.87
		3	0.61	0.92	0.73	0.53
		AVG	0.55	0.51	0.50	0.77
500	51.13	1	0.7	0.3	0.42	0.95
		2	0.38	0.69	0.49	0.53
		3	0.64	0.51	0.57	0.77
		AVG	0.57	0.50	0.49	0.75

จากผลการทดลองพบว่า การสร้างข้อมูลสังเคราะห์ในระดับที่เหมาะสมช่วยเพิ่มความสามารถของแบบจำลองในการเรียนรู้ได้อย่างมีประสิทธิภาพ โดยเมื่อใช้จำนวนข้อมูล 155 ภาพต่อระดับความรุนแรง แบบจำลองให้ค่า Test Accuracy = 52.27%, Precision เฉลี่ย 0.46, Recall = 0.45, F1-score = 0.42 และ Specificity = 0.73 ซึ่งถือเป็นระดับที่สมดุลระหว่างความแม่นยำและความสามารถในการตรวจจับตัวอย่างที่ถูกต้อง ผลลัพธ์ดังกล่าวแสดงให้เห็นว่า การเพิ่มข้อมูลด้วย GANs ในระดับที่พอดีช่วยให้แบบจำลองเรียนรู้คุณลักษณะของสิวได้อย่างหลากหลาย โดยไม่ทำให้เกิดการซ้ำซ้อนของข้อมูล เมื่อพิจารณาผลแต่ละระดับความรุนแรง พบว่า ระดับความรุนแรงที่ 3 ให้ค่าประสิทธิภาพสูง โดยมี Precision = 0.55, Recall = 0.90 และ F1-score = 0.69 แสดงถึงความสามารถของโมเดลในการตรวจจับสิวที่มีการอักเสบและรอยแดงได้ ขณะที่ระดับความรุนแรงที่ 1 มีค่า Precision = 0.50 และ Recall = 0.35 ซึ่งสะท้อนให้เห็นว่าแบบจำลองสามารถทำนายตัวอย่างในระดับความรุนแรงดังกล่าวได้ถูกต้องในสัดส่วนปานกลาง อย่างไรก็ตาม ค่า Recall ที่ค่อนข้างต่ำบ่งชี้ว่ายังมีตัวอย่างสิวในระดับความรุนแรงที่ 1 ถูกตรวจไม่พบอยู่ในสัดส่วนที่สูง ส่งผลให้ประสิทธิภาพในการตรวจจับตัวอย่างที่เป็นจริงยังมีข้อจำกัด ส่วน ระดับความรุนแรงที่ 2 มี Precision = 0.33 และ Recall = 0.12 ซึ่งต่ำกว่าคลาสอื่นเนื่องจากลักษณะภาพมีความใกล้เคียงกับสิวระดับความรุนแรงที่ 3 ส่งผลให้โมเดลจำแนกผิดได้บ้าง เมื่อใช้จำนวนข้อมูล 300 ภาพต่อระดับความรุนแรง แบบจำลองให้ค่า Recall = 0.51 แสดงถึงความสามารถในการตรวจจับตัวอย่างสิวที่เป็นจริงได้ครอบคลุมมากขึ้น อย่างไรก็ตาม ค่า Test Accuracy ลดลงเหลือ 38.64% และ F1-score = 0.50 สะท้อนถึงความสามารถในการตรวจจับและความแม่นยำในการจำแนก โดยการเพิ่มข้อมูลสังเคราะห์ในระดับนี้ช่วยลดการพลาดการตรวจพบตัวอย่างสิว แต่เพิ่มความคลาดเคลื่อนในการจำแนกระดับความรุนแรง เมื่อพิจารณารายระดับความรุนแรง พบว่า ระดับความรุนแรงที่ 3 มีค่า Recall สูง แสดงถึงความสามารถในการตรวจจับสิวที่มีการอักเสบชัดเจนได้ดี ขณะที่ ระดับความรุนแรงที่ 1 มีค่า Recall เพิ่มขึ้นแต่ Precision ลดลง สะท้อนแนวโน้มการทำนายเกินจริง ส่วน ระดับความรุนแรงที่ 2 มีค่า Precision และ Recall ต่ำ เนื่องจากลักษณะภาพมีความใกล้เคียงกับคลาสอื่น ส่งผลให้เกิดความสับสนในการจำแนก สำหรับกรณี 500 ภาพต่อระดับความรุนแรง พบว่าค่า Precision = 0.57 และ Specificity = 0.75 แสดงถึงความสามารถในการหลีกเลี่ยงการทำนายผิดได้ดีขึ้น อย่างไรก็ตาม ค่า Test Accuracy (51.13%) และ F1-score = 0.49 ไม่เพิ่มขึ้นอย่างชัดเจน เมื่อพิจารณารายแต่ละระดับความรุนแรงพบว่าแบบจำลองสามารถจำแนกระดับความรุนแรงที่มีลักษณะชัดเจนได้แม่นยำขึ้น แต่มีแนวโน้มพลาดการตรวจจับคลาสที่มีลักษณะกำกวม ส่งผลให้ Precision และ Recall และไม่สามารถเพิ่มประสิทธิภาพโดยรวมของแบบจำลองได้อย่างต่อเนื่อง

ผลการทดลองนี้สอดคล้องกับแนวคิดของ Goodfellow et al. (2014) ซึ่งระบุว่า ประสิทธิภาพของการสร้างข้อมูลด้วย GANs ขึ้นอยู่กับคุณภาพ ความสมดุล และความสมจริงของภาพที่สร้าง มากกว่า

ปริมาณเพียงอย่างเดียว การเพิ่มข้อมูลโดยไม่คำนึงถึงความหลากหลายอาจทำให้แบบจำลองเรียนรู้ลักษณะเทียมเกินจริง ส่งผลให้ความสามารถในการนำไปใช้กับข้อมูลใหม่ลดลง นอกจากนี้ยังสอดคล้องกับผลงานของ Frid-Adar et al. (2018) ที่ใช้ GANs สร้างภาพเอกซเรย์ระดับและพบว่า การสร้างข้อมูลในปริมาณเหมาะสมช่วยเพิ่มความแม่นยำของโมเดล CNN ได้อย่างมีนัยสำคัญ รวมถึง Zhao et al. (2020) ซึ่งรายงานว่าคุณภาพของภาพสังเคราะห์ที่สมจริงสามารถช่วยให้โมเดลเรียนรู้ลักษณะโรคผิวหนังได้ใกล้เคียงกับข้อมูลจริงมากขึ้น

การสร้างข้อมูลด้วย GANs ในระดับ 155 ภาพต่อระดับความรุนแรง ให้ผลลัพธ์ดีขึ้นกว่าเมื่อเทียบกับการสร้างข้อมูลด้วย GANs ในระดับอื่น ทุกตัวชี้วัดทั้ง Test Accuracy, Precision, Recall และ F1-score สะท้อนว่า การใช้ข้อมูลสังเคราะห์ในปริมาณที่เหมาะสมสามารถเพิ่มความสามารถของแบบจำลองในการจำแนกสิวได้อย่างมีประสิทธิภาพ โดยเฉพาะในสถานะที่ข้อมูลจริงมีจำกัด ผลลัพธ์นี้แสดงให้เห็นถึงศักยภาพของ GANs ในการจำลองข้อมูลที่มีความสมจริงสูงและช่วยปรับปรุงความสมดุลของชุดข้อมูลได้ดีกว่าเทคนิค ROS และ SMOTE ที่เน้นการทำซ้ำเชิงปริมาณมากกว่าคุณภาพของภาพสังเคราะห์

4.4.4 การเปรียบเทียบผลการปรับสมดุลข้อมูลด้วยเทคนิค ROS, SMOTE, GANs

การเปรียบเทียบประสิทธิภาพของแบบจำลองภายหลังการปรับสมดุลข้อมูลด้วยเทคนิค ROS, SMOTE และ GANs โดยเลือกจากผลของแต่ละเทคนิคที่มีประสิทธิภาพในการเรียนรู้ชุดข้อมูลมาเปรียบเทียบกัน ซึ่งจำนวนข้อมูลที่ผ่านการคัดเลือกและการปรับสมดุลข้อมูลแล้ว

ตารางที่ 4.9 การเปรียบเทียบผลการปรับสมดุลข้อมูลของทั้ง 3 เทคนิค

Resampling Techniques	TestAcc (%)	Class	Precision	Recall	F1-score	Specificity
ROS	44.32	1	0.42	0.47	0.44	0.76
		2	0.23	0.11	0.15	0.83
		3	0.51	0.64	0.56	0.51
		AVG	0.39	0.41	0.38	0.70
		SMOTE	52.27	1	0.4	0.43
2	0.6	0.23		0.33	0.93	
3	0.56	0.76		0.65	0.53	
AVG	0.52	0.47		0.46	0.74	
GANs	51.13	1		0.7	0.3	0.42
		2	0.38	0.69	0.49	0.53
		3	0.64	0.51	0.57	0.77
		AVG	0.57	0.50	0.49	0.75

การเปรียบเทียบประสิทธิภาพของ Resampling Techniques 3 วิธี ได้แก่ ROS, SMOTE และ GANs โดยใช้แบบจำลอง ResNet50 ภายใต้พารามิเตอร์ Learning Rate = 0.001 และ Batch Size = 128 จากผลการทดลองตารางที่ 4.9 พบว่า GANs ให้ผลลัพธ์ที่ดีที่สุดในภาพรวม โดยมีค่า Test Accuracy = 51.13%, Precision = 0.57, Recall = 0.50, F1-score = 0.49, และ Specificity = 0.75 ซึ่งสูงที่สุดในทุกตัวชี้วัด แสดงให้เห็นว่าเทคนิค GANs ให้ประสิทธิภาพโดยรวมใกล้เคียงกับ SMOTE โดยมีค่า Test Accuracy ใกล้เคียงกัน (51.13% และ 52.27%) อย่างไรก็ตาม GANs ให้ค่า Precision เฉลี่ยสูงที่สุด (0.57) สะท้อนถึงความแม่นยำในการทำนายเชิงบวกที่ดีกว่า แม้ค่า Recall และ F1-score จะเพิ่มขึ้นไม่มากนัก แสดงถึงข้อจำกัดด้านความครอบคลุมของการตรวจจับ เมื่อพิจารณารายระดับความรุนแรง พบว่า ระดับความรุนแรงที่ 3 ให้ผลลัพธ์ที่ดีภายใต้ GANs โดยมีค่า Precision, Recall และ F1-score อยู่ในระดับสมดุล (0.64, 0.51 และ 0.57) แสดงถึงประสิทธิภาพในการเรียนรู้จากข้อมูลสังเคราะห์ในกลุ่มที่มีลักษณะทางภาพชัดเจน ขณะที่ ระดับความรุนแรงที่ 1 มี Precision สูงแต่ Recall ต่ำ สะท้อนการทำนายที่แม่นยำแต่ไม่ครอบคลุม ส่วน ระดับความรุนแรงที่ 2 มี Recall สูงแต่ Precision ต่ำ บ่งชี้ถึงการทำนายเกินจากความทับซ้อนของลักษณะทางภาพระหว่างคลาส เมื่อเปรียบเทียบกับ SMOTE พบว่า SMOTE ให้ค่า Recall ในระดับความรุนแรงที่ 3 สูงกว่า แต่ Precision ต่ำกว่า GANs เล็กน้อย สะท้อนว่า SMOTE ช่วยเพิ่มความครอบคลุมได้ดี แต่ไม่สามารถคงโครงสร้างเชิงพื้นที่ของข้อมูลภาพได้เทียบเท่า GANs ผลลัพธ์นี้สอดคล้องกับแนวคิดของ Goodfellow et al. (2014) และ Frid-Adar et al. (2018) ที่ชี้ว่าความสมจริงของข้อมูลสังเคราะห์จาก GANs มีบทบาทสำคัญต่อประสิทธิภาพของแบบจำลอง อย่างไรก็ตาม ผลการทดลองยังชี้ให้เห็นข้อจำกัดของ GANs ในคลาสที่มีลักษณะกำกวม ซึ่งอาจต้องอาศัยการออกแบบของโครงสร้างโมเดลหรือเทคนิคเสริมเพื่อเพิ่มสมดุลระหว่าง Precision และ Recall ในภาพรวม

เทคนิค SMOTE ให้ประสิทธิภาพโดยรวมเป็นรองจาก GANs เล็กน้อย โดยมีค่า Test Accuracy = 52.27%, Precision เฉลี่ย = 0.52, Recall = 0.47, F1-score = 0.46 และ Specificity = 0.74 แม้ค่า Test Accuracy จะสูงกว่า GANs เล็กน้อย แต่ค่า Precision เฉลี่ยและ F1-score ต่ำกว่า สะท้อนว่า SMOTE ให้ความสมดุลของประสิทธิภาพโดยรวมรองจาก GANs โดยเฉพาะในด้านความแม่นยำของการทำนายเชิงบวก เมื่อพิจารณาเชิงรายระดับความรุนแรง พบว่า ระดับความรุนแรงที่ 3 ภายใต้ SMOTE มีค่า Recall สูง (0.76) และ F1-score สูงที่สุดในกลุ่ม SMOTE (0.65) แสดงถึงความสามารถในการตรวจจับสัญญาณได้ครอบคลุม อย่างไรก็ตาม ค่า Precision (0.56) ยังต่ำกว่า GANs เล็กน้อย สะท้อนแนวโน้มการตรวจจับได้มากขึ้นแต่ยังมีการทำนายเกินบางส่วน สำหรับ ระดับความรุนแรงที่ 2 แม้ Precision จะอยู่ในระดับค่อนข้างสูง (0.60) แต่ Recall ต่ำ (0.23) แสดงถึงข้อจำกัดในการเรียนรู้ของข้อมูลที่มีลักษณะทับซ้อน ขณะที่ ระดับความรุนแรงที่ 1 ให้ผลลัพธ์อยู่ในระดับปานกลางและค่อนข้างสมดุล ผลลัพธ์ดังกล่าวชี้ให้เห็นว่า

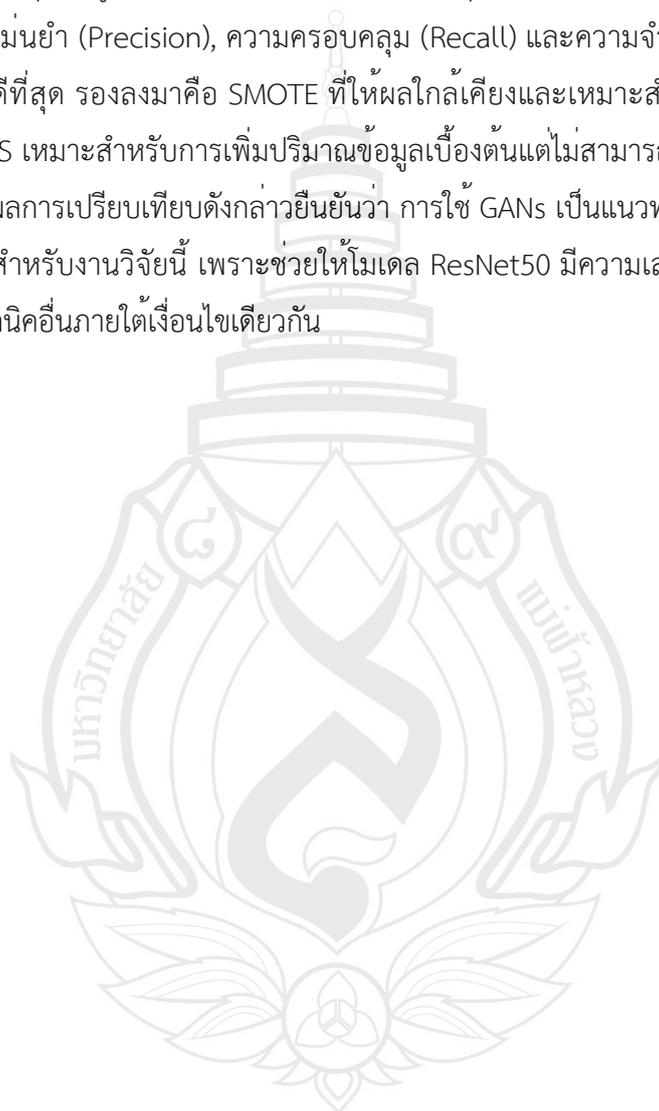
SMOTE สามารถเพิ่มความครอบคลุมของการตรวจจับได้ดีในบางระดับความรุนแรง แต่ยังไม่สามารถรักษาความแม่นยำของการทำนายในทุกระดับได้เทียบเท่า GANs สาเหตุสำคัญมาจากกลไกของ SMOTE ที่สร้างข้อมูลสังเคราะห์ที่ใน feature space แบบเชิงเส้น ซึ่งช่วยลดปัญหาความไม่สมดุลของข้อมูลได้ดี แต่ไม่สามารถสะท้อนโครงสร้างเชิงพื้นที่และรายละเอียดทางภาพของสปีวได้โดยตรง แตกต่างจาก GANs ที่เรียนรู้การกระจายของข้อมูลภาพในระดับพิกเซล ทำให้ข้อมูลสังเคราะห์มีความสมจริงมากกว่าและส่งผลกระทบต่อ Precision โดยรวมที่สูงกว่า อย่างไรก็ตาม ผลของ SMOTE ยังสอดคล้องกับแนวคิดของ Chawla et al. (2002) ที่ระบุว่า SMOTE สามารถลดอคติจาก class imbalance และช่วยให้แบบจำลองเรียนรู้ข้อมูลส่วนน้อยได้ดีขึ้น แม้ประสิทธิภาพโดยรวมจะเป็นรองจาก GANs ในงานที่อาศัยลักษณะทางภาพสูง

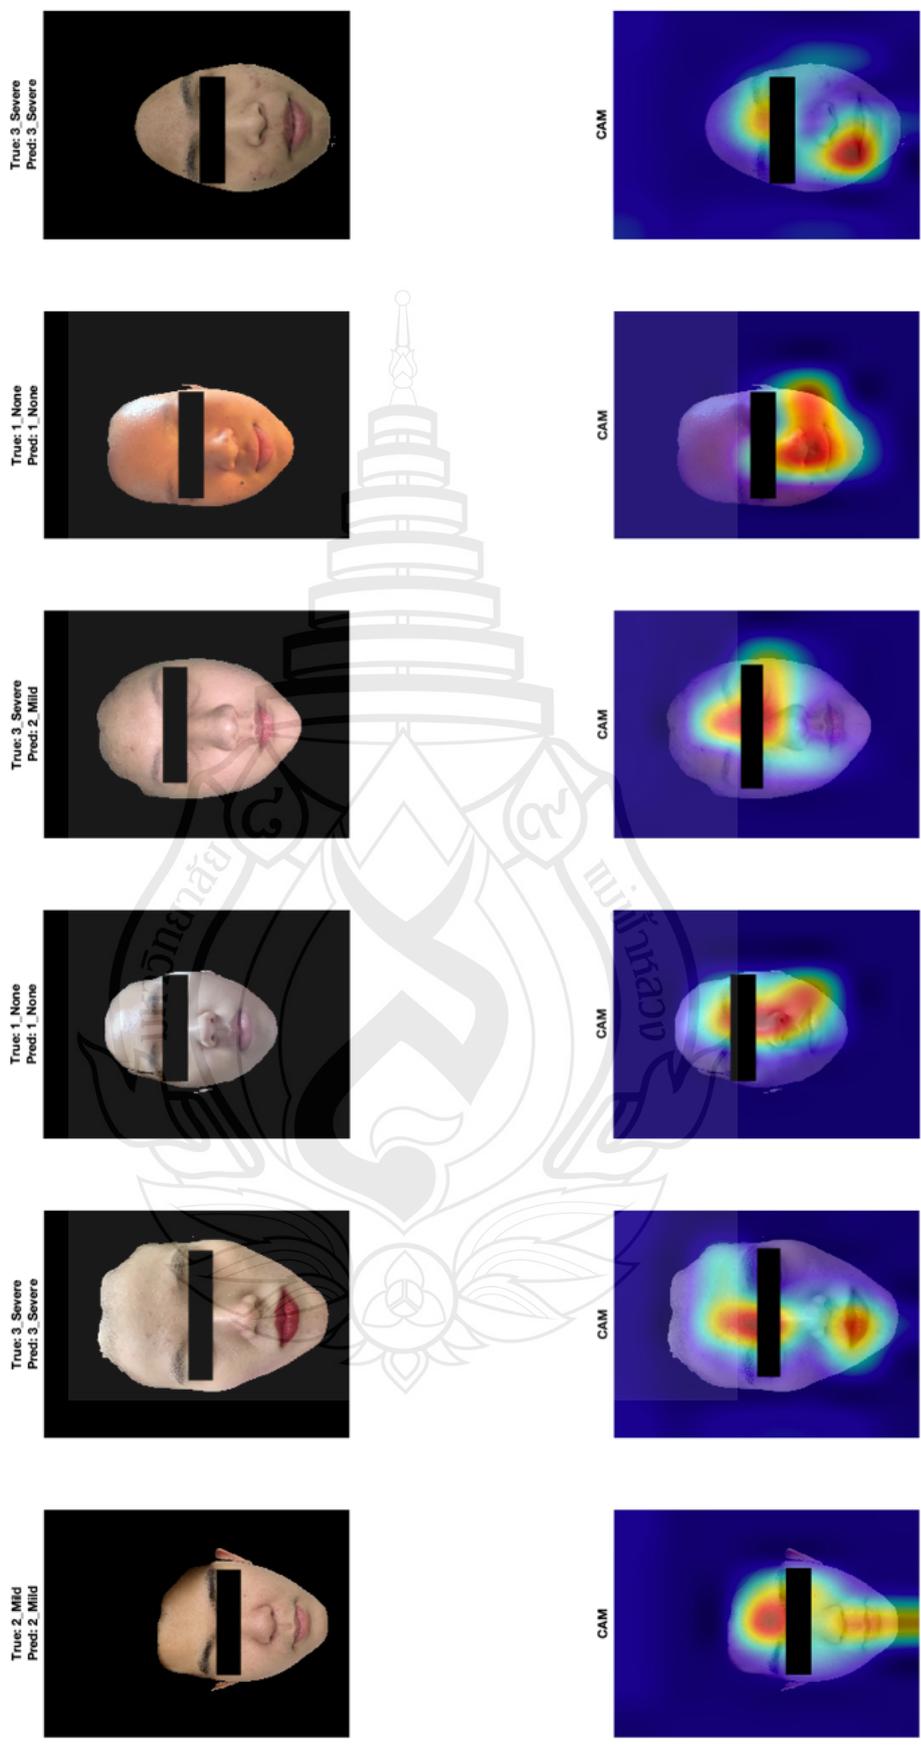
จากตารางผลการทดลองพบว่า ROS ให้ประสิทธิภาพต่ำที่สุดเมื่อเทียบกับ SMOTE และ GANs โดยมีค่า Test Accuracy = 44.32%, Precision เฉลี่ย = 0.39, Recall = 0.41, F1-score = 0.38 และ Specificity = 0.70 แม้ ROS จะช่วยปรับจำนวนตัวอย่างในแต่ละระดับความรุนแรงให้มีความสมดุลมากขึ้น แต่เนื่องจากการเพิ่มข้อมูลด้วยการทำซ้ำตัวอย่างเดิมโดยตรง จึงไม่สามารถเพิ่มความหลากหลายของข้อมูลเชิงภาพได้อย่างแท้จริง เมื่อพิจารณาเชิงรายระดับความรุนแรง พบว่าระดับความรุนแรงที่ 2 ให้ผลลัพธ์ต่ำที่สุด โดยมีค่า Precision = 0.23 และ Recall = 0.11 สะท้อนว่าแบบจำลองไม่สามารถเรียนรู้ลักษณะจำเพาะของสปีวระดับกลางได้อย่างมีประสิทธิภาพ ซึ่งอาจเกิดจากลักษณะของสปีวระดับนี้มีความทับซ้อนกับทั้งระดับเริ่มต้นและระดับรุนแรง ทำให้การทำซ้ำข้อมูลเดิมไม่ช่วยขยายขอบเขตการเรียนรู้ของแบบจำลอง ในขณะที่ ระดับความรุนแรงที่ 3 แม้จะมี Recall ค่อนข้างสูง (0.64) แต่ Precision อยู่ในระดับปานกลาง (0.51) บ่งชี้ถึงการตรวจจับได้มากขึ้นแต่ยังมีการทำนายผิดพลาด ผลลัพธ์ดังกล่าวสะท้อนว่า ROS มีแนวโน้มทำให้แบบจำลองเกิดการเรียนรู้ซ้ำ (redundant learning) และเพิ่มความเสี่ยงต่อ overfitting เนื่องจากแบบจำลองถูกฝึกด้วยข้อมูลที่มีลักษณะซ้ำกันจำนวนมาก ส่งผลให้ไม่สามารถปรับตัวได้ดีเมื่อทดสอบกับข้อมูลใหม่ ผลการทดลองนี้สอดคล้องกับงานของ He & Garcia (2009) ที่ชี้ว่า ROS แม้จะช่วยลดปัญหาความไม่สมดุลของจำนวนข้อมูล แต่ไม่สามารถเพิ่มความสมดุลเชิงเนื้อหาของคุณลักษณะ (feature diversity) ได้จริง โดยเฉพาะในงานที่ต้องอาศัยความแตกต่างเชิงภาพอย่างละเอียด โดยสรุป ROS เหมาะสำหรับเป็นวิธีพื้นฐานเพื่อเปรียบเทียบผลการทดลอง แต่มีข้อจำกัดชัดเจนในการใช้งานกับปัญหาการจำแนกภาพสปีวหลายระดับความรุนแรง ซึ่งจำเป็นต้องใช้เทคนิคการเพิ่มข้อมูลที่สามารถสร้างความหลากหลายของข้อมูลได้มากกว่า เช่น SMOTE หรือ GANs เพื่อยกระดับประสิทธิภาพของแบบจำลองในภาพรวม

เมื่อเปรียบเทียบในแต่ละระดับความรุนแรง พบว่า ระดับความรุนแรงที่ 3 ในทุกเทคนิคให้ค่า F1-score สูงที่สุด โดยเฉพาะในกรณีของ GANs และ SMOTE ที่สามารถรักษาสมดุลของ Precision-Recall ได้ดีกว่าระดับความรุนแรงอื่น สะท้อนว่าข้อมูลสปีวรุนแรงมีลักษณะเด่นชัดกว่าและส่งผลให้

โมเดลสามารถเรียนรู้ได้แม่นยำกว่า ในทางกลับกัน ระดับความรุนแรงที่ 2 มีค่าตัวชี้วัดต่ำสุดในทุกเทคนิค เนื่องจากมีความใกล้เคียงกับทั้งสปีวเล็กน้อยและสปีวรุนแรง ซึ่งทำให้เกิดการจำแนกผิดพลาดได้ง่าย

การทดลองแสดงให้เห็นว่า GANs Test Accuracy = 51.13% เป็นเทคนิคที่มีประสิทธิภาพสูง ในการปรับสมดุลข้อมูลสำหรับการจำแนกระดับความรุนแรงของสปีว เนื่องจากสามารถสร้างสมดุลระหว่างความแม่นยำ (Precision), ความครอบคลุม (Recall) และความจำเพาะ (Specificity) ของแบบจำลองได้ดีที่สุด รองลงมาคือ SMOTE ที่ให้ผลใกล้เคียงและเหมาะสมสำหรับกรณีที่มีข้อมูลจริงมีจำกัด ส่วน ROS เหมาะสำหรับการเพิ่มปริมาณข้อมูลเบื้องต้นแต่ไม่สามารถเพิ่มความหลากหลายได้อย่างเพียงพอ ผลการเปรียบเทียบดังกล่าวยืนยันว่า การใช้ GANs เป็นแนวทางการปรับสมดุลข้อมูลที่เหมาะสมที่สุดสำหรับงานวิจัยนี้ เพราะช่วยให้โมเดล ResNet50 มีความเสถียรและความสามารถที่ดีกว่าการใช้เทคนิคอื่นภายใต้เงื่อนไขเดียวกัน





ภาพที่ 4.3 การวิเคราะห์พื้นที่สนใจของแบบจำลองด้วยเทคนิค Grad-CAM (Gradient-weighted Class Activation Mapping)

4.4.5 การอธิบายกระบวนการเรียนรู้ของแบบจำลองด้วยเทคนิค Grad-CAM

ผลการทำ Grad-CAM แสดงในภาพที่ 4.3 การวิเคราะห์พื้นที่ที่สนใจของแบบจำลองด้วยเทคนิค ช่วยเปิดเผยกระบวนการเรียนรู้ภายในของแบบจำลองการเรียนรู้เชิงลึกในเชิงพื้นที่ (spatial learning) ได้อย่างชัดเจน ซึ่งเป็นประเด็นสำคัญต่อการเพิ่มความโปร่งใส (transparency) และความสามารถในการอธิบายผลลัพธ์ของแบบจำลองที่มีโครงสร้างซับซ้อน เช่น Convolutional Neural Network (CNN) โดยแผนที่ความร้อนที่ได้สะท้อนให้เห็นว่าการตัดสินใจของแบบจำลองไม่ได้เกิดจากการพิจารณาภาพใบหน้าในลักษณะภาพรวมทั้งหมด แต่เป็นการให้น้ำหนักกับตำแหน่งเฉพาะที่มีความเกี่ยวข้องกับลักษณะของสิวโดยตรง เมื่อพิจารณาความสอดคล้องระหว่างพื้นที่ที่แบบจำลองให้ความสำคัญและตำแหน่งของสิวจริงบนใบหน้า พบว่าแบบจำลองสามารถเรียนรู้ลักษณะเชิงตำแหน่ง (local discriminative features) ได้อย่างเหมาะสม โดยสีแดงและสีส้มแสดงถึงพื้นที่ที่แบบจำลองให้ความสำคัญสูงสุด ขณะที่สีน้ำเงินและสีเขียวแสดงถึงบริเวณที่แบบจำลองให้ความสำคัญน้อยกว่า ผลการทดลองพบว่า บริเวณที่แบบจำลองให้ความสำคัญสูงสุด สอดคล้องกับตำแหน่งที่พบสิวจริง เช่น บริเวณ แก้ม จมูก และคาง ซึ่งเป็นจุดที่พบสิวอักเสบได้บ่อยในข้อมูลชุดฝึก

ผลลัพธ์ดังกล่าวสนับสนุนแนวคิดของ Selvaraju et al. (2017) ที่ระบุว่า Grad-CAM สามารถใช้เป็นเครื่องมือในการตรวจสอบว่าแบบจำลองใช้คุณลักษณะที่ “มีความหมาย” ต่อคลาสเป้าหมายจริงในการทำนายผลลัพธ์ นอกจากนี้ ความแตกต่างของรูปแบบการกระจายตัวและความเข้มของสีในแต่ละระดับความรุนแรงของสิวยังสะท้อนให้เห็นถึงความสามารถของแบบจำลองในการปรับการให้น้ำหนักของคุณลักษณะตามระดับความรุนแรงของโรค โดยในระดับความรุนแรงที่ 1 แผนที่ Grad-CAM แสดงความเข้มของสีต่ำและกระจายตัวกว้าง ซึ่งบ่งชี้ว่าแบบจำลองสามารถแยกแยะลักษณะของผิวที่มีความผิดปกติหรือไม่หรือไม่มีสิวได้อย่างเหมาะสม ในขณะที่ระดับความรุนแรงที่ 2 และระดับความรุนแรงที่ 3 พบความเข้มของสีสูงและกระจุกตัวในบริเวณที่มีสิวอักเสบชัดเจน สะท้อนถึงการเรียนรู้เชิงลำดับชั้น (hierarchical feature learning) ที่เป็นลักษณะสำคัญของ Deep Learning (Samek et al., 2021) ผลการวิเคราะห์ดังกล่าวยังมีบทบาทสำคัญในการตรวจสอบความถูกต้องของการเรียนรู้ภายในแบบจำลอง (internal validation of learning behavior) เนื่องจากช่วยยืนยันว่าแบบจำลองไม่ได้อาศัยปัจจัยแวดล้อมที่ไม่เกี่ยวข้อง เช่น พื้นหลัง สีผิวโดยรวม หรือสภาพแสงของภาพ เป็นหลักในการจำแนกผลลัพธ์ แต่ให้ความสำคัญกับตำแหน่งของสิวที่มีความหมายเชิงกายภาพและสอดคล้องกับความรู้ทางการแพทย์ ซึ่งสอดคล้องกับแนวคิดของ Explainable Artificial Intelligence (XAI) ที่มุ่งลดความเสี่ยงจากการตัดสินใจที่ผิดพลาดของระบบปัญญาประดิษฐ์ในงานด้านการแพทย์ (Tjoa & Guan, 2020)

บทที่ 5

สรุปผลการศึกษาและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การวิจัยเรื่อง “การพัฒนาระบบจำแนกระดับความรุนแรงของสิวนบนใบหน้าและคำแนะนำผลิตภัณฑ์สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก” มีวัตถุประสงค์ เพื่อพัฒนาโมเดลจำแนกระดับความรุนแรงของสิวนบนใบหน้าโดยใช้เทคนิคการเรียนรู้เชิงลึก และแสดงให้เห็นถึงการประยุกต์ใช้โมเดลดังกล่าวในรูปแบบเว็บแอปพลิเคชัน โดยใช้เทคนิคการเรียนรู้เชิงลึกในการจำแนกระดับความรุนแรงของสิว ซึ่งใช้ภาพถ่ายใบหน้าของอาสาสมัครในการสอนอัลกอริธึม ตามเกณฑ์ของ Investigator’s Global Assessment (IGA) ในการจำแนกระดับความรุนแรงของสิวและข้อมูลภาพถ่ายที่ใช้ในการวิจัยที่ใช้ในการวิจัยได้จากอาสาสมัคร จำนวน 524 คน โดยแบ่งเป็น 3 ระดับของความรุนแรง ได้แก่ ระดับ 1 (Almost clear) ระดับ 2 (Mild) และระดับ 3 (Moderate–Severe) ข้อมูลที่ใช้สำหรับฝึกสอนโมเดลมีทั้งหมด 442 ภาพ ถูกแบ่งออกเป็นชุดฝึกสอน จำนวน 354 ภาพ และชุดทดสอบ จำนวน 88 ภาพ

จากการทดสอบพบว่า การเตรียมข้อมูล (Preprocessing) ภาพใบหน้าก่อนนำเข้าสู่กระบวนการเรียนรู้เชิงลึก เช่น การแยกส่วนของใบหน้า การปรับขนาดภาพ และการเพิ่มข้อมูล ช่วยให้แบบจำลองสามารถจำแนกระดับความรุนแรงของสิวได้ดีขึ้นเมื่อทดสอบกับข้อมูลที่ไม่เคยเห็นมาก่อน โดยค่าความถูกต้องในการทดสอบ (Test Accuracy) เพิ่มขึ้นจาก 28.08% เป็น 37.50% ช่วยลดสิ่งรบกวน และลดปัญหา Overfitting ที่พบในข้อมูลดิบ การปรับพารามิเตอร์ของแบบจำลอง (Hyperparameter Tuning) พบว่า ค่าที่เหมาะสม คือ Batch Size = 128 และ Learning Rate = 0.001 ซึ่งให้ค่า Test Accuracy สูงสุดเท่ากับ 52.27%

แบบจำลอง ResNet50 ให้ประสิทธิภาพที่ดี (Test Accuracy = 48.86%, F1 = 0.45) ในขณะที่อัลกอริธึม Adam ให้ผลดีในกลุ่มตัวอย่าง (Test Accuracy = 52.27%, F1 = 0.43) การตรวจสอบความถูกต้องแบบ 5-Fold Cross Validation ให้ค่าเฉลี่ย Test Accuracy เท่ากับ 51.14% และเทคนิคการปรับสมดุลข้อมูลด้วย GANs ที่ระดับ 500 ภาพต่อระดับความรุนแรง ให้ผลดีกว่าเทคนิคอื่น

ดังนั้นแบบจำลองที่ให้ประสิทธิภาพดีที่สุดในงานวิจัยนี้ คือ ResNet50 ที่ปรับแต่งด้วยพารามิเตอร์ Epochs = 300, Batch Size = 128, Learning Rate = 0.001 และใช้อัลกอริธึม

Adam พร้อมการเตรียมข้อมูลแบบ Preprocessing และปรับสมดุลข้อมูลด้วย GANs ที่ระดับ 500 ภาพต่อระดับความรุนแรง ซึ่งให้ค่าความถูกต้องในการทดสอบที่สูง เท่ากับ 51.13% (Precision = 0.57, Recall = 0.50, F1-score = 0.49 และ Specificity = 0.75) สะท้อนถึงความเสถียรและความสามารถในการจำแนกข้อมูลใหม่ได้ดี ในเชิงรายระดับความรุนแรง สิวระดับความรุนแรงที่ 1 ให้ค่า Precision สูง (0.70) แต่ Recall ต่ำ (0.30) แสดงถึงความแม่นยำในการทำนายแต่ยังตรวจจับได้ไม่ครบถ้วน ขณะที่สิวระดับความรุนแรงที่ 2 มี Recall สูงสุด (0.69) แต่ Precision ต่ำ (0.38) เนื่องจากลักษณะทางภาพทับซ้อนกับระดับอื่น ส่วนสิวระดับความรุนแรงที่ 3 ให้ผลลัพธ์สมดุลที่สุด (Precision = 0.64, Recall = 0.51 และ F1-score = 0.57) เนื่องจากมีลักษณะเด่นชัดมากกว่า โดยภาพรวมผลการทดลองยืนยันว่าการใช้ ResNet50 ที่ปรับแต่งด้วย Epochs = 300, Batch Size = 128, Learning Rate = 0.001 และอัลกอริทึม Adam ร่วมกับ GANs ที่ระดับข้อมูลเหมาะสม ช่วยเพิ่มศักยภาพของการเรียนรู้เชิงลึกในการประเมินระดับความรุนแรงของสิวจากภาพถ่ายใบหน้า และมีแนวโน้มต่อการพัฒนาเพื่อใช้งานจริงในอนาคต

แม้แบบจำลองจะผ่านการปรับสมดุลข้อมูลด้วยเทคนิคต่าง ๆ เช่น ROS, SMOTE และ GANs และมีการปรับพารามิเตอร์เพื่อเพิ่มประสิทธิภาพ แต่ค่า Test Accuracy ยังอยู่ในระดับต่ำ เนื่องจากข้อจำกัดสำคัญของชุดข้อมูล ได้แก่ จำนวนข้อมูลจริงที่ค่อนข้างจำกัด, ความหลากหลายของภาพใบหน้าที่ไม่เพียงพอ และ ระดับความแตกต่างของสิวระหว่างคลาสที่มีความซับซ้อนสูง ทำให้โมเดลเรียนรู้ได้ไม่ครอบคลุมลักษณะปริมูมิของข้อมูลทั้งหมด อีกทั้งข้อมูลบางส่วนมีความคล้ายคลึงกันมาก เช่น ระดับความรุนแรงที่ 1 กับ 2 หรือ ระดับความรุนแรงที่ 2 กับ 3 ส่งผลให้แบบจำลองแยกแยะได้ยาก นอกจากนี้ เทคนิค Oversampling อาจเพิ่มปัญหาการเรียนรู้ซ้ำ (Overfitting) โดยเฉพาะเมื่อข้อมูลสังเคราะห์มีความซ้ำซ้อนหรือไม่สะท้อนลักษณะสิวจริงทั้งหมด ส่งผลให้โมเดลมีประสิทธิภาพดีในชุดฝึกแต่ลดลงเมื่อนำไปทดสอบกับข้อมูลใหม่ สุดท้าย ความแตกต่างด้านแสง สีผิว และมุมภาพของผู้ถ่ายยังเป็นปัจจัยรบกวนที่ทำให้แบบจำลองสูญเสียความสามารถในการ Generalization จึงทำให้ Test Accuracy อยู่ในระดับต่ำกว่าที่คาดหวัง

5.2 ข้อจำกัดของการวิจัย

การวิจัยครั้งนี้มีข้อจำกัดบางประการที่อาจส่งผลต่อความแม่นยำและความสามารถทั่วไปของผลการศึกษา ดังนี้

เนื่องจากมีข้อมูลภาพถ่ายที่เป็นหน้าตรง จำนวนเพียง 442 ภาพที่ถูกใช้ในการฝึกสอนโมเดล ซึ่งรูปภาพที่ถูกตัดออกทั้งหมด 1,130 ภาพ โดยข้อมูลที่ถูกตัดออกนี้มี หน้าตรง ด้านซ้าย ด้านขวา

ภาพที่เห็นใบหน้าไม่ชัดเจนและจำนวนข้อมูลที่ถูกจำแนกเป็น ระดับความรุนแรง 0 (Grade 0 = ผิวใส/ไม่มีผิว) ซึ่งข้อมูลที่ผู้ใช้สอนโมเดลอาจยังไม่เพียงพอต่อการเรียนรู้ของแบบจำลองเชิงลึกที่ต้องการข้อมูลจำนวนมากเพื่อให้สามารถจับลักษณะเฉพาะของสิวได้อย่างครอบคลุมและมีเสถียรภาพ ผลที่ตามมาคือความสามารถในการจำแนกอาจถูกจำกัดอยู่ในกรอบของข้อมูลที่ใช้ในการฝึกสอนเท่านั้น

การกระจายตัวของข้อมูลในแต่ละระดับความรุนแรงของสิวไม่สมดุล โดยเฉพาะกลุ่มสิวะระดับความรุนแรงที่ 1 (Almost clear) ที่มีจำนวนภาพน้อยกว่ากลุ่มอื่น ส่งผลให้แบบจำลองเรียนรู้ข้อมูลจากกลุ่มระดับความรุนแรงที่มีจำนวนมากได้มากกว่ากลุ่มที่มีจำนวนน้อยซึ่งเป็นข้อจำกัดทางด้านความหลากหลายของข้อมูล และกลุ่มสิวะระดับความรุนแรงที่ 2 มีความใกล้เคียงกับกลุ่มสิวะระดับความรุนแรงที่ 1 และ 3 ทำให้แบบจำลองมีโอกาสจำแนกผิดพลาดได้บ่อยและ

นอกจากนี้การจำแนกระดับความรุนแรงของสิวในการศึกษานี้จำกัดอยู่เพียง 3 ระดับจากเกณฑ์มาตรฐาน Investigator's Global Assessment (IGA) ซึ่งแม้จะช่วยลดความซับซ้อนของการประมวลผล แต่ก็ทำให้ความละเอียดของผลการจำแนกลดลง และอาจไม่สะท้อนความแตกต่างระหว่างระดับ “ปานกลาง” และ “รุนแรง” ได้อย่างชัดเจน

และประเด็นสุดท้าย การประเมินผลแบบจำลองในงานวิจัยนี้ยังดำเนินการภายใต้สภาพแวดล้อมการทดลองในห้องปฏิบัติการเท่านั้น ยังไม่มีการนำระบบไปทดสอบในสภาพการใช้งานจริง เช่น ทดลองใช้ผ่านเว็บแอปพลิเคชันหรืออุปกรณ์พกพา ซึ่งอาจทำให้ผลการประเมินยังไม่สะท้อนประสิทธิภาพของระบบในบริบทการใช้งานจริงอย่างแท้จริง

5.3 ข้อเสนอแนะ

จากข้อจำกัดที่กล่าวมาข้างต้น ผู้วิจัยมีข้อเสนอแนะเพื่อใช้ในการพัฒนาการวิจัยในอนาคต ดังนี้

สำหรับชุดข้อมูลที่ใช้ในการสอนโมเดลอาจเพิ่มจำนวนชุดข้อมูลที่ใช้ในการฝึกสอนและการปรับชุดข้อมูลให้สมดุลในแต่ละระดับความรุนแรง โดยรวบรวมภาพจากแหล่งข้อมูลที่หลากหลาย ทั้งในด้านเพศ วัย สภาพผิว และสภาพแสง เพื่อให้แบบจำลองสามารถเรียนรู้ได้ครอบคลุมและมีความสามารถในการประยุกต์ใช้กับสภาพแวดล้อมจริงมากยิ่งขึ้นและควรเพิ่มระดับการจำแนกความรุนแรงของสิวให้ครอบคลุมทั้ง 5 ระดับตามเกณฑ์ IGA เพื่อให้ผลการจำแนกมีความละเอียดและใกล้เคียงกับการประเมินทางการแพทย์มากขึ้น

ควรรนำเทคนิคการสร้างข้อมูลสังเคราะห์ที่มีคุณภาพสูงมาใช้ เช่น StyleGAN หรือ Diffusion Model ซึ่งสามารถสร้างภาพจำลองที่มีความสมจริงและหลากหลายเพื่อลดปัญหาการเรียนรู้ซ้ำซ้อน งานวิจัยในอนาคตควรพิจารณาประยุกต์ใช้เทคนิคขั้นสูงทางด้าน Deep Learning และ Transfer Learning เพื่อเพิ่มศักยภาพของแบบจำลองในการจำแนกระดับความรุนแรงของสิวให้มีความแม่นยำมากยิ่งขึ้น ตัวอย่างเทคนิคที่ควรรนำมาศึกษาเพิ่มเติม ได้แก่ Vision Transformer (ViT) ซึ่งเป็นโครงข่ายประสาทเทียมที่ประยุกต์แนวคิดของ Transformer จากงานประมวลผลภาษาธรรมชาติมาใช้กับข้อมูลภาพ โดยแบ่งภาพออกเป็นส่วนย่อย (patches) และเรียนรู้ความสัมพันธ์เชิงบริบทระหว่างส่วนต่าง ๆ ของภาพได้อย่างมีประสิทธิภาพ ทำให้สามารถวิเคราะห์ลักษณะผิวและตำแหน่งของสิวได้อย่างละเอียดและแม่นยำมากขึ้น อีกหนึ่งเทคนิคที่มีประสิทธิภาพสูงคือ EfficientNet และ EfficientNetV2 ซึ่งเป็นโครงข่ายเชิงลึกที่ได้รับการออกแบบให้มีสมดุลระหว่างความแม่นยำและประสิทธิภาพในการคำนวณ โดยใช้แนวคิดการขยายขนาดเครือข่ายแบบผสมผสาน (compound scaling) เพื่อเพิ่มประสิทธิภาพการเรียนรู้โดยไม่เพิ่มภาระของการประมวลผลมากนัก เทคนิคนี้ช่วยให้แบบจำลองสามารถตรวจจับรายละเอียดที่ละเอียดอ่อนบนใบหน้า เช่น จุดสิวจุดแดง หรือสิวกักเสบได้อย่างมีประสิทธิภาพ ในขณะที่เดียวกันยังช่วยลดเวลาการประมวลผลและทรัพยากรที่ใช้ในการฝึกสอน

นอกจากนี้ เทคนิค Ensemble Transfer Learning ยังเป็นอีกแนวทางหนึ่งที่มีศักยภาพในการเพิ่มประสิทธิภาพของการจำแนก โดยอาศัยการผสมผสานผลลัพธ์จากแบบจำลองเชิงลึกหลายโมเดล เช่น ResNet, DenseNet และ Inception เข้าด้วยกัน เพื่อสร้างแบบจำลองรวมที่สามารถเรียนรู้ลักษณะเฉพาะของสิวจากหลายมุมมองและลดอคติของโมเดลเดี่ยว เทคนิคนี้ช่วยให้การจำแนกมีความแม่นยำและเสถียรมากขึ้นในสภาพข้อมูลที่มีความหลากหลายหรือไม่สมดุล ทั้งนี้ การประยุกต์ใช้เทคนิคดังกล่าวรวมกับการเพิ่มกลไก Attention Mechanism เพื่อให้โมเดลเน้นเฉพาะบริเวณที่เกิดสิวโดยตรง และเทคนิค Multi-Task Learning เพื่อให้โมเดลสามารถเรียนรู้การจำแนกสิวพร้อมกับการระบุลักษณะของรอยโรคผิวหนังอื่น ๆ ไปพร้อมกัน จะช่วยยกระดับความสามารถของระบบให้สามารถประเมินลักษณะสิวได้อย่างแม่นยำ ครอบคลุม และสอดคล้องกับการประเมินทางคลินิกมากยิ่งขึ้น

รายการอ้างอิง

- กุสาวดี เมลืองนนท์. (ม.ป.ป.). *ยารักษาสิว*. สืบค้นเมื่อ 24 มีนาคม 2566
<https://pharm.tu.ac.th/uploads/pharm/pdf/articles/acne57.pdf>
- พลูศรี เขตโสภณ. (2549). *ปัจจัยที่มีผลต่อความรู้ในการรักษาสิวของนักศึกษาระดับปริญญาตรี ในอำเภอเมือง จังหวัดนครปฐม*. สารนิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต. มหาวิทยาลัยศิลปากร.
- Bhate, K., & Williams, H. C. (2013). Epidemiology of acne vulgaris. *Br J Dermatol*, 168(3), 474-485.
- Bhavna, Verma, R., Handa, R., & Puri, V. (2019). A hybrid approach for diabetes prediction and risk analysis using data mining. In *International Conference on Advanced Communication and Computational Technology* (pp. 1213-1230). Singapore: Springer Nature Singapore.
- Brandt, F. S., Cazzaniga, A., & Hann, M. (2011). Cosmeceuticals: current trends and market analysis. In *Seminars in cutaneous medicine and surgery*, 30(3), 141-143.
- Bottou, L., Curtis, F. E., & Nocedal, J. (2018). Optimization methods for large-scale machine learning. *SIAM review*, 60(2), 223-311.
- Bottou, L., & Bousquet, O. (2011). *The tradeoffs of large-scale learning (Chapter in Optimization for Machine Learning)*. MIT Press.
- Buda, M., Maki, A., & Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249-259.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321-357.
- Chayatumagoon, S., & Chongstitvatana, P. (2021). Image classification of sugar crystal with deep learning. *2021 13th International Conference on Knowledge and Smart Technology (KST)*, 118-121. <https://doi.org/10.1109/kst51265.2021.9415841>

- Collier, N. C., Harper, C. J., Cantrell, C. W., Wang, W., Foster, W. K., & Elewski, E. B. (2008). The prevalence of acne in adults 20 years and older. *J Am Acad Dermatol*, *58*(1), 56–59.
- Chollet, F. (2017). *Deep Learning with Python*. Manning Publications.
- Cunliffe, W., Perera, W. D. H., & Thackray, P. (1970). Pilosebaceous duct physiology III. Observations on the number and size of pilosebaceous ducts in acne vulgaris. *British journal of dermatology*, *95*(2), 153–156.
- Draelos, Z. D. (2015). The science behind skin care: Moisturizers and their ingredients. *Journal of Cosmetic Dermatology*, *14*(2), 157-162.
<https://doi.org/10.1111/jocd.12131>
- Draelos, Z. D. (2020). The importance of skin care formulations for facial anti-aging. *Journal of Cosmetic Dermatology*, *19*(2), 351-356.
<https://doi.org/10.1111/jocd.13309>
- De Vries, F. M. C., Meulendijks, A. M., Driessen, R. J. B., van Dooren, A. A., Tjin, E. P. M., & van de Kerkhof, P. C. M. (2018). The efficacy and safety of non-pharmacological therapies for the treatment of acne vulgaris: A systematic review and best-evidence synthesis. *Journal of the European Academy of Dermatology and Venereology*, *32*(7), 1195–1203.
- Eichenfield, L. F., Krakowski, A. C., Piggott, C., Del Rosso, J., Baldwin, H., Friedlander, S. F., . . . Thiboutot, D. M. (2013). Evidence-Based Recommendations for the Diagnosis and Treatment of Pediatric Acne. *PEDIATRICS*, *131*(Supplement), 163–186.
- Eisen, A. Z., Holyoke, J. B., Lobitz W. C. (1955). Responses of the superficial portion of the human pilosebaceous apparatus to controlled injury. *Journal of Investigative Dermatology*, *25*(3), 145–156.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., . . . Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, *542*(7639), 115–118. <https://doi.org/10.1038/nature21056>
- Feldman, S., Careccia, R. E., Barham, K. L. & Hancox, J. (2004) Diagnosis and Treatment of Acne. *American Family Physician*, *69*(9), 2123-2130.

- Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). Synthetic data augmentation using GAN for improved liver lesion classification. *IEEE Transactions on Medical Imaging*, 38(3), 677–685.
- Fluhr, J. W., Gloor, M., & Lehmann, L. (2003). *Glycerol accelerates recovery of barrier function in vivo*. *Acta Dermato-Venereologica*.
- Gholamalinezhad, H., & Khosravi, H. (2020). *Pooling methods in deep neural networks: A review*. arXiv. <https://arxiv.org/abs/2009.07485>
- Goceri, E. (2021). Deep learning-based classification of facial dermatological disorders. *Computers in Biology and Medicine*, 128, 104118. <https://doi.org/10.1016/j.compbiomed.2021.104118>
- Goldberg, J. D., & Berlin, L. A. (2012). Acne and rosacea epidemiology, diagnosis, and treatment. *Manson Publishing*, 8-9
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27.
- Goulden, V., Stables, G., & Cunliffe, W. J. (1999). Prevalence of facial acne in adults. *Journal of the American Academy of Dermatology*, 41(4), 577–580. [https://doi.org/10.1016/S0190-9622\(99\)70300-2](https://doi.org/10.1016/S0190-9622(99)70300-2)
- Han, S., Park, H., Kim, S., & Lee, J. (2020). Facial region-based preprocessing for skin lesion classification using deep learning. *IEEE Access*, 8, 213764–213775.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263–1284. <https://doi.org/10.1109/TKDE.2008.239>
- Hinton, G., Srivastava, N., & Swersky, K. (2012). Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cited on*, 14(8), 2.

- Huynh, Q. T., Nguyen, P. H., Le, H. X., Ngo, L. T., Trinh, N. T., Tran, M. T. T., . . . Ngo, H. T. (2022). Automatic acne object detection and acne severity grading using smartphone images and artificial intelligence. *Diagnostics*, 12(8), 1879.
- Jeong, H. K., Park, C., Henao, R., & Kheterpal, M. (2023). Deep learning in dermatology: A systematic review of current approaches, outcomes, and limitations. *JID Innovations*, 3, Article 100150. <https://doi.org/10.1016/j.xjidi.2022.100150>
- Jonathan, D. (2023). *Transformer-based semantic segmentation image model: face-parsing*. <https://huggingface.co/jonathandinu/face-parsing>. Accessed Sep 12, 2023.
- Khan, M. O. (2024). AI explained: A simple guide to artificial intelligence. LinkedIn. <https://www.linkedin.com/pulse/ai-explained-simple-guide-artificial-intelligence-muhammad-omer-khan-q7ltf>
- King Mongkut's Institute of Technology, Ladkrabang. (n.d.). *Artificial neural network for weather prediction*. <https://weather4thai.kmitl.ac.th/ANN.php>
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. International Conference on Learning Representations (ICLR). <https://arxiv.org/abs/1412.6980>
- Kim, S., & Lee, H. (2019). Smartphone applications for acne severity assessment: A feasibility study. *Journal of Mobile Technology in Medicine*, 8(4), 44-50.
- King, B., Barve, S., Ford, A., & Jha, R. (2020). Unsupervised clustering of COVID-19 chest X-ray images with a self-organizing feature map. In *2020 IEEE 63rd International Midwest Symposium on Circuits and Systems (MWSCAS)*. (pp. 395-398). IEEE.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI)*, 1137–1145.
- Kubo, I., & Matsumoto, A. (2020). The chemistry and biological activities of salicylic acid derivatives. *Bioorganic & Medicinal Chemistry Letters*, 30(9), 126920.
- Kraning, K. K. & Odland, G. F. (1979). Prevalence, morbidity and cost of dermatologic diseases. *Journal of Investigative Dermatology*, 73, 395-513
- Krejcie, R. V., & Morgan. (1970). Determining Sample Size for Research Activities. *Education and Psychological Measurement*, 30(3), 607-610.

- Kumar, V., & Garg, M. L. (2018). Predictive analytics: A review of trends and techniques. *International Journal of Computer Applications*, 182(2).
- Layton, A. M., & Eady, E. A. (2011). Polyhydroxy acids (PHAs) for skin disorders. *Dermatologic Clinics*, 29(4), 581-590.
- Lee, J., Yoon, H., Kim, S., Lee, C., Lee, J., & Yoo, S. (2024). Deep learning-based skin care product recommendation: A focus on cosmetic ingredient analysis and facial skin conditions. *Journal of Cosmetic Dermatology*, 23(6), 2066–2077. <https://doi.org/10.1111/jocd.16218>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Liu, X., & Chen, Y. (2018). Deep learning for acne severity classification using convolutional neural networks. *Computer Methods and Programs in Biomedicine*, 153, 121-128.
- Malgina, E., & Kurochkina, M.-A. (2021). Development of the mobile application for assessing facial acne severity from photos. In *2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*. IEEE. <https://doi.org/10.1109/ElConRus51938.2021.9396382>
- MathWorks. (n.d.). *Transfer learning using MATLAB*. Retrieved May 20, 2024, from <https://www.mathworks.com/discovery/transfer-learning.html#matlab>
- McGinley, K. I., Webster, G. F., Ruggieri, M. R., & Leyden, J. J. (1980). Regional variations of cutaneous propionibacteria, correlation of Propionibacterium acnes populations with sebaceous secretion. *Journal of Clinical Microbiology*, 12(5), 672-675.
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), 1236–1246. <https://doi.org/10.1093/bib/bbx044>
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, 807-814.
- Norris, D. J. (2020). Machine learning with the raspberry pi: Experiments with data and computer vision. *Apress*, 25-213

- Oge, L. K., Broussard, A., & Marshall, M. D. (2019). Acne vulgaris: Diagnosis and treatment. *American family physician*, 100(8), 475-484.
- Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359.
<https://doi.org/10.1109/TKDE.2009.191>
- Praseetha, V. M., Bayezeed, S., & Vadivel, S. (2019). Secure fingerprint authentication using deep learning and minutiae verification. *Journal of Intelligent Systems*, 29(1), 1379-1387. <https://doi.org/10.1515/jisys-2018-0289>
- Phan, D., T., Ta, Q., B., Huynh, T., C., Vo T., H., Nguyen, C., H., Park S., . . . Oh, J. (2021). A smart LED therapy device with an automatic facial acne vulgaris diagnosis based on deep learning and internet of things application. *Computers in Biology and Medicine*, 136, 1-12.
- Purath, J., & Coyner, T. (2017). Pharmacologic therapy for acne. *Clinician Reviews*, 27(10), 22–29.
- Raghu, M., & Schmidt, E. (2020). *A survey of deep learning for scientific discovery* (arXiv:2003.11755). arXiv. <https://arxiv.org/abs/2003.11755>
- Rawlings, V. A., Webster, F. G. (2007). Acne and its therapy. *Informa healthcare*, 26.
- Rawat, W., & Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural Computation*, 29(9), 2352–2449.
- Rhee, E. J. (2018). A deep learning approach for classification of cloud image patches on small datasets. *Journal of information and communication convergence engineering*, 16(3), 173- 178.
- Ruder, S. (2017). *An overview of gradient descent optimization algorithms*. arXiv. <https://arxiv.org/abs/1609.04747>
- Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach*. Pearson.
- Raschka, S. (2018). *Model evaluation, model selection, and algorithm selection in machine learning*. arXiv. <https://arxiv.org/abs/1811.12808>
- Samek, W., Montavon, G., Lapuschkin, S., Anders, C. J., & Müller, K. R. (2021). Explaining deep neural networks and beyond: A review of methods and applications. *Proceedings of the IEEE*, 109(3), 247–278.

- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual explanations from deep networks via gradient-based localization. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 618–626.
- Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. *Proceedings of the 20th International Conference on Artificial Neural Networks (ICANN)*, 92-101.
- Smith, L. N. (2017). Cyclical learning rates for training neural networks. *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 464–472.
- Smith, J., & Doe, A. (2022). Application of image analysis in acne severity classification. *Journal of Dermatological Research*, 34(2), 123-130.
- Shannon, J. (2019). Why do humans get acne? a hypothesis. *Medical Hypotheses*, 134, 1-7.
- Sheel, D. (2020). *Deep Learning*. ABB Corporate Research Center.
<https://new.abb.com/news/detail/58004/deep-learning>.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, Article 60.
<https://doi.org/10.1186/s40537-019-0197-0>
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
<https://arxiv.org/abs/1409.155>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1–9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. (pp. 2818-2826). IEEE.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018). A Survey on Deep Transfer Learning. In *International Conference on Artificial Neural Networks*. (pp. 270-279). Springer.

- Tan, J. K. L., & Bhate, K. (2015). A global perspective on the epidemiology of acne. *British Journal of Dermatology*, 172, 3–12.
- Tougui, I., Jilbab, A., & El Mhamdi, J. (2021). Impact of the choice of cross-validation techniques on the results of machine learning-based diagnostic applications. *Healthcare*, 9(7), 829.
- Traini, D. O. (2025). Artificial intelligence in the assessment and grading of acne: a systematic review of recent advancements, datasets, challenges and future directions. *Journal of Personalized Medicine*, 15(6), 238.
- Titus, S., & Hodge, J. (2012). Diagnosis and Treatment of Acne. *American Family Physician*, 86(8), 734-740.
- Tjoa, E., & Guan, C. (2020). A survey on explainable artificial intelligence (XAI): Toward medical XAI. *IEEE Transactions on Neural Networks and Learning Systems*, 32(11), 4793–4813.
- Uchida, K., Tanaka, M., & Okutomi, M. (2018). Coupled convolution layer for convolutional neural network. *Neural Networks*, 105, 197-205.
- Wang, J. V., & Saedi, N. (2019). Evaluating the role of alpha hydroxy acids in dermatology. *Journal of Dermatological Treatment*, 30(3), 301-304.
- Wang, Y., Yang, L., Liu, S., & Zhang, Y. (2019). Automatic acne severity grading based on convolutional neural networks and the Investigator's Global Assessment scale. *IEEE Access*, 7, 120681–120689.
- Wang, P., Fan, E., & Wang, P. (2020). *Comparative Analysis of Image Classification Algorithms Based on Traditional Machine Learning and Deep Learning*. Pattern Recognition Letters.
- Walton, S., Wyatt, E. H., Cunliffe, W. J. (1988). Genetic control of sebum excretion and acne: A twin study. *Br J Dermatol*, 118, 6-393.
- Wang, S. H., Muhammad, K., Hong, J., Sangaiah, A. K., & Zhang, Y. D. (2020). Alcoholism identification via convolutional neural network based on parametric ReLU, dropout, and batch normalization. *Neural Computing and Applications*, 32, 665-680.

- Webster, G. F., Leyden, I. J., Nilsson, U. R. (1979). Complement activation by in acne vulgaris, consumption of complement by comedones. *Infection and immunity*, 26(1), 183-186.
- Wen, H., Yu, W., Wu, Y., Zhao, J., Liu, X., Kuang, Z., & Fan, R. (2022). Acne detection and severity evaluation with interpretable convolutional neural network models. *Technology and health care*, 143-153.
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big Data*, 3(1), 1-40.
- Williams, H. C., Dellavalle, R. P., & Garner, S. (2012). Acne vulgaris. *The Lancet*, 379(9813), 361–372.
- Wilson, A. C., Roelofs, R., Stern, M., Srebro, N., & Recht, B. (2017). *The marginal value of adaptive gradient methods in machine learning*. NeurIPS.
- Yang, Y., Guo, L., Wu, Q., Zhang, M., Zeng, R., Ding, H., . . . Lin, T. (2021). Construction and Evaluation of a Deep Learning Model for Assessing Acne Vulgaris Using Clinical Images. *Dermatology and Therapy*, 11(4), 1239–1248.
- Zaenglein, A. L., Pathy, A. L., Schlosser, B. J., Alikhan, A., Baldwin, H. E., Berson, D. S., . . . Bhushan, R. (2016). Guidelines of care for the management of acne vulgaris. *Journal of the American Academy of Dermatology*, 74(5), 945-973.
- Zhang, Y., Li, Q., & Liu, H. (2021). Deep convolutional neural network-based acne severity classification with face segmentation preprocessing. *IEEE Access*, 9, 88791–88802.
- Zhao, T., Zhang, H., & Spoelstra, J. (2019). A Computer Vision Application for Assessing Facial Acne Severity from Selfie Images. *Cornell university*, 1 ,1-4.
- Zhao, Z., Yang, L., Cheung, W., & Li, X. (2020). Skin disease recognition using improved GAN-based data augmentation. *Computer Methods and Programs in Biomedicine*, 195, 105568.
- Zou, Q., Qu, K., Luo, Y., Yin, D., Ju, Y., & Tang, H. (2019). Predicting diabetes mellitus with machine learning techniques. *Frontiers in Genetics*, 10, 515.

ภาคผนวก ก

หนังสือรับรองจริยธรรมวิจัยในมนุษย์



The Mae Fah Luang University Ethics Committee on Human Research
333 Moo 1, Thasud, Muang, Chiang Rai 57100
Tel: (053) 917-170 to 71 Fax: (053) 917-170 E-mail: rec.humang@mfu.ac.th

หนังสือรับรองด้านจริยธรรมการวิจัย

COA: 52/2025 รหัสโครงการวิจัย: EC 22190-18

ชื่อโครงการวิจัย : การพัฒนาระบบจำแนกระดับความรุนแรงของสิวบนใบหน้าและแนะนำผลิตภัณฑ์
สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก

ชื่อผู้วิจัยหลัก: นายธราดล ขวัญศิริ

สำนักวิชา: วิทยาศาสตร์สุขภาพ

ผู้สนับสนุนการวิจัย: สำนักงานบัณฑิตศึกษา มหาวิทยาลัยแม่ฟ้าหลวง

การรับรอง :

(1) โครงการวิจัย	ฉบับที่ 4 วันที่ 19 เมษายน 2566
(2) เอกสารข้อมูลและขอความยินยอมเข้าร่วมการวิจัย	ฉบับที่ 4 วันที่ 19 เมษายน 2566
(3) ข้อมูลประชาสัมพันธ์รับสมัครผู้เข้าร่วมโครงการวิจัย	ฉบับที่ 2 วันที่ 16 มกราคม 2566
(4) แบบสำรวจ	ฉบับที่ 1 วันที่ 13 มกราคม 2566
(5) แบบสอบถาม	ฉบับที่ 2 วันที่ 15 มกราคม 2566
(6) ผู้วิจัย และผู้วิจัยร่วม	
- นายธราดล ขวัญศิริ	- ผู้ช่วยศาสตราจารย์ ดร.วุฒิชัย นาชัยเวียง
- ผู้ช่วยศาสตราจารย์ ดร.ภัทรมน วุฒิพิทยามงคล	

ขอรับรองว่าโครงการดังกล่าวข้างต้นได้ผ่านการพิจารณารับรองจากคณะกรรมการจริยธรรมการวิจัย
ในมนุษย์ มหาวิทยาลัยแม่ฟ้าหลวง ว่าสอดคล้องกับแนวทางจริยธรรมสากล ได้แก่ ปฏิญญาเฮลซิงกิ (Declaration
of Helsinki) รายงานเบลมอนต์ (Belmont Report) แนวทางจริยธรรมสากลสำหรับการวิจัยในมนุษย์ของสภา
องค์การสากลด้านวิทยาศาสตร์การแพทย์ (CIOMS) และแนวทางการปฏิบัติการวิจัยที่ดี (ICH-GCP)

วันที่รับรองด้านจริยธรรมของโครงการวิจัย ครั้งที่ 1:	21 เมษายน 2566
วันที่รับรองด้านจริยธรรมของโครงการวิจัย ครั้งที่ 2:	2 เมษายน 2567
วันที่รับรองด้านจริยธรรมของโครงการวิจัย ครั้งที่ 3:	2 เมษายน 2568
วันสิ้นสุดการรับรอง:	1 เมษายน 2569
ความถี่ของการส่งรายงานความก้าวหน้าของการวิจัย:	1 ปี

ลงนาม

(อาจารย์ นพ.จุลพงศ์ อจลพงศ์)

ประธานคณะกรรมการจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยแม่ฟ้าหลวง

AL_02_1/2024 Certificate of Approval หน้า 1 จาก 4



The Mae Fah Luang University Ethics Committee on Human Research
333 Moo 1, Thasud, Muang, Chiang Rai 57100
Tel: (053) 917-170 to 71 Fax: (053) 917-170 E-mail: rec.human@mfu.ac.th

ผู้วิจัยที่โครงการวิจัยผ่านการรับรองจากคณะกรรมการจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยแม่ฟ้าหลวง
ต้องปฏิบัติดังต่อไปนี้

- (1) ดำเนินการวิจัยตามที่ระบุในโครงการวิจัยอย่างเคร่งครัด
- (2) ใช้เอกสารข้อมูลและขอความยินยอมเข้าร่วมการวิจัย / แบบสอบถาม / แบบบันทึกข้อมูล / เอกสาร
ประชาสัมพันธ์ ที่มีตราประทับของคณะกรรมการจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยแม่ฟ้าหลวง เท่านั้น
- (3) ผู้วิจัยต้องส่งรายงานความก้าวหน้าของการวิจัย (AP 05/2024) ตามระยะเวลาที่คณะกรรมการฯ กำหนด และ
ภายใน 30 วัน ก่อนหมดอายุการรับรอง ในกรณีที่การวิจัยยังไม่เสร็จสิ้น ผู้วิจัยต้องส่งจดหมายขอต่ออายุ
การรับรอง
- (4) เมื่อมีการแก้ไขเพิ่มเติมโครงการวิจัย ผู้วิจัยต้องส่งรายงานส่วนแก้ไขเพิ่มเติมโครงการวิจัย (AP 06/2024) และ
โครงการวิจัยที่มีการแก้ไขเพิ่มเติม เพื่อแจ้งให้คณะกรรมการฯ พิจารณารับรองก่อนดำเนินการตามที่ได้แก้ไข
เพิ่มเติม (ยกเว้นในกรณีที่การแก้ไขเพิ่มเติมนั้นกระทำเพื่อความปลอดภัยของอาสาสมัคร)
- (5) เมื่อมีเหตุการณ์ไม่พึงประสงค์ร้ายแรง “ในสถาบัน” ผู้วิจัยต้องส่งรายงานเหตุการณ์ไม่พึงประสงค์ชนิด
ร้ายแรง (AP 07/2024) ตามข้อกำหนดของ ICH-GCP
- (6) เมื่อมีการเบี่ยงเบนหรือไม่ปฏิบัติตามโครงการวิจัยที่ได้รับการรับรอง ผู้วิจัยต้องส่งรายงานการการเบี่ยงเบน
หรือไม่ปฏิบัติตามข้อกำหนด (AP 08/2024)
- (7) เมื่อการวิจัยเสร็จสิ้น หรือ มีการยุติโครงการวิจัยก่อนกำหนดเวลาที่กำหนด ผู้วิจัยต้องส่งรายงาน
ปิดโครงการวิจัย (AP 09/2024)

หมายเหตุ สามารถ Download แบบรายงานต่าง ๆ ได้ที่ <https://ethic.mfu.ac.th>

ข้าพเจ้าในฐานะ ผู้วิจัย ยินยอมที่จะปฏิบัติตามข้อกำหนดดังกล่าว

จรตล นิสริ์

(นายธราตล ขวัญศิริ)

วันที่ 21/04/๒๕



The Mae Fah Luang University Ethics Committee on Human Research
 333 Moo 1, Thasud, Muang, Chiang Rai 57100
 Tel: (053) 917-170 to 71 Fax: (053) 917-170 E-mail: rec.human@mfu.ac.th

CERTIFICATE OF APPROVAL

COA: 52/2025

Protocol No: EC 22190-18

Title Development of facial acne severity level classification and self-treatment product suggestion system using deep learning

Principal investigator: Mr. Taradon Khonsiri

School: Health Science

Funding support: Postgraduate studies scholarship, Mae Fah Luang University

Approval:

- | | |
|---|---|
| 1) Research protocol | Version 4 Date April 19, 2023 |
| 2) Information sheet and informed consent documents | Version 4 Date April 19, 2023 |
| 3) Research participant recruitment information | Version 2 Date January 16, 2023 |
| 4) Survey form | Version 1 Date January 13, 2023 |
| 5) Questionnaire | Version 2 Date January 15, 2023 |
| 6) Principal investigator and Co-investigators | |
| - Mr. Taradon Khonsiri | - Assistant Professor Woottichai Nachaiwieng, Ph.D. |
| - Assistant Professor Pattaramon Vuttipittayamongkol, Ph.D. | |

The aforementioned documents have been reviewed and approved by the Mae Fah Luang University Ethics Committee on Human Research in compliance with international guidelines such as Declaration of Helsinki, the Belmont Report, CIOMS Guidelines and the International Conference on Harmonization of Technical Requirements for Registration of Pharmaceuticals for Human Use - Good Clinical Practice (ICH - GCP)

Date of 1st Approval: April 21, 2023

Date of 2nd Approval: April 2, 2024

Date of 3rd Approval: April 2, 2025

Date of Expiration: April 1, 2026

Frequency of Continuing Review: 1 year

(Jullapong Achalapong, M.D.)

Chairperson of the Mae Fah Luang Ethics Committee on Human Research



The Mae Fah Luang University Ethics Committee on Human Research
 333 Moo 1, Thasud, Muang, ChiangRai 57100
 Tel: (053) 917-170 to 71 Fax: (053) 917-170 E-mail: rec.human@mfu.ac.th

For research protocol approved by the Mae Fah Luang University Ethics Committee on Human Research (MFU EC), the investigators must comply with the followings:

1. Strictly conduct the research as required by the protocol.
2. Use only the information sheet, consent form, questionnaire, case record form and advertisement bearing the MFU EC stamp of approval.
3. Submit a progress report (AP 05/2024) for continuing review and for renewing the approval within 30 days before expiration date.
4. When there are changes of the protocol, the investigator must submit an amendment report (AP 06/2024) with amended protocol for MFU EC approval before implementing any changes in the research (unless those changes are required urgently for the safety of the research subjects).
5. When there is any unanticipated problem or serious adverse event, the investigator must submit a safety report (AP 07/2024) as set forth in the ICH-GCP.
6. When there is any deviation or non-compliance with the approved protocol, the investigator must submit a protocol deviation/non-compliance report (AP 08/2024).
7. When the research is complete or terminated, the investigator must submit a closing report (AP 09/2024).

Please go to <https://ethic.mfu.ac.th> to download MFU EC forms for reporting.

I, as an investigator, agree to comply with the above obligation.

Taradon Khonsiri

(Mr. Taradon Khonsiri)

Date 21/04/68

ภาคผนวก ข

เอกสารข้อมูลและขอความยินยอมเข้าร่วมการวิจัย

Version 3 Date 19/04/2023

AP 03_1/2022

เอกสารข้อมูลและขอความยินยอมเข้าร่วมการวิจัย

ฉบับเก็บรวบรวมข้อมูลในการสอนอัลกอริทึม

ชื่อโครงการวิจัย : การพัฒนาระบบจำแนกระดับความรุนแรงของสิ่วบนใบหน้าและคำแนะนำผลิตภัณฑ์สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก (Development of facial acne severity level classification and self-treatment product suggestion system using deep learning.)

ผู้วิจัยหลัก : นายธราดล ขวัญศิริ

สังกัด : สำนักวิชาวิทยาศาสตร์สุขภาพ มหาวิทยาลัยแม่ฟ้าหลวง

อาจารย์ที่ปรึกษา : ผศ.ดร.วุฒิชัย นาชัยเวียง

แหล่งทุนวิจัย/ผู้สนับสนุนการวิจัย : มหาวิทยาลัยแม่ฟ้าหลวง

1. บทนำส่วนต้น สรุปสาระหลักของโครงการวิจัย

โดยวิทยานิพนธ์เรื่องนี้มีการศึกษาเกี่ยวกับการวิเคราะห์หรือจำแนกประเภทของสิ่วและระดับความรุนแรงของสิ่วตามบริเวณต่างๆบนใบหน้าด้วยระบบวิเคราะห์ของการเรียนรู้เชิงลึก (Deep learning) อีกทั้งการศึกษาวิจัยในครั้งนี้ นับว่าเป็นประโยชน์ต่อผู้ที่เป็นสิ่วในการช่วยประเมินและวินิจฉัยความรุนแรงของสิ่วในขั้นเบื้องต้นได้ ดังนั้นการจำแนกระดับความรุนแรงของสิ่วบนใบหน้าโดยใช้การเรียนรู้เชิงลึก (Deep learning) ในการวิเคราะห์แทนการเข้าพบแพทย์ผู้เชี่ยวชาญด้านการรักษาสิ่วยังช่วยลดค่าใช้จ่ายสำหรับการเข้าพบและปรึกษาแพทย์ผิวหนัง ซึ่งการเข้าพบแพทย์ผิวหนังในแต่ละครั้งอาจจะมีค่าใช้จ่ายและส่วนต่างสำหรับค่าผลิตภัณฑ์ในการรักษาสิ่ว อย่างไรก็ตามการเก็บข้อมูลภาพถ่ายใบหน้าในครั้งนี้ผู้วิจัยจะนำภาพถ่ายใบหน้าทั้งหมด 524 คน ซึ่งจะมีการถ่ายภาพหน้าตรง หน้าข้างซ้าย หน้าข้างขวา เพื่อนำไปสอนอัลกอริทึมวัตถุประสงค์ในการเก็บรวบรวมข้อมูลครั้งนี้เพื่อนำรูปภาพใบหน้าของอาสาสมัครมาใช้เป็นข้อมูลพื้นฐานสำหรับการสอนอัลกอริทึม โดยอาสาสมัครจะต้องกรอกข้อมูลลงในแบบฟอร์มและถ่ายภาพตามตัวอย่างที่ผู้วิจัยได้แจ้งไว้ ซึ่งจะมีการถ่ายภาพหน้าตรง หน้าข้างซ้าย หน้าข้างขวา สำหรับความเสี่ยงในการเข้าร่วมการวิจัยในครั้งนี้คือ ความเสี่ยงต่อการถูกเผยแพร่ข้อมูลใบหน้า แนวทางในการป้องกันข้อมูลถูกเผยแพร่ โดยผู้วิจัยจะจัดเก็บไฟล์ข้อมูลทั้งหมดไว้ในคอมพิวเตอร์ที่มีการใส่รหัสของผู้วิจัยเอง และข้อมูลใบหน้าทั้งหมดจะถูกเก็บเป็นความลับไม่มีการเปิดเผยแก่บุคคลอื่นที่ไม่มีความเกี่ยวข้องในงานวิจัยนี้ และอาสาสมัครจะได้รับประโยชน์จากการนำภาพถ่ายไปช่วยสอนอัลกอริทึมและสามารถทราบถึงระดับความรุนแรงของสิ่วโดยผู้เชี่ยวชาญจะเป็นผู้จำแนกระดับความรุนแรงของสิ่วและผู้วิจัยจะทำการเก็บข้อมูลภาพถ่ายที่ผ่านการวินิจฉัยแล้วไปสอนอัลกอริทึม ซึ่งหากอาสาสมัครต้องการทราบถึงระดับความรุนแรงของสิ่วที่ตนเป็นอยู่อาสาสมัครสามารถติดต่อผู้วิจัยโดยตรงผ่านโทรศัพท์มือถือของผู้วิจัยเองที่เบอร์ 096-793-4681 ทางเลือกอื่นกรณีท่านไม่ต้องการเข้าร่วมการวิจัย โดยท่านอาจจะไม่จำเป็นในการเข้าร่วมในโครงการวิจัยนี้ เนื่องจากท่านอาจจะมีความจำเป็นหรือแนวทางการรักษาอื่นจากโรงพยาบาลหรือคลินิกเสริมความงามต่างๆ สำหรับการรักษาสิ่วที่ท่านเป็นอยู่

ท่านได้รับการเชิญชวนให้เข้าร่วมในโครงการวิจัยนี้ เนื่องจากท่านมีความสนใจทดลอง เว็บบแอปพลิเคชัน ในการจำแนกระดับความรุนแรงของสิวและเป็นกลุ่มอาสาสมัครตามวัตถุประสงค์ของโครงการวิจัยและมีความประสงค์ที่จะเข้าร่วมเป็นอาสาสมัครในโครงการวิจัยนี้ ก่อนที่ท่านจะตกลงเข้าร่วมหรือไม่ โปรดอ่านข้อความในเอกสารนี้อย่างถี่ถ้วน เพื่อให้ทราบถึงเหตุผลและรายละเอียดของ โครงการวิจัยนี้ว่า หากเข้าร่วม ท่านจะต้องทำอะไรบ้าง รวมทั้งข้อดีและข้อเสียที่อาจเกิดขึ้นในระหว่างการวิจัย

หากท่านมีข้อสงสัยใด ๆ กรุณาซักถามจากทีมงานผู้วิจัย ซึ่งจะเป็นผู้ตอบคำถามจนกว่าท่านจะเข้าใจอย่างชัดเจน ท่านสามารถปรึกษาญาติพี่น้อง เพื่อน หรือแพทย์ที่ท่านรู้จัก ก่อนตัดสินใจว่าจะเข้าร่วมหรือไม่เข้าร่วมในโครงการวิจัยนี้

การเข้าร่วมในโครงการวิจัย จะต้องเป็น**ความสมัครใจ**ของท่าน ไม่มีการบังคับหรือชักจูง ถ้าท่านตัดสินใจเข้าร่วม กรุณาลงนามในเอกสารแสดงเจตนายินยอมเข้าร่วมโครงการวิจัยนี้

2. ข้อมูลระบุว่าเป็นการวิจัยและความเป็นอิสระในการตัดสินใจเข้าร่วมการวิจัย

ท่านได้รับเชิญให้เข้าร่วมการวิจัย โปรดใช้เวลาในการอ่านเอกสารฉบับนี้ ซึ่งจะช่วยให้ท่านรับทราบสิ่งต่าง ๆ ที่ท่านจะมีส่วนร่วมในการวิจัยนี้ การตัดสินใจเข้าร่วมการวิจัยนี้ขึ้นอยู่กับความสมัครใจของท่าน หากท่านไม่สมัครใจเข้าร่วมการวิจัย จะไม่มีผลใด ๆ ต่อการดูแลรักษาหรือสิทธิที่ท่านพึงมี

การเข้าร่วมการวิจัยนี้ขึ้นอยู่กับความสมัครใจ

- ท่านสามารถตัดสินใจได้อย่างอิสระว่าจะเข้าร่วมหรือไม่เข้าร่วมการวิจัยนี้
- ท่านสามารถปรึกษาครอบครัวหรือแพทย์ผู้รักษาก่อนตัดสินใจ และสามารถซักถามข้อสงสัยเกี่ยวกับโครงการวิจัยได้ ซึ่งผู้วิจัยจะอธิบายเพิ่มเติมแก่ท่านและตอบข้อซักถามจนท่านเข้าใจ
- หากท่านสมัครใจเข้าร่วมการวิจัยนี้แล้ว ท่านยังคงสามารถถอนตัวออกจากกรวิจัยได้ทุกเมื่อ

3. เหตุผลและความสำคัญของการวิจัย

ส่วนใหญ่สิวมักเกิดกับวัยรุ่นและไม่ใช้ความผิดปกติสำหรับวัยรุ่นใหญ่รวมถึงสามารถพบได้ในเด็กด้วยเช่นกัน โดยความรุนแรงของสิวมักจะมากขึ้น 3-5 ปี หลังจากเริ่มเป็นสิวมักหายในช่วงอายุ 20-25 ปี นอกจากนี้ยังพบอีกว่าการใช้เครื่องสำอางเพื่อเสริมสร้างความงาม ซึ่งเครื่องสำอางที่ใช้เป็นส่วนหนึ่งของสาเหตุสำคัญที่ทำให้เกิดสิวมักส่งผลให้เกิดความไม่มั่นใจต่อภาพลักษณ์และความวิตกกังวลเป็นอย่างมากในผู้ป่วยที่ได้รับผลกระทบ เนื่องจากสิวมักเป็นหนึ่งในความผิดปกติที่พบบ่อยที่สุดซึ่งรักษาโดยแพทย์ผิวหนังและผู้ให้บริการด้านสุขภาพอื่นๆ และอาจจะมีภาระค่าใช้จ่ายเป็นจำนวนมากในการรักษาหรือวิเคราะห์ความรุนแรงของสิวมโดยการเข้าปรึกษาแพทย์ผู้เชี่ยวชาญ ดังนั้นผู้วิจัยจึงต้องการที่จะแสดงให้เห็นอาสาสมัครได้ทราบถึงระดับความรุนแรงของสิวมพร้อมทั้งให้คำแนะนำเกี่ยวกับทางเลือกในการรักษาที่มีอยู่แล้วสำหรับการรักษาสิวมโดยผ่านการวิเคราะห์ของการเรียนรู้เชิงลึก

4. คุณสมบัติของผู้ที่สามารถเข้าร่วมการวิจัย และจำนวนผู้เข้าร่วมการวิจัย

การวิจัยนี้จะคัดเลือกบุคคลทั่วไปที่มีและไม่มีปัญหาสิวมใบหน้าเข้าร่วมการวิจัยจำนวน 524 คน

ท่านได้รับเชิญให้เข้าร่วมในโครงการวิจัยนี้เพราะคุณสมบัติที่เหมาะสมดังต่อไปนี้

1. เพศหญิงหรือเพศชาย
2. อายุตั้งแต่ 18 ขึ้นไป
3. เป็นบุคคลทั่วไปที่มีและไม่มีปัญหาสิ่วบนใบหน้า
4. ผู้ที่มีความต้องการที่จะวิเคราะห์ระดับความรุนแรงของสิ่วบนใบหน้า

ท่านไม่สามารถเข้าร่วมในโครงการวิจัย หากท่านมีคุณสมบัติดังต่อไปนี้

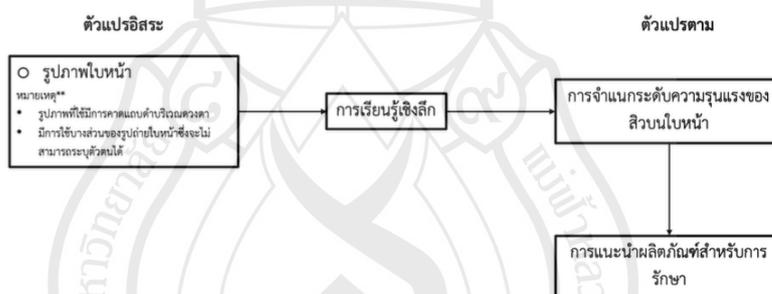
ผู้ที่ เป็นโรคกลัวการถ่ายภาพ

5. วัตถุประสงค์ของการวิจัย

โครงการวิจัยนี้มีวัตถุประสงค์

1. เพื่อนำรูปภาพใบหน้าของอาสาสมัครมาใช้เป็นข้อมูลพื้นฐานสำหรับการสอนอัลกอริทึมเพื่อเรียนรู้ระดับความรุนแรงของสิ่ว

6. รูปแบบการวิจัย



การศึกษานี้เป็นการวิจัยเชิงทดลองที่แท้จริงโดยโครงการวิจัยนี้เป็นการจำแนกและวิเคราะห์ระดับความรุนแรงของสิ่วด้วย อัลกอริทึมการเรียนรู้ของเครื่องซึ่งจะมีการเรียนรู้เชิงลึกในการประมวลผลและจะมีการให้คำแนะนำการดูแลรักษาผ่านการประมวลผลซึ่งจะใช้ตัวอย่างภาพถ่ายจากอาสาสมัครหรือคลินิกเสริมความงามในจังหวัดเชียงรายหรือจังหวัดใกล้เคียง จำนวนหลายภาพถ่าย ในการวิจัยเพื่อประสิทธิภาพสูงสุดของระบบการประมวลผลของการเรียนรู้เชิงลึกและจะมีการแนะนำผลิตภัณฑ์สำหรับการรักษาสำหรับอาสาสมัครที่มาใช้งานระบบ

สถานที่ทำการวิจัย และจำนวนผู้เข้าร่วมในโครงการวิจัย

สถานที่ทำการวิจัยคือ จังหวัดเชียงราย จำนวนผู้เข้าร่วมในโครงการจำนวน 524 คน โดยคัดเลือกจากบุคคลทั่วไปที่มีปัญหาสิ่วบนใบหน้าและไม่มีปัญหาสิ่วบนใบหน้าซึ่งจะคัดเลือกจากอาสาสมัครในจังหวัดเชียงราย

และจังหวัดที่ใกล้เคียง ซึ่งก่อนถ่ายภาพต้องไม่มีเครื่องสำอางปกปิดรอยโรคหรือสิวเพื่อผลลัพธ์ที่แม่นยำต่อการอ่านค่าของอัลกอริทึมโดยระบบการเรียนรู้เชิงลึกจะมีการเรียนรู้และวิเคราะห์ระดับความรุนแรงของสิบบนใบหน้า

7. ขั้นตอนการวิจัยและระยะเวลาที่เข้าร่วมการวิจัย

1. อาสาสมัครสแกน QR code
2. อาสาสมัครกรอกข้อมูลและอัปโหลดรูปภาพใบหน้าที่อาสาสมัครเป็นผู้ถ่ายเองด้วยโทรศัพท์ของอาสาสมัครเองโดยไม่ผ่านแอปแต่งรูปใดๆทั้งสิ้นหรือผู้วิจัยเป็นผู้ถ่ายภาพใบหน้าอาสาสมัครเองด้วยโทรศัพท์มือถือของผู้วิจัยด้วยแอปกล้องถ่ายภาพของโทรศัพท์ไอโฟน 14 ซึ่งประกอบไปด้วยภาพถ่ายหน้าตรง หน้าข้างซ้าย หน้าข้างขวา เพื่อนำภาพถ่ายไปใช้ในการสอนอัลกอริทึมโดยใช้ระยะเวลาประมาณ 10-15 นาที

ความรับผิดชอบของผู้เข้าร่วมในโครงการวิจัย

การให้ความร่วมมือในการถ่ายภาพตามคำแนะนำของผู้วิจัย

8. ความเสี่ยงและความไม่สะดวกสหายจากการเข้าร่วมการวิจัย

ความเสี่ยงต่ออาสาสมัครเมื่อเข้าร่วมโครงการวิจัยนี้

ไม่มีความเสี่ยงหรืออันตรายต่อร่างกายของอาสาสมัครแต่อาจมีความเสี่ยงในรูปแบบของข้อมูล เช่น อาจมีความเสี่ยงต่อการถูกเผยแพร่ข้อมูลใบหน้า

ความไม่สบาย หรือความเสี่ยงที่อาจเกิดขึ้น และการดูแลรักษา

วิจัยนี้ไม่เกิดความเสี่ยงและอันตรายต่ออาสาสมัคร แต่อาจมีความเสี่ยงต่อการถูกเผยแพร่ข้อมูลใบหน้า จึงเกิดความไม่สบายใจเกิดขึ้น และมีความกังวลการเสียเวลาในการเข้าร่วมทำการทดสอบ ความกังวลต่อการถ่ายภาพและการเปิดเผยผิวหนังแบบไร้เครื่องสำอาง ในความเสี่ยงของการถูกเผยแพร่ข้อมูลใบหน้านั้น ผู้วิจัยมีแนวทางในการป้องกันข้อมูลถูกเผยแพร่ โดยผู้วิจัยจะจัดเก็บไฟล์ข้อมูลทั้งหมดไว้ในคอมพิวเตอร์ที่มีการใส่รหัสของผู้วิจัยเอง และข้อมูลใบหน้าทั้งหมดจะถูกเก็บเป็นความลับไม่มีการเปิดเผยแก่บุคคลอื่นที่ไม่มีความเกี่ยวข้องในงานวิจัยนี้

9. ประโยชน์ที่คาดว่าจะเกิดขึ้นจากการเข้าร่วมการวิจัย

1. การวิเคราะห์ประเภทของสิบบนใบหน้าผ่านระบบการเรียนรู้เชิงลึก อาสาสมัครจะได้ทราบถึงระดับความรุนแรงของสิบบนใบหน้าและอาสาสมัครจะได้รับคำแนะนำจากเว็บแอปพลิเคชัน เพื่อเป็นแนวทางในการรักษาพร้อมทั้งแสดงให้เห็นถึงสาเหตุที่ทำให้เกิดสิบบนใบหน้าในระดับความรุนแรงต่างๆ และยังได้รับวิธีการป้องกันและแก้ไขปัญหาของการเกิดสิบบนใบหน้าอย่างถูกวิธี หากอาสาสมัครต้องการที่จะทราบถึงระดับความรุนแรงของสิบบนใบหน้าสามารถติดต่อผู้วิจัยเพื่อสอบถามข้อมูลได้โดยตรงผ่านทางเบอร์โทรศัพท์มือถือ

2. การวิเคราะห์ภาพถ่ายใบหน้าโดยใช้ระบบการเรียนรู้เชิงลึก เป็นการวิเคราะห์แทนการเข้าพบแพทย์ผู้เชี่ยวชาญด้านการรักษาสิบบนใบหน้า ช่วยลดค่าใช้จ่ายในการเข้าพบแพทย์ในการรักษาสิบบนใบหน้าในระดับต่างๆ

10. ทางเลือกอื่น หากไม่สมัครใจเข้าร่วมการวิจัย

ท่านอาจจะไม่จำเป็นต้องเข้าร่วมในโครงการวิจัยนี้ เนื่องจากท่านอาจจะมีคำแนะนำหรือแนวทางการรักษาอื่น ๆ จากโรงพยาบาลหรือคลินิกเสริมความงามต่างๆ สำหรับการรักษาสิวที่ท่านเป็นอยู่

11. แนวทางการจัดการเมื่อมีสถานการณ์ที่อาจเกิดขึ้นระหว่างการวิจัย

สถานการณ์	แนวทางการปฏิบัติ
▪ หากท่านถอนตัวระหว่างการวิจัย	ท่านสามารถถอนตัวออกจากกรวิจัยได้ทุกเมื่อหากท่านรู้สึกไม่ปลอดภัยต่อการให้ข้อมูลส่วนตัวแก่ผู้วิจัย และสามารถแจ้งต่อผู้วิจัยในการลบข้อมูลของท่านได้ทุกเมื่อ
▪ หากมีข้อมูลใหม่ที่เกี่ยวข้องกับการวิจัยหรือความปลอดภัยของท่าน	ผู้วิจัยจะแจ้งให้ท่านทราบโดยเร็ว และท่านสามารถตัดสินใจได้ว่า ท่านจะร่วมอยู่ในกรวิจัยนี้ต่อหรือไม่

12. ประโยชน์หรือสิ่งที่คุณเข้าร่วมการวิจัยอาจได้รับ หลังเสร็จสิ้นการวิจัย

หลังจากเสร็จสิ้นการวิจัย อาสาสมัครสามารถติดต่อผู้วิจัยเพื่อสอบถามถึงระดับความรุนแรงของสิวนบนใบหน้าและปัจจัยที่อาจก่อให้เกิดผลกระทบต่อกรเกิดสิวนพร้อมทั้งยังทราบถึงแนวทางการป้องกันและการรักษาดูแลสิวนตามความเหมาะสมของระดับความรุนแรงของสิวนบนใบหน้าซึ่งระบบกรจำแนกได้ให้คำแนะนำได้

13. การรักษาความลับของข้อมูลและข้อจำกัดในการรักษาความลับของข้อมูล

กรดำเนินการวิจัยและการนำเสนอข้อมูลผลกรศึกษาเพื่อประโยชน์ทางวิชาการ ข้อมูลของอาสาสมัครจะถูกเก็บเป็นความลับ จะไม่เปิดเผยข้อมูลของอาสาสมัครต่อสาธารณะ และมีมาตรการในการเก็บรักษาข้อมูลส่วนตัว โดยมีการใช้รหัสแทนตัวอาสาสมัครซึ่งจะเก็บรวบรวมข้อมูลในรูปแบบภาพถ่ายของอาสาสมัครผู้มีสิวนและไม่มีสิวนบนใบหน้าโดยเก็บรวบรวมไว้ในคอมพิวเตอร์ซึ่งแต่ละภาพถ่ายจะบันทึกเป็นรหัสของอาสาสมัครและไม่มีการบุชื่อของอาสาสมัครและมีการคาดแถบดำบริเวณดวงตาเพื่อไม่ให้สามารถระบุตัวตนของผู้ให้ข้อมูลได้ รวมไปถึงหลักฐานและเอกสารจะถูกทำลายหลังสิ้นสุดโครงการเมื่อครบ 3 ปี

14. ค่าตอบแทนกรเข้าร่วมในการวิจัย

- ไม่มีค่าตอบแทน

15. ค่าใช้จ่ายที่ผู้เข้าร่วมการวิจัยต้องรับผิดชอบ

- ไม่มีค่าใช้จ่ายใดๆในการเข้าร่วมโครงการวิจัยนี้

16. บุคคลที่สามารถติดต่อได้ กรณีที่มีปัญหาหรือข้อสงสัย

หากมีคำถามเกี่ยวข้องกับการวิจัย ท่านสามารถติดต่อผู้วิจัย หรือผู้รับผิดชอบ ได้ตลอด 24 ชั่วโมง และหากเกิดอันตรายใด ๆ ท่านสามารถติดต่อผู้วิจัยได้ตลอด 24 ชั่วโมง นายธราตล ขวัญศิริ สำนักวิชาวิทยาศาสตร์สุขภาพ สาขาวิชาเทคโนโลยีชีวกรแพทย์และสารสนเทศสุขภาพ หลักสูตรวิทยาการวิเคราะห์ทาง

Version 3 Date 19/04/2023

AP 03_1/2022

สุขภาพและชีวการแพทย์ มหาวิทยาลัยแม่ฟ้าหลวง เบอร์โทรศัพท์ 096-793-4681 อีเมล 6451811501@lamduan.mfu.ac.th

หากท่านได้รับการปฏิบัติที่ไม่เป็นธรรมในโครงการวิจัยนี้ ท่านสามารถติดต่อได้ที่ห้องปฏิบัติการ คณะกรรมการจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยแม่ฟ้าหลวง อาคารบริการวิชาการ (AS) ชั้น 4 มหาวิทยาลัยแม่ฟ้าหลวง โทรศัพท์ 053-917-170 ถึง 71 โทรสาร 053-917-170 หรืออีเมล rec.human@mfu.ac.th



หนังสือแสดงความยินยอมเข้าร่วมการวิจัย

ข้าพเจ้า _____ ตัดสินใจเข้าร่วมการวิจัยเรื่อง ระบบ
จำแนกระดับความรุนแรงของสิวบนใบหน้าและแนะนำผลิตภัณฑ์สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก ซึ่ง
ข้าพเจ้าได้รับข้อมูลและคำอธิบายเกี่ยวกับการวิจัยนี้แล้ว และได้มีโอกาสซักถามและได้รับคำตอบเป็นที่พอใจ
แล้ว ข้าพเจ้ามีเวลาเพียงพอในการอ่านและทำความเข้าใจข้อมูลในเอกสารให้ข้อมูลสำหรับผู้เข้าร่วมการวิจัย
อย่างถี่ถ้วน และได้รับเวลาเพียงพอในการตัดสินใจว่าจะเข้าร่วมการวิจัยนี้

ข้าพเจ้ารับทราบว่าข้าพเจ้าสามารถปฏิเสธการเข้าร่วมการวิจัยนี้ได้โดยอิสระ และระหว่างการเข้าร่วม
การวิจัย ข้าพเจ้ายังสามารถถอนตัวออกจากการศึกษาได้ทุกเมื่อ โดยไม่ส่งผลกระทบต่อการศึกษา หรือสิทธิ
ที่ข้าพเจ้าพึงมี

โดยการลงนามนี้ ข้าพเจ้าไม่ได้สละสิทธิใด ๆ ที่ข้าพเจ้าพึงมีตามกฎหมาย และหลังจากลงนามแล้ว
ข้าพเจ้าจะได้รับเอกสารข้อมูลและขอความยินยอมไว้จำนวน 1 ชุด

ลายมือชื่อผู้เข้าร่วมการวิจัย _____ วัน-เดือน-ปี _____
(_____)

<p>..... (กรณีที่ผู้เข้าร่วมการวิจัยอ่านหนังสือไม่ออกแต่พึงเข้าใจ)</p> <p>ข้าพเจ้าไม่สามารถอ่านหนังสือได้ แต่ผู้วิจัยได้อ่านข้อความในเอกสารข้อมูลและขอความยินยอมนี้ให้แก่ ข้าพเจ้าฟังจนเข้าใจดีแล้ว ข้าพเจ้าจึงลงนามหรือพิมพ์ลายนิ้วมือของข้าพเจ้าในหนังสือนี้ด้วยความสมัครใจ</p> <p>ลงนาม/พิมพ์ลายนิ้วมือผู้เข้าร่วมการวิจัย _____ วัน-เดือน-ปี _____ (_____)</p>
--

ลายมือชื่อผู้ขอความยินยอม _____ วัน-เดือน-ปี _____
(_____)

คำรับรองของพยานผู้ไม่มีส่วนได้เสียกับการวิจัย (กรณีที่ผู้เข้าร่วมการวิจัยอ่านหนังสือไม่ออกแต่พึงเข้าใจ)

ข้าพเจ้าได้อยู่ร่วมในกระบวนการขอความยินยอมและยืนยันว่า ผู้ขอความยินยอมได้อ่าน/อธิบาย
เอกสารข้อมูลให้แก่ _____ ซึ่งผู้มีชื่อข้างต้นมีโอกาสดูถามข้อสงสัยต่าง ๆ และ
ได้ให้ความยินยอมเข้าร่วมการวิจัยโดยอิสระ หลังจากรับทราบข้อมูลที่มีอยู่ตรงตามที่ปรากฏในเอกสารนี้แล้ว

ลายมือชื่อพยาน _____ วัน-เดือน-ปี _____
(_____)

ภาคผนวก ค

เอกสารประชาสัมพันธ์รับอาสาสมัครเข้าร่วมโครงการวิจัย

Version 2 Date 16/01/2023

เปิดรับอาสาสมัครเข้าร่วมโครงการวิจัย

การพัฒนาระบบจำแนกระดับความรุนแรงของสิ่วบนใบหน้าและ
คำแนะนำผลิตภัณฑ์สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก

เกณฑ์การคัดเลือกอาสาสมัครเข้าร่วม
โครงการวิจัย

- เพศหญิงหรือเพศชายอายุ 18 ปีขึ้นไป
- เป็นบุคคลทั่วไปที่มีและไม่มีปัญหาสิ่วบนใบหน้า
- เป็นผู้ที่สุขภาพร่างกายแข็งแรง
- ผู้ที่มีความต้องการที่จะวิเคราะห์ระดับความรุนแรงของสิ่วบนใบหน้า

สอบถามข้อมูลเพิ่มเติมได้ที่
นายรราดล ขวัญศิริ
สำนักวิชาวิทยาศาสตร์สุขภาพ
หลักสูตรวิทยาการวิเคราะห์ทางสุขภาพและชีวการแพทย์
โทร: 096-793-4681
งานวิจัยนี้เป็นส่วนหนึ่งของวิทยานิพนธ์

ลงทะเบียนได้ที่
QR code




ภาคผนวก ง

แบบฟอร์มกรอกข้อมูลสำหรับอาสาสมัครที่สแกนคิวอาร์โค้ด

Section 1 of 3

× ⋮

ลงทะเบียนเก็บข้อมูลสำหรับทำวิทยานิพนธ์ในหัวข้อ " การพัฒนาระบบจำแนกระดับความรุนแรงของสิวนนไบหน้าและคำแนะนำผลิตภัณฑ์สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก "

คำชี้แจงสำหรับการเข้าร่วมโครงการ
แบบสอบถามการลงทะเบียนนี้เป็นส่วนหนึ่งของรายวิชาวิทยานิพนธ์ รหัสวิชา 1811780 ของนักศึกษาปริญญาโท สำนักวิชาวิทยาศาสตร์สุขภาพ สาขาวิชาวิทยาการวิเคราะห์ทางสุขภาพและชีวการแพทย์ อยู่ภายใต้การดูแลของ ผศ. ดร.วุฒิชัย นาชัยเวียง และ ผศ. ดร.ดร.ภัทรมน วุฒิพิทยามงคล ซึ่งเป็นอาจารย์ที่ปรึกษาในการทำวิจัยครั้งนี้ โดยข้อมูลที่ท่านได้กรอกในแบบสอบถามนี้จะไม่มีการเปิดเผยต่อสาธารณะและจะเก็บไว้เป็นความลับสำหรับการวิจัยในหัวข้อ "การพัฒนาระบบจำแนกระดับความรุนแรงของสิวนนไบหน้าและคำแนะนำผลิตภัณฑ์สำหรับการรักษาโดยใช้การเรียนรู้เชิงลึก"

วัตถุประสงค์
เพื่อนำรูปภาพไบหน้าของอาสาสมัครมาใช้เป็นข้อมูลพื้นฐานสำหรับการสอนอัลกอริทึมเพื่อเรียนรู้ระดับความรุนแรงของสิวน

แบบสอบถามแบ่งออกเป็น 2 ส่วน ดังนี้

1. ข้อมูลส่วนตัว
2. ปัญหาสิวนนไบหน้า

Section 2 of 3

ส่วนที่ 1 ข้อมูลส่วนตัว ✕ ⋮

Description (optional)

อายุ*

Short answer text

เบอร์โทรศัพท์ที่ติดต่อกลับ

Long answer text

Section 3 of 3

ส่วนที่ 2 ปัญหาสิวบนใบหน้า ✕ ⋮

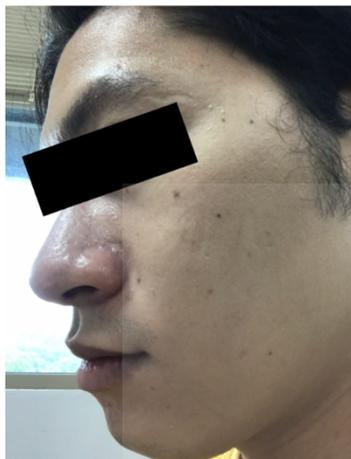
Description (optional)

ท่านมีปัญหาสิวบนใบหน้าหรือไม่*

มี

ไม่มี

อัฟ โหลดภาพถ่ายใบหน้า (หน้าด้านซ้าย) *



📁 Add file

อัฟ โหลดภาพถ่ายใบหน้า (หน้าตรง) *



📁 Add file

อัฟ โหลดภาพถ่ายใบหน้า (หน้าด้านขวา) *



📁 Add file



ภาคผนวก จ

แบบฟอร์มกรอกข้อมูลสำหรับแพทย์เฉพาะทางด้านผิวหนังในการแยกระดับความรุนแรงของสิว

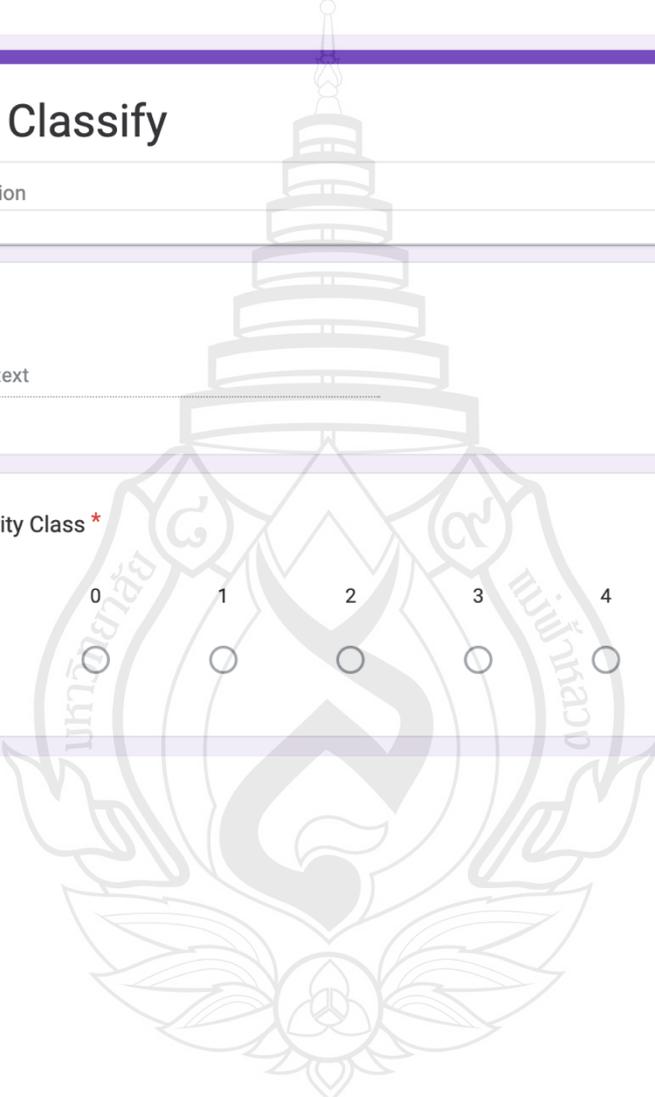


Image Classify

Form description

Folder ID *

Short answer text

Overall Severity Class *

	0	1	2	3	4	
None	<input type="radio"/>	Very Severe				

ภาคผนวก จ

ข้อมูลสำหรับการดูแลรักษาผิวเบื้องต้นที่ต้องใช้แนะนำใน Web Application

Skin types

1. NORMAL SKIN

A well-balanced skin is referred to as the normal skin type. Your skin falls under this category if it has a good balance of oil- and moisture. It is not the most common skin type in adults as it is generally seen before puberty.

Normal Skin characteristics:

- even texture and tone
- good elasticity
- blemish free
- small pores

2. DRY SKIN

This skin type produces less sebum as a result of which - it lacks lipids that it needs to retain moisture to protect - the skin against external influences.

Dry skin might have a dull and rough appearance.

Dry Skin characteristics:

- coarse texture
- tight pores
- less elasticity
- more visible lines (premature aging)

* You should be applied skin care oil base.

3. OILY SKIN

Contrary to dry skin, oily skin overproduces sebum.

This skin type is fairly common in adolescents because -

the sebaceous gland is stimulated by hormones at puberty -
which increases the oil flow in the skin.

Oily Skin characteristics:

- enlarged pores
- greasy and shiny appearance
- prone to acne
- good skin tone

**You should be applied skin care water base. **

4. COMBINATION

This skin type has the characteristics of both, dry and oily skin.

It is one of the most common skin types with oilier usually in the T-zone area (forehead, nose and chin), while the cheeks and sides of the face can be either normal or dry.

Combination Skin characteristics:

- larger pores around the T-zone
- thicker texture in oily areas
- prone to blemishes around oilier areas

**You should be avoided to applied skin care oil base on T-zone. **

Skincare routine





Morning skincare routine

1. **Cleanse:** Wash your face with a gentle cleanser (or water if you're in a rush).
2. **Moisturize:** Apply moisturizer (Cream, Gel, Lotion). You can use a broad-spectrum moisturizing sunscreen with SPF 30+ to skip step 3.
3. **Protect:** Apply a broad-spectrum sunscreen with SPF 30+. Do we sound like a broken record.

Nighttime skincare routine

1. **Cleanse:** Wash your face with a gentle cleanser. Now's the time to remove your makeup (we like micellar water for this).
2. **Treat:** Apply your products in a thin layer or use your other skin treatment as directed.
3. **Moisturize:** Apply a moisturizer— ultra-hydrating rich moisturizer (Cream, Gel, Lotion).

Moisturizers containing botanical extracts have anti-inflammatory properties.

- Ginkgo biloba
- Green tea
- Licochalcone
- Aloe vera
- Allantoin
- Cica (Centellar Asiatica)

Active ingredients help to acne care.

- Zinc PCA (1%).
- Nicotinamide-Vitamin B3 (5%)

Acne Management

Severity 1 Non-inflammation

Comedolytic (Black head/White head)

You can choose the only one that recommends topical products for acne treatment. (Topical monotherapy)

Recommends applying topical products.

- Retinoid (0.01-0.1%). Apply retinoid in a thin layer to your entire face at night skin care routine (be careful not to get it in your mouth, nostrils, and eyes). You should use a dose that's about the size of a pea. For the first couple weeks of treatment, apply retinoid only every other day. Finish with a facial moisturizer that won't clog your pores (non-comedogenic). You must apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning.

- Benzoyl peroxide (2.5-10%). Applied 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply moisturizer for reduce side effects, avoid sensitive areas such as under the eyes, nostrils, and around the mouth (for beginner should be use 2.5% concentration of benzoyl peroxide)

- Azelaic acid (20%). Before applying, wash the affected area of your skin with water and a mild soap or a cleansing lotion that does not contain soap. Rinse well and pat dry. Shake the foam can well before using. Apply a small amount of the medicine to each affected area and gently rub it in. Be sure to apply your azelaic acid at night and practice wearing sunscreen during the day. If you're using a serum with azelaic acid, apply it before azelaic acid, moisturizers, and sunscreen.

The medication products of retinoid

- Adapalene (Differin®, Epiduo®).
- Tazarotene (Tazorac®, Avage®).
- Tretinoin (Atralin®, Avita®, Refissa®, Renova®, Retin-A®, Tretin-X®).

Side effects

- Redness
- Peeling
- Drying
- Itching
- Photosensitivity
- Burning sensation
- skin irritants (stop to apply the products and consult with dermatologist.)

** To reduce side effects, you must apply moisturizer to every skin care routine and. apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning. **

consultation with dermatologist or pharmaceutical before you apply the products.

Severity 2 Mild-inflammation

Papule and pustules

You can choose the only one or combination that recommends topical products for acne treatment. (Topical monotherapy or Topical combination therapy)

Recommends applying topical products.

Topical monotherapy

- Retinoid (0.01-0.1%). Apply retinoid in a thin layer to your entire face at night skin care routine (be careful not to get it in your mouth, nostrils, and eyes). You should use a dose that's about the size of a pea. For the first couple weeks of treatment, apply retinoid only every other day. Finish with a facial moisturizer that won't clog your pores (non-comedogenic). You must apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning.
- Benzoyl peroxide (2.5-10%). Applied 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply moisturizer for reduce side effects, avoid sensitive areas such as under the eyes, nostrils, and around the mouth (for beginner should be use 2.5% concentration of benzoyl peroxide)
- Azelaic acid (20%). Before applying, wash the affected area of your skin with water and a mild soap or a cleansing lotion that does not contain soap. Rinse well and pat dry. Shake the foam can well before using. Apply a small amount of the medicine to each affected area and gently rub it in. Be sure to apply your azelaic acid at night and practice wearing sunscreen during the day. If you're using a serum with azelaic acid, apply it before azelaic acid, moisturizers, and sunscreen.
- Clindamycin (1%) or Erythromycin (1-4%). Apply 2-3 time daily.

Topical combination therapy

- Benzoyl peroxide (2.5-10%) + Clindamycin (1%) or Erythromycin (1-4%). Applied benzoyl peroxide 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply moisturizer for reduce side effects, avoid sensitive areas such as under the eyes, nostrils, and around the mouth. After that, apply clindamycin or erythromycin a small amount as a thin film once a day, at least one hour before bedtime. Apply the medicine to dry, clean areas affected by acne. Rub in gently and well.
- Benzoyl peroxide (2.5%) + Adapalene (0.1%). Apply a thin film of adapalene and benzoyl peroxide gel to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.

- Benzoyl peroxide (2.5%) + Retinoid (0.01-0.1%). Applied benzoyl peroxide 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply retinoid in a thin layer to your entire face at night skin care routine (be careful not to get it in your mouth, nostrils, and eyes). Finish with a facial moisturizer that won't clog your pores (non-comedogenic). You must apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning.

- Benzoyl peroxide (2.5%) + Tretinoin (0.05%) or Isotretinoin (0.05%) + Clindamycin (1%) or Erythromycin (1-4%). Applied benzoyl peroxide 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face. Before applying the gel, wash and dry the skin. As advised by your doctor, isotretinoin should be thinly placed over the affected area(s) of skin once or twice a day. Make sure the gel doesn't accumulate in skin folds or the sides of the nose and take care to prevent rubbing it around your eyes, mouth, or nostrils. After that Clindamycin (1%) or Erythromycin (1-4%). Apply 2-3 time daily.

- Tretinoin (0.05%) + Clindamycin (1%) or Erythromycin (1-4%). Use only a pea-sized quantity of the topical clindamycin and tretinoin. Apply to your entire face at bedtime every night. While taking this medication, do not wash your face more than three times every day. Acne might get worse if you wash your face more frequently or scrub it when you do.

The medication products of retinoid

- Adapalene (Differin®, Epiduo®).
- Tazarotene (Tazorac®, Avage®).
- Tretinoin (Atralin®, Avita®, Refissa®, Renova®, Retin-A®, Tretin-X®).

Side effects

- Redness
- Peeling
- Drying
- Itching
- Photosensitivity
- Burning sensation
- skin irritants (stop to apply the products and consult with dermatologist.)

** To reduce side effects, you must apply moisturizer to every skin care routine and. apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning. **

consultation with dermatologist or pharmaceutical before you apply the products.

Severity 3 Moderate-inflammation

Papule, pustules, and few nodules

You can choose the combination that recommends topical and systemic products for acne treatment. (Topical combination therapy, Systemic and topical therapy)

Topical combination therapy

- Benzoyl peroxide (2.5-10%) + Clindamycin (1%) or Erythromycin (1-4%). Applied benzoyl peroxide 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply moisturizer for reduce side effects, avoid sensitive areas such as under the eyes, nostrils, and around the mouth. After that, apply clindamycin or erythromycin a small amount as a thin film once a day, at least one hour before bedtime. Apply the medicine to dry, clean areas affected by acne. Rub in gently and well.
- Tretinoin (0.05%) + Clindamycin (1%). Use only a pea-sized quantity of the topical clindamycin and tretinoin. Apply to your entire face at bedtime every night. While taking this medication, do not wash your face more than three times every day. Acne might get worse if you wash your face more frequently or scrub it when you do.
- Isotretinoin (0.05%) + Erythromycin (2%). Before applying the gel, wash and dry the skin. As advised by your doctor, Isotrexin® should be thinly placed over the affected area(s) of skin once or twice a day. Make sure the gel doesn't accumulate in skin folds or the sides of the nose and take care to prevent rubbing it around your eyes, mouth, or nostrils.
- Benzoyl peroxide (2.5%) + Adapalene (0.1%). Apply a thin film of adapalene and benzoyl peroxide gel to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.
- Tazarotene (0.1%) + Clindamycin (1%) or Erythromycin (2%) + Benzoyl peroxide (2.5%). Apply once daily in the evening after facial cleansing. Clindamycin or erythromycin will be applied first and tazarotene will be applied 5-10 minutes later. Benzoyl peroxide gel to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.

Systemic and topical therapy

- Oral antibiotics + Adapalene (0.1%). Apply a thin film of adapalene to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.
- Oral antibiotics + Azelaic acid (20%). Before applying, wash the affected area of your skin with water and a mild soap or a cleansing lotion that does not contain soap. Rinse well and pat dry. Shake the foam can well before using. Apply a small amount of the medicine to each affected area and gently rub it in. Be sure to apply your azelaic acid at night and practice wearing sunscreen during the day. If you're using a serum with azelaic acid, apply it before azelaic acid, moisturizers, and sunscreen.
- Oral antibiotics + Benzoyl peroxide (2.5-10%). Applied 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply moisturizer for reduce side effects, avoid sensitive areas such as under the eyes, nostrils, and around the mouth (for beginner should be use 2.5% concentration of benzoyl peroxide)

- Oral antibiotics + Benzoyl peroxide (2.5%) + Retinoid (0.01-0.1%). Applied benzoyl peroxide 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply retinoid in a thin layer to your entire face at night skin care routine (be careful not to get it in your mouth, nostrils, and eyes). Finish with a facial moisturizer that won't clog your pores (non-comedogenic). You must apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning.

- Oral antibiotics + Benzoyl peroxide (2.5%) + Adapalene (0.1%). Apply a thin film of adapalene and benzoyl peroxide gel to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.

- Oral antibiotics + Tazarotene (0.1%) + Clindamycin (1%) or Erythromycin (2%) + Benzoyl peroxide (2.5%). Apply once daily in the evening after facial cleansing. Clindamycin or erythromycin will be applied first and tazarotene will be applied 5-10 minutes later. Benzoyl peroxide gel to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.

Oral antibiotic medicine should be consult with dermatologist or pharmaceutical before.

Oral antibiotics

- **Tetracycline.** Adults 1,000-1,500 mg/day when symptoms improve reduce the dose to 125-500 mg/day. Children (> 8 years old) 25-50 mg/kg/day
- **Doxycycline.** Adults 200 mg/day then 100 mg/day. Children (> 8 years old) 2 mg/lb./day then 1mg/lb./day
- **Minocycline.** Adults 50 mg 1-3 times/day. Children (> 8 years old) 4 mg/kg every 12 hour.
- **Erythromycin** 500-1000 mg/day
- **Azithromycin** 500 mg 1-3 times/week
- **Cotrimoxazole** 800/160 mg twice daily.

The medication products of retinoid

- Adapalene (Differin®, Epiduo®).
- Tazarotene (Tazorac®, Avage®).
- Tretinoin (Atralin®, Avita®, Refissa®, Renova®, Retin-A®, Tretin-X®).

Side effects

- Redness
- Peeling
- Drying
- Itching

- Photosensitivity
- Burning sensation
- skin irritants (stop to apply the products and consult with dermatologist.)

** To reduce side effects, you must apply moisturizer to every skin care routine and. apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning. **

consultation with dermatologist or pharmaceutical before you apply the products.

Severity 4 Severe inflammation

Papule, pustules, and multiple nodules

You can choose the only one that recommends systemic products or combination for acne treatment. (Systemic therapy, Systemic and topical combination therapy)

Recommends to oral isotretinoin medicine.

- **Isotretinoin.** ≥ 12 years of age: 0.5-1mg/kg/day orally in 2 divided doses with food. Duration of dosing 15-20 weeks.

Adverse effects/toxicities

- Cardiovascular: chest pain, edema flushing, stroke
- Skin: alopecia, cheilitis, cutaneous allergic reaction, dry nose, dry skin, photosensitivity
- Gastrointestinal: bleeding and inflammation of gums, colitis, esophagitis, nausea
- Ocular: dry eyes, optic neuritis

Recommends to oral antibiotics medicine.

- **Doxycycline.** Adults 200 mg. on the first day of treatment (administered 100 mg every 12 hours) followed by a maintenance dose of 100 mg/day. Eat immediately after meals.

- **Tetracycline.** Adults 1,000-1,500 mg/day when symptoms improve reduce the dose to 125-500 mg/day. Children (> 8 years old) 25-50 mg/kg/day

- **Minocycline.** Adults 50 mg 1-3 times/day. Children (> 8 years old) 4 mg/kg every 12 hour.

- **Erythromycin** 500-1000 mg/day

- **Azithromycin** 500 mg 1-3 times/week

- **Cotrimoxazole** 800/160 mg twice daily.

Adverse effects/toxicities

- Gastrointestinal: anorexia, nausea, diarrhea, vomiting
- Skin: toxic epidermal necrolysis, erythema multiforme, photosensitivity
- Drug allergy: hives, edema

Oral antibiotic medicine should be consult with dermatologist or pharmaceutical before.

You can choose the only one that recommends topical products for acne treatment.

Recommends applying topical products with antibiotics.

- Oral antibiotics + Benzoyl peroxide (2.5-10%). Applied 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply moisturizer for reduce side effects, avoid sensitive areas such as under the eyes, nostrils, and around the mouth (for beginner should be use 2.5% concentration of benzoyl peroxide)
- Oral antibiotics + Adapalene (0.1%). Apply a thin film of adapalene to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.
- Oral antibiotics + Azelaic acid (20%). Before applying, wash the affected area of your skin with water and a mild soap or a cleansing lotion that does not contain soap. Rinse well and pat dry. Shake the foam can well before using. Apply a small amount of the medicine to each affected area and gently rub it in. Be sure to apply your azelaic acid at night and practice wearing sunscreen during the day. If you're using a serum with azelaic acid, apply it before azelaic acid, moisturizers, and sunscreen.
- Oral antibiotics + Benzoyl peroxide (2.5%) + Retinoid (0.01-0.1%). Applied benzoyl peroxide 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply retinoid in a thin layer to your entire face at night skin care routine (be careful not to get it in your mouth, nostrils, and eyes). Finish with a facial moisturizer that won't clog your pores (non-comedogenic). You must apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning.
- Oral antibiotics + Benzoyl peroxide (2.5%) + Adapalene (0.1%). Apply a thin film of adapalene and benzoyl peroxide gel to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.
- Oral antibiotics + Clindamycin or Erythromycin (3%) + Benzoyl peroxide (5%). Applied benzoyl peroxide 1-2 time daily. Applied before taking a shower for 5–10 minutes in a thin layer on the face and then wash – out of your face, after that apply moisturizer for reduce side effects, avoid sensitive areas such as under the eyes, nostrils, and around the mouth. After that, apply clindamycin or erythromycin a small amount as a thin film once a day, at least one hour before bedtime. Apply the medicine to dry, clean areas affected by acne. Rub in gently and well.
- Oral antibiotics + Tazarotene (0.1%) + Clindamycin (1%) or Erythromycin (2%) + Benzoyl peroxide (2.5%). Apply once daily in the evening after facial cleansing. Clindamycin or erythromycin will be applied first and tazarotene

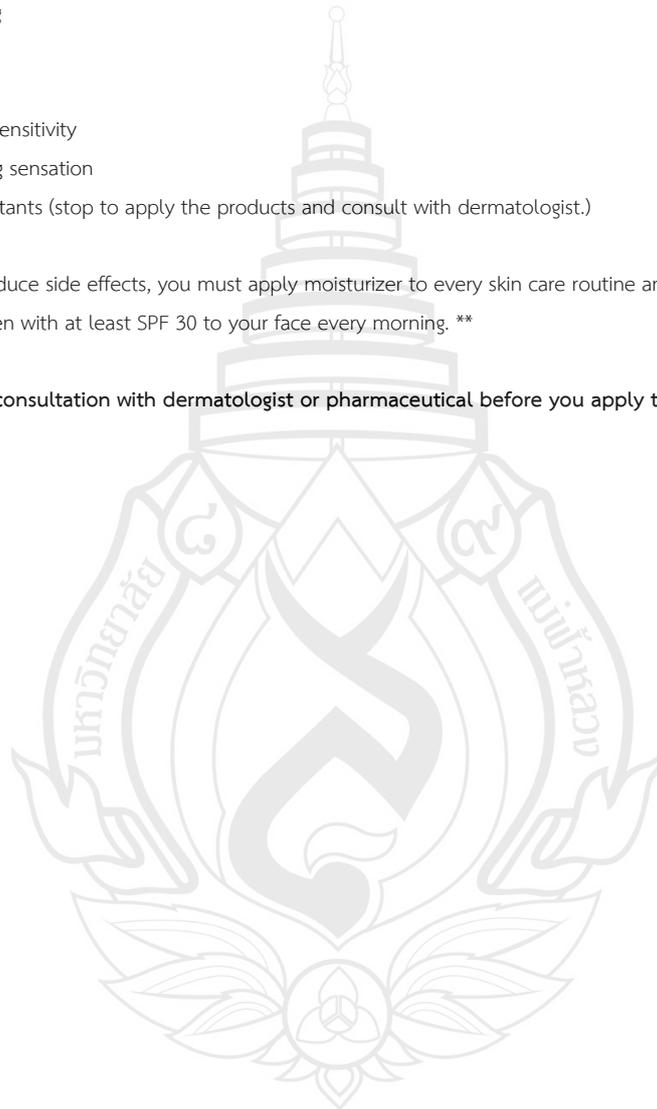
will be applied 5-10 minutes later. Benzoyl peroxide gel to affected areas of the face and/or trunk once daily after washing. Use a pea-sized amount for each area of the face (e.g., forehead, chin, each cheek). Avoid the eyes, lip, and mucous membranes.

Side effects

- Redness
- Peeling
- Drying
- Itching
- Photosensitivity
- Burning sensation
- skin irritants (stop to apply the products and consult with dermatologist.)

** To reduce side effects, you must apply moisturizer to every skin care routine and. apply a broad-spectrum sunscreen with at least SPF 30 to your face every morning. **

consultation with dermatologist or pharmaceutical before you apply the products.



ภาคผนวก ข

ข้อมูลการเรียกใช้ Face Parsing สำหรับขั้นตอนการเตรียมข้อมูล

```
from transformers import AutoImageProcessor, AutoModelForSemanticSegmentation
import torch, cv2

processor = AutoImageProcessor.from_pretrained("jonathandinu/face-parsing")
model = AutoModelForSemanticSegmentation.from_pretrained("jonathandinu/face-parsing")

image = cv2.imread("face.jpg")
inputs = processor(images=image, return_tensors="pt")
outputs = model(**inputs)
mask = torch.argmax(outputs.logits.squeeze(), dim=0).detach().cpu().numpy()
```

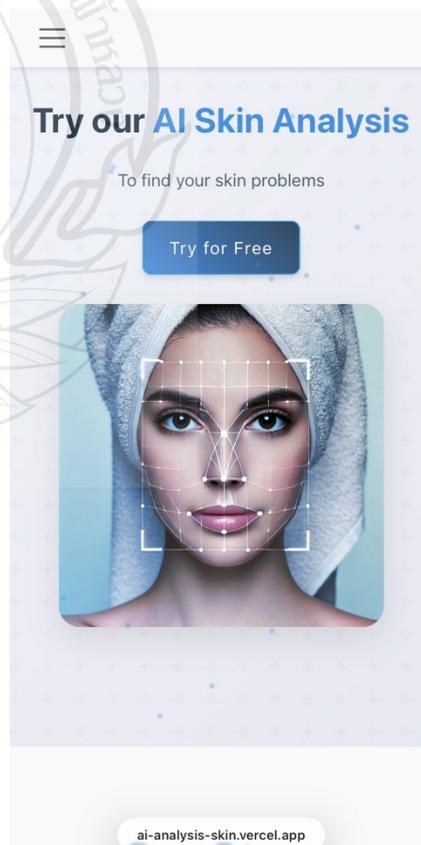
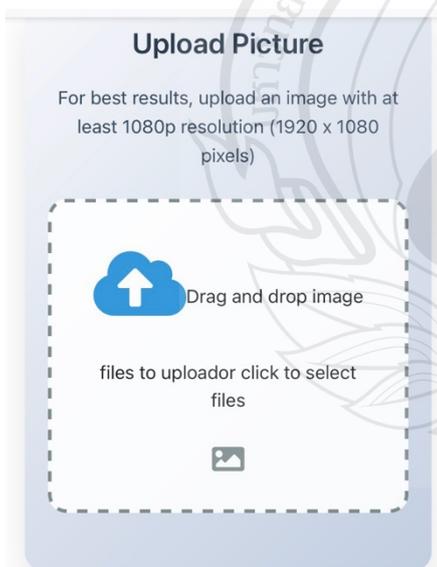


ภาคผนวก ซ

หน้า UI (User Interface) ของ Web Application



<https://ai-analysis-skin.vercel.app/>



ภาคผนวก ฅ

การอธิบายการตัดสินใจของแบบจำลองด้วยเทคนิค Grad-CAM

```

%% ===== Load & split =====
imds = imageDatastore('/Users/rodheng/Documents/ForMATLAB/FacePasing/Train', ...
    'IncludeSubfolders', true, 'LabelSource', 'foldernames');
imds = shuffle(imds);
[imdsTrain, imdsValid] = splitEachLabel(imds, 0.8, 'randomized');

disp('Label counts (all):');    countEachLabel(imds)
disp('Label counts (train):'); countEachLabel(imdsTrain)
disp('Label counts (valid):'); countEachLabel(imdsValid)

%% ===== Load Pretrained ResNet50 and Modify Layers =====
net = resnet50;
inputSize = net.Layers(1).InputSize;
lgraph = layerGraph(net);
numClasses = numel(categories(imdsTrain.Labels));

% แทนที่ fully-connected ท้ายสุด
newLearnableLayer = fullyConnectedLayer(numClasses, 'Name','new_fc', ...
    'WeightLearnRateFactor',10, 'BiasLearnRateFactor',10);
lgraph = replaceLayer(lgraph, 'fc1000', newLearnableLayer);

% แทนที่ชั้นจำแนก
lgraph = replaceLayer(lgraph, 'ClassificationLayer_fc1000', ...
    classificationLayer('Name','new_classoutput'));

figure; plot(lgraph); title('Modified ResNet-50');

%% ===== Augmentation & Datastores =====
imageAugmenter = imageDataAugmenter( ...
    'RandXReflection', true, ...
    'RandRotation', [-30, 30], ...
    'RandScale', [0.8, 1.2], ...
    'RandXTranslation', [-20, 20], ...

```

```

'RandYTranslation', [-20, 20]);

augimdsTrain = augmentedImageDatastore(inputSize(1:2), imdsTrain, ...
    'DataAugmentation', imageAugmenter, 'DispatchInBackground', true);

augimdsValid = augmentedImageDatastore(inputSize(1:2), imdsValid, ...
    'DispatchInBackground', true);

%% ===== Training Options =====
patience = 6;
ckptDir = fullfile(pwd,'checkpoints');
if ~exist(ckptDir,'dir'), mkdir(ckptDir); end

options = trainingOptions('adam', ...
    'ValidationData', augimdsValid, ...
    'MiniBatchSize', 128, ...
    'MaxEpochs', 300, ...
    'InitialLearnRate', 0.001, ...
    'Shuffle', 'every-epoch', ...
    'ValidationFrequency', 10, ...
    'ValidationPatience', patience, ...
    'OutputNetwork', 'best-validation-loss', ...
    'CheckpointPath', ckptDir, ...
    'Plots', 'training-progress');

%% ===== Train =====
trainedNet = trainNetwork(augimdsTrain, lgraph, options);

%% ===== Evaluation (Validation) =====
YPredValid = classify(trainedNet, augimdsValid);
valAcc = mean(YPredValid == imdsValid.Labels);
figure;
cmValid = confusionchart(imdsValid.Labels, YPredValid, 'Normalization','row-normalized');
cmValid.Title = 'Confusion Matrix - Validation';
cmValid.RowSummary = 'row-normalized';
cmValid.ColumnSummary = 'column-normalized';
disp(['Validation Accuracy: ', num2str(valAcc*100, '%.2f'), '%']);

%% ===== Test Set =====
imdsTest = imageDatastore('/Users/rodkenj/Documents/ForMATLAB/FacePasing/Test', ...
    'IncludeSubfolders', true, 'LabelSource','foldernames');

```

```

disp('Label counts in TEST:'); countEachLabel(imdsTest)

augimdsTest = augmentedImageDatastore(inputSize(1:2), imdsTest); % no augmentation

[YPredTest, scoresTest] = classify(trainedNet, augimdsTest);
accTest = mean(YPredTest == imdsTest.Labels);
figure;
cmTest = confusionchart(imdsTest.Labels, YPredTest, 'Normalization', 'row-normalized');
cmTest.Title = 'Confusion Matrix - Test';
cmTest.RowSummary = 'row-normalized';
cmTest.ColumnSummary = 'column-normalized';
disp(['Test Accuracy: ', num2str(accTest*100, '%.2f'), '%']);

%% ===== Per-class Metrics =====
numClasses = numel(categories(imdsTest.Labels));
metrics = array2table(zeros(numClasses, 4), ...
    'VariableNames', {'Precision', 'Recall', 'F1Score', 'Specificity'}, ...
    'RowNames', categories(imdsTest.Labels));

confMatTest = confusionmat(imdsTest.Labels, YPredTest, ...
    'Order', categories(imdsTest.Labels));

for j = 1:numClasses
    TP = confMatTest(j, j);
    FP = sum(confMatTest(:, j)) - TP;
    FN = sum(confMatTest(j, :)) - TP;
    TN = sum(confMatTest(:)) - TP - FP - FN;

    metrics.Precision(j) = TP / (TP + FP + eps);
    metrics.Recall(j) = TP / (TP + FN + eps);
    metrics.F1Score(j) = 2 * (metrics.Precision(j) * metrics.Recall(j)) / ...
        (metrics.Precision(j) + metrics.Recall(j) + eps);
    metrics.Specificty(j) = TN / (TN + FP + eps);
end

disp(metrics);
avgMetricsTable = array2table(mean(metrics{:, :}), ...
    'VariableNames', metrics.Properties.VariableNames);
disp(avgMetricsTable);

```

```

%% ===== ROC Curve =====
figure; hold on;
classLabels = categories(imdsTest.Labels);
for k = 1:numClasses
    [rocX, rocY, ~, AUC] = perfcurve(imdsTest.Labels == classLabels{k}, scoresTest(:, k), true);
    plot(rocX, rocY, 'DisplayName', [Class ', char(classLabels{k}), ' (AUC=', num2str(AUC, '%.2f'), ']');
end
xlabel('False Positive Rate'); ylabel('True Positive Rate');
title('ROC Curves for Test Set'); legend('Location', 'Best'); hold off;

%% ===== Grad-CAM / CNN Heat Maps (CAM) : Single Example =====
% เลือกรูปจากชุด Test แบบสุ่ม
idx = randi(numel(imdsTest.Files));
lorig = readimage(imdsTest, idx); % รูปต้นฉบับ (ขนาดจริง)

% Resize ให้ตรงกับ input ของ ResNet50 (ป้องกัน error Invalid input size)
I = imresize(lorig, inputSize(1:2));

% ทำนายคลาสของภาพนี้
[predLabel, predScore] = classify(trainedNet, I);

% สร้าง Class Activation Map ด้วย Grad-CAM
% ถ้า MATLAB มี gradCAM (R2021a+)
scoreMap = gradCAM(trainedNet, I, predLabel);

% ถ้าจำเป็นระบุชั้น feature (ตัวอย่างสำหรับ ResNet50)
% featureLayer = 'activation_49_relu';
% scoreMap = gradCAM(trainedNet, I, predLabel, 'FeatureLayer', featureLayer);

% ปรับขนาด heatmap ให้เท่ากับรูปต้นฉบับ เพื่อ overlay
scoreMap = imresize(scoreMap, [size(lorig,1) size(lorig,2)]);

% แสดงผล
figure;

% รูปต้นฉบับ
subplot(1,2,1);
imshow(lorig);
trueLabel = imdsTest.Labels(idx);
title(sprintf('Original\nTrue: %s | Pred: %s', ...

```

```

string(trueLabel), string(predLabel)), 'Interpreter','none');

% รูป overlay Grad-CAM
subplot(1,2,2);
imshow(lorig); hold on;
h = imagesc(scoreMap);
colormap jet;
h.AlphaData = 0.5; % ความโปร่งแสงของ heatmap
title('Grad-CAM Heatmap');
colorbar;
hold off;

%% ===== Grad-CAM / CNN Heat Maps (CAM) : Multiple Examples =====
numShow = 6; % จำนวนภาพที่ยากดู
numShow = min(numShow, numel(imdsTest.Files)); % กันเกิน

idxs = randperm(numel(imdsTest.Files), numShow);

figure;
for i = 1:numShow
    lorig = readimage(imdsTest, idxs(i));
    I = imresize(lorig, inputSize(1:2));

    [predLabel, ~] = classify(trainedNet, I);
    scoreMap = gradCAM(trainedNet, I, predLabel);
    scoreMap = imresize(scoreMap, [size(lorig,1) size(lorig,2)]);

    % แถวบน: รูปจริง + label
    subplot(2, numShow, i);
    imshow(lorig);
    title(sprintf('True: %s\nPred: %s', ...
        string(imdsTest.Labels(idxs(i))), string(predLabel)), ...
        'Interpreter','none');

    % แถวล่าง: รูป overlay CAM
    subplot(2, numShow, i + numShow);
    imshow(lorig); hold on;
    h = imagesc(scoreMap);
    colormap jet;
    h.AlphaData = 0.5;
    title('CAM');

```

hold off;
end



ประวัติผู้ประพันธ์

ชื่อ	ธราดล ขวัญศิริ
ประวัติการศึกษา	
2560-2564	ปริญญาตรี วิทยาศาสตร์บัณฑิต (เทคโนโลยีความงาม) วิทยาศาสตร์เครื่องสำอาง มหาวิทยาลัยแม่ฟ้าหลวง
ประวัติการทำงาน	
2568-ปัจจุบัน	เจ้าหน้าที่ประสานโครงการ (นักวิทยาศาสตร์) มหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย
2565-2568	ผู้ช่วยสอนในรายวิชาจิตวิทยาในชีวิตประจำวัน
2565	มหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย ผู้ช่วยนักวิจัยในโครงการการประเมินประสิทธิผลผลิตภัณฑ์ฟรีไบโอติคส์จากน้ำตาลอ้อยธรรมชาติสำหรับ การฟื้นฟูจุลินทรีย์ในระบบทางเดินอาหารที่เป็นประโยชน์ต่อภาวะสุขภาพของประชากรไทยวัยทำงาน การศึกษาแบบทดลอง มหาวิทยาลัยแม่ฟ้าหลวง จังหวัดเชียงราย
ทุนการศึกษา	
2565	ทุนสนับสนุนระดับบัณฑิตศึกษา มหาวิทยาลัยแม่ฟ้าหลวง